UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Engenharia
Campus de Bauru

**FABIO ISAAC FERREIRA**

# PREDIÇÃO DA LARGURA ÚTIL DE DRESSADORES DE PONTA ÚNICA UTILIZANDO EMISSÃO ACÚSTICA E REDES NEURAIS ARTIFICIAIS

**Bauru**
**2016**

**FABIO ISAAC FERREIRA**

# PREDIÇÃO DA LARGURA ÚTIL DO DRESSADOR DE PONTA ÚNICA UTILIZANDO EMISSÃO ACÚSTICA E REDES NEURAIS ARTIFICIAIS

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

Orientador: Prof. Dr. Paulo Roberto de Aguiar

Ferreira, Fábio Isaac.
Predição da Largura Útil de Dressadores de Ponta Única Utilizando Emissão Acústica e Redes Neurais Artificiais / Fábio Isaac Ferreira, 2016
130 f. : il.

Orientador: Paulo Roberto de Aguiar

Dissertação (Mestrado)–Universidade Estadual Paulista. Faculdade de Engenharia, Bauru, 2016

1. Emissão Acústica. 2. Dressagem. 3. Redes Neurais Artificiais. 4. Monitoramento da condição da Ferramenta. I. Universidade Estadual Paulista. Faculdade de Engenharia. II. Título.

UNIVERSIDADE ESTADUAL PAULISTA

**Câmpus de Bauru**

**ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE FÁBIO ISAAC FERREIRA, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DA FACULDADE DE ENGENHARIA.**

Aos 25 dias do mês de agosto do ano de 2016, às 14:00 horas, no(a) Anfiteatro da Seção Técnica de Pós-graduação da FEB, reuniu-se a Comissão Examinadora da Defesa Pública, composta pelos seguintes membros: Prof. Dr. PAULO ROBERTO DE AGUIAR - Orientador(a) do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, Prof. Dr. FABRICIO GUIMARÃES BAPTISTA do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, Prof. Dr. DANILO HERNANE SPATTI do(a) Departamento Acadêmico de Elétrica / Universidade Tecnológica Federal do Paraná, sob a presidência do primeiro, a fim de proceder a arguição pública da DISSERTAÇÃO DE MESTRADO de FÁBIO ISAAC FERREIRA, intitulada **PREDIÇÃO DA LARGURA ÚTIL DE DRESSADORES DE PONTA ÚNICA UTILIZANDO EMISSÃO ACÚSTICA E REDES NEURAIS ARTIFICIAIS**. 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. FABRICIO GUIMARÃES BAPTISTA

Prof. Dr. DANILO HERNANE SPATTI

UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Campus de Bauru

FEB

## PROPOSTA DE ALTERAÇÃO DO TÍTULO

A BANCA EXAMINADORA PROPÕE A ALTERAÇÃO DO TÍTULO DO TRABALHO DO ALUNO: FÁBIO ISAAC FERREIRA

DE: "MONITORAMENTO DA FERRAMENTA PARA PREDIÇÃO DA LARGURA ÚTIL DO DRESSADOR DE PONTA ÚNICA UTILIZANDO EMISSÃO ACÚSTICA"

PARA:
Predição da largura útil do dressador de ponta única utilizando emissão acústica e redes neurais artificiais.

Bauru, 11 de julho de 2016.

Prof. Dr. Paulo Roberto de Aguiar
Orientador

Dedico este trabalho à minha família, por ter a persistência e a paciência de acreditar e investir em mim. Ao meu pai, cuja presença significou segurança e certeza de que jamais estou sozinho nesta jornada. À minha mãe, pelo cuidado e dedicação que me deram esperança para prosseguir.

## AGRADECIMENTOS

A Deus, por tudo o que me deu e me ajudou a conquistar. Por sua presença, me iluminando e me ajudando a tomar as decisões da minha vida.

Aos meus pais Rosa e Antônio, por me propiciarem a oportunidade de estudar e me desenvolver profissionalmente. Por todo apoio financeiro, incentivos, conselhos, carinho e compreensão. A eles, todo o meu amor e gratidão.

Aos meus irmãos Caroline e Alexandre, juntamente com minha avó Lídia e a todos os meus familiares, que, de alguma forma, estiveram ao meu lado neste período de batalhas e vitórias, demonstrando e tornando viva a importância dos laços entre a família.

Ao meu orientador, Prof. Dr. Paulo Roberto de Aguiar, pela amizade de todo este tempo e pela oportunidade em me aceitar como seu orientado. Por todos os conhecimentos transmitidos, que me impulsionaram a crescer como ser humano e como profissional, sempre serei grato.

Aos professores Eduardo Carlos Bianchi, Fabrício de Guimarãoes Baptista, Alfredo Covolan Ulson e Doriana M. D'Addona pela disponibilidade em sempre auxiliar e direcionar nas atividades imprescindíveis para a realização deste trabalho.

A todos os amigos da universidade, que, de alguma forma, deram seu apoio e auxílio, sempre dispostos em ajudar no trabalho e a partilhar experiências do dia-a-dia.

Ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), pelo suporte financeiro através da bolsa de pesquisa desfrutada durante todo este período.

Por todos os demais, que contribuíram, de alguma forma, pelo meu desenvolvimento e crescimento pessoal e profissional.

## RESUMO

A dressagem é um processo essencial para a usinagem, pois impacta diretamente na qualidade superficial de peças retificadas. A dressagem consiste em recompor a característica cortante dos grãos abrasivos da superfície do rebolo após sucessivas retificações, a partir da remoção de material pela ponta do dressador de diamante. O dressador pode ser monitorado em tempo real utilizando sensores, a fim de garantir a qualidade no processo da dressagem e fornecer informações da condição da ferramenta, sem precisar interromper o processo de usinagem. Assim, este trabalho propõe um método para predição da largura de atuação do dressador de diamante, utilizando sinais de emissão acústica e redes neurais artificiais. Sabe-se que a largura de atuação do dressador impacta diretamente na dressagem, pois determina a agressividade que é gerada no rebolo. Por isso, um sistema de monitoramento *online* que seja capaz de predizer um passo à frente a condição do dressador seria de grande valia para o processo, pois extinguiria a necessidade de paradas para monitoramento direto, reduziria a atuação dos operadores e evitaria a subutilização ou sobreutilização da ferramenta. Para este fim, os experimentos foram realizados em uma retificadora plana equipada com rebolos abrasivos de óxido de alumínio e dressadores piramidais de ponta única, do tipo natural. Os sinais de emissão acústica foram aquisitados a uma frequência de 2 MHz e processados utilizando filtros digitais e diferentes estatísticas, como RMS, ROP, *power law*, CFAR e MVD. Dois tipos de redes neurais foram desenvolvidos, um para estimação e outro para predição, sendo que a saída da primeira rede é utilizada como entrada para a segunda. Para a estimação, foram desenvolvidos modelos neurais do tipo MLP, que utilizam as estatísticas dos sinais do sensor como suas entradas. Para a predição, foram desenvolvidos modelos do tipo TDNN, que inserem o atraso no tempo. Os resultados obtidos indicam que a emissão acústica é eficiente para a predição da largura útil do dressador com a utilização das melhores estatísticas e faixa de bandas selecionadas. A utilização de redes neurais se apresentou eficiente para este tipo de aplicação e a metodologia proposta pode ser implementada para a predição do parâmetro, fornecendo informações indispensáveis ao processo, um passo à frente.



**Palavras-chave –** Emissão acústica. Dressagem. Redes neurais artificiais. Monitoramento da condição da ferramenta.

## ABSTRACT

Dressing is an important process in machining, because it directly impacts on the quality surface of the workpieces. Dressing consists of restoring the cutting characteristics of the abrasive grains on wheel surface after several grinding passes through material removal by the tip of the diamond dresser. The dresser can be monitored in real time using sensors in order to guarantee the quality of the dressing process and provide information about tool condition, without the need of interrupting machining process. Then, this work proposes a methodology to predict the width of dresser at the dressing depth using acoustic emission signals and artificial neural networks. It is known that the width of dressing at the dressing depth directly impacts in dressing, because it defines the wheel sharpness. Therefore an online monitoring system able to predict one step forward the condition of the dresser would be of great value for the process, because it would extinguish the need of stops for the direct monitoring, would reduce the function of operators and would avoid the sub-utilization and over-utilization of the tool. For this purpose, experiments were performed using a horizontal surface grinding machine equipped with aluminum oxide grinding wheels and natural single-point pyramidal dressers. Acoustic emission signals were acquired at 2 MHz and processed using digital filters and some statistics as RMS, ROP, power law, CFAR and MVD. Two kinds of neural networks were developed, one for estimation and other for prediction, wherein the output of first were used as input of second. For estimation, MLP neural models were developed, being that the statistics of sensor signals were used as their inputs. For prediction, TDNN neural models were developed, inserting time delay. Results obtained indicate that acoustic emission is efficient to predict width of dresser using the best statistics and selected width bands. Utilization of neural networks performed efficient for this kind of application and the proposed methodology can be implemented of prediction of this parameter, providing indispensable information to the process one step forward.



**Keywords –** Acoustic emission. Dressing. Artificial neural networks. Monitoring tool condition.

## LISTA DE ILUSTRAÇÕES

Figura 2-1 – Exemplo de quatro operações básicas de retificação. ..... 23
Figura 2-2 – Os seis elementos básicos envolvidos na retificação tangencial plana. 24
Figura 2-3 – Forças de corte para a retificação tangencial plana. ..... 27
Figura 2-4 – Representação esquemática do processo de dressagem. ..... 33
Figura 2-5 – Agressividade do rebolo em função de seu grau de recobrimento. ..... 34
Figura 2-6 – Reprentação do micro efeito nos grãos abrasivos. ..... 35
Figura 2-7 – Modelo de um neurônio artificial. ..... 42
Figura 2-8 – Rede Neural Perceptron de Múltiplas Camadas. ..... 44
Figura 2-9 – Estrutura geral da TDNN. ..... 48
Figura 3-1 – Um dos dressadores naturais piramidais utilizados nos ensaios. ..... 50
Figura 3-2 – Esquemático da montagem do banco de ensaios. ..... 51
Figura 3-3 – Sistema para a aquisição das imagens e foto do dressador para vista frontal (a) e (b) e vista superior (c) e (d). ..... 54
Figura 3-4 – Processo de extração do valor do $b_d$ através da análise das imagens. 56
Figura 3-5 – Fluxograma para obtenção do valor do $b_d$. ..... 57
Figura 3-6 – Primeira passada do sinal EA sendo: (a) sinal puro; (b) filtro de ordem 5; (c) estatística RMS e (d) filtro de ordem 1. ..... 59
Figura 3-7 – Seleção do trecho de contato entre o rebolo e a ferramenta (a) e trecho extraído (b). ..... 60
Figura 3-8 – Processo de tratamento do sinal EA para obtenção da curva de valores médios das passadas. ..... 60
Figura 3-9 – Construção dos modelos neurais para estimação e predição. ..... 62
Figura 4-1 – Relação entre o ajuste do inversor com o tempo de contato entre o rebolo e o diamante. ..... 65
Figura 4-2 – Evolução do $b_d$ durante as passadas para os três dressadores. ..... 69
Figura 4-3 – Média e desvio padrão do $b_d$ a partir dos valores dos três ensaios. ..... 69
Figura 4-4 – Média e desvio padrão do $U_d$ a partir do valor médio dos três ensaios. 70
Figura 4-5 – Comparação de filtros passa-baixa para uma mesma passada RMS. ..... 72
Figura 4-6 – Comparação de filtros passa-baixa para uma mesma passada CFAR. 73
Figura 4-7 – Comparação para diferentes valores de *v* utilizando *power law*. Da esquerda para direita, *v* é 0,5; 2,5 e ∞. ..... 73
Figura 4-8 – Comparação para diferentes valores de *v* utilizando CFAR. Da esquerda para a direita, *v* é 0,5; 2;5 e ∞. ..... 74
Figura 4-9 – Passadas RMS para as condições novo, meia-vida e desgastado. ..... 75
Figura 4-10 – Análise espectral de diferentes passadas utilizando a FFT. ..... 75
Figura 4-11 – Análise espectral de diferentes passadas utilizando a PSD. ..... 77
Figura 4-12 – Média das passadas RMS sem seleção de banda. ..... 79
Figura 4-13 – Média das passadas RMS para a banda 6 (32 kHz a 34 kHz) ..... 80
Figura 4-14 – Média das passadas ROP para a banda 6 (32 kHz a 34 kHz) ..... 80
Figura 4-15 – Média das passadas MVD sem seleção de banda. ..... 81
Figura 4-16 – Média das passadas *power law* sem seleção de banda. ..... 82
Figura 4-17 – Média das passadas CFAR sem seleção de banda. ..... 83
Figura 4-18 – Estrutura geral da rede de estimação. ..... 84

Figura 4-19 – Regressão para treino e teste da rede de estimação com 2 entradas. .....86
Figura 4-20 – Saída da melhor rede neural de estimação com 2 entradas. .....86
Figura 4-21 – Histograma de erro da melhor rede neural de estimação com 2 entradas. .....87
Figura 4-22 – Erros de estimação para o $b_d$. .....88
Figura 4-23 – Erros de estimação em porcentagem para o $b_d$. .....89
Figura 4-24 – Valores de $b_d$ estimado e predito, em comparação com os reais. .....91
Figura 4-25 – Regressão para treinamento e teste para a rede de predição. .....93
Figura 4-26 – Histograma de erro da melhor rede de predição. .....93
Figura 4-27 – Erros de predição para o $b_d$. .....94
Figura 4-28 – Erros de predição em porcentagem para o $b_d$. .....95
Figura A-1 – Média das passadas RMS para a banda 1 (21 kHz a 25 kHz). .....104
Figura A-2 – Média das passadas RMS para a banda 2 (24 kHz a 29 kHz). .....105
Figura A-3 – Média das passadas RMS para a banda 3 (25 kHz a 30 kHz). .....105
Figura A-4 – Média das passadas RMS para a banda 4 (29 kHz a 32 kHz). .....106
Figura A-5 – Média das passadas RMS para a banda 5 (30 kHz a 34 kHz). .....106
Figura A-6 – Média das passadas RMS para a banda 7 (41 kHz a 44 kHz). .....107
Figura A-7 – Média das passadas RMS para a banda 8 (50 kHz a 55 kHz). .....107
Figura A-8 – Média das passadas RMS para a banda 9 (63 kHz a 68 kHz). .....108
Figura A-9 – Média das passadas RMS para a banda 10 (72 kHz a 75 kHz). .....108
Figura A-10 – Média das passadas RMS para a banda 11 (95 kHz a 99 kHz). .....109
Figura A-11 – Média das passadas RMS para a banda 12 (105 kHz a 107 kHz). ..109
Figura A-12 – Média das passadas RMS para a banda 13 (111 kHz a 114 kHz). ..110
Figura A-13 – Média das passadas RMS para a banda 14 (120 kHz a 124 kHz). ..110
Figura A-14 – Média das passadas RMS para a banda 15 (131 kHz a 134 kHz). ..111
Figura A-15 – Média das passadas RMS para a banda 16 (199 kHz a 204 kHz). ..111
Figura A-16 – Média das passadas RMS para a banda 17 (216 kHz a 219 kHz). ..112
Figura A-17 – Média das passadas ROP sem seleção de banda. .....112
Figura A-18 – Média das passadas ROP para a banda 1 (21 kHz a 25 kHz).....113
Figura A-19 – Média das passadas ROP para a banda 2 (24 kHz a 29 kHz).....113
Figura A-20 – Média das passadas ROP para a banda 3 (25 kHz a 30 kHz).....114
Figura A-21 – Média das passadas ROP para a banda 4 (29 kHz a 32 kHz).....114
Figura A-22 – Média das passadas ROP para a banda 5 (30 kHz a 34 kHz).....115
Figura A-23 – Média das passadas ROP para a banda 7 (41 kHz a 44 kHz).....115
Figura A-24 – Média das passadas ROP para a banda 8 (50 kHz a 55 kHz).....116
Figura A-25 – Média das passadas ROP para a banda 9 (63 kHz a 68 kHz).....116
Figura A-26 – Média das passadas ROP para a banda 10 (72 kHz a 75 kHz).....117
Figura A-27 – Média das passadas ROP para a banda 11 (95 kHz a 99 kHz).....117
Figura A-28 – Média das passadas ROP para a banda 12 (105 kHz a 107 kHz)....118
Figura A-29 – Média das passadas ROP para a banda 13 (111 kHz a 114 kHz)....118
Figura A-30 – Média das passadas ROP para a banda 14 (120 kHz a 124 kHz)....119
Figura A-31 – Média das passadas ROP para a banda 15 (131 kHz a 134 kHz)....119
Figura A-32 – Média das passadas ROP para a banda 16 (199 kHz a 204 kHz)....120
Figura A-33 – Média das passadas ROP para a banda 17 (216 kHz a 219 kHz)....120
Figura A-34 – Média das passadas MVD para a banda 6 (32 kHz a 34 kHz). .....121
Figura A-35 – Média das passadas CFAR para a banda 2 (24 kHz a 29 kHz).....121

Figura A-36 – Média das passadas CFAR para a banda 3 (25 kHz a 30 kHz).....122
Figura A-37 – Média das passadas CFAR para a banda 4 (29 kHz a 32 kHz).....122
Figura A-38 – Média das passadas CFAR para a banda 5 (30 kHz a 34 kHz).....123
Figura A-39 – Média das passadas CFAR para a banda 6 (32 kHz a 34 kHz).....123
Figura A-40 – Média das passadas CFAR para a banda 8 (50 kHz a 55 kHz).....124
Figura A-41 – Média das passadas *power law* para a banda 1 (21 kHz a 25 kHz). 124
Figura A-42 – Média das passadas *power law* para a banda 2 (24 kHz a 29 kHz). 125
Figura A-43 – Média das passadas *power law* para a banda 3 (25 kHz a 30 kHz). 125
Figura A-44 – Média das passadas *power law* para a banda 4 (29 kHz a 32 kHz). 126
Figura A-45 – Média das passadas *power law* para a banda 5 (30 kHz a 34 kHz). 126
Figura A-46 – Média das passadas *power law* para a banda 6 (32 kHz a 34 kHz). 127
Figura A-47 – Média das passadas *power law* para a banda 7 (41 kHz a 44 kHz). 127
Figura A-48 – Média das passadas *power law* para a banda 8 (50 kHz a 55 kHz). 128

## LISTA DE TABELAS

Tabela 3-1 – Parâmetros de dressagem utilizados nos ensaios. .....52
Tabela 3-2 – Parâmetros utilizados no dispositivo para a captura de imagens.....53
Tabela 3-3 – Parâmetros de configuração do sistema de aquisição de dados. .....55
Tabela 3-4 – Parâmetros da rede neural de estimação .....63
Tabela 4-1 – Parâmetros de ajuste dos ensaios. .....66
Tabela 4-2 – Diâmetro do rebolo no início e no final de cada ensaio. .....67
Tabela 4-3 – Valores de $b_d$ para os três ensaios. .....68
Tabela 4-4 – $b_d$ médio e desvio padrão. .....70
Tabela 4-5 – Bandas de frequência selecionadas a partir da análise espectral pela FFT. .....76
Tabela 4-6 – Bandas de frequência selecionadas a partir da análise espectral pela PSD. .....77
Tabela 4-7 – Bandas de frequência selecionadas para análise. .....78
Tabela 4-8 – Melhores RNAs para diferentes entradas ativas. .....85
Tabela 4-9 – Correlação para cada entrada utilizada na RNA. .....90
Tabela 4-10 – Valores dos $b_d$'s das redes. .....92

## LISTA DE ABREVIATURAS E SIGLAS

$a$ – Profundidade de corte da retificação

$a_d$ – Profundidade de dressagem

$bd$ – Largura de atuação do dressador

CFAR – *Constant False Alarm Rate* (Taxa Constante de Alarme Falso)

DFT – *Discrete Fourier Transform* (Transformada Discreta de Fourier)

$d_s$ – Diâmetro do rebolo

EA – Emissão Acústica

FFT – *Fast Fourier Transform* (Transformada Rápida de Fourier)

IA – Inteligência Artificial

$L_R$ – Largura do Rebolo

MLP – *Multi-Layer Perceptron* (Perceptron Multi-Camadas)

MQL – Mínima Quantidade de Lubrificante

MVD – *Mean Value Dispersion* (Dispersão do Valor Médio)

$n_s$ – Velocidade de Rotação do Rebolo, em rpm

RMS – *Root Mean Square* (Valor Médio Quadrático)

RNA – Rede Neural Artificial

ROP – *Ratio Of Power* (Taxa de Potência do sinal)

$s_d$ – Avanço axial do dressador por revolução, ou passo de dressagem

TDNN – *Time Delay Neural Network* (Rede Neural com Atraso no Tempo)

$U_d$ – Grau de recobrimento do rebolo

$v_d$ – Velocidade transversal do rebolo, ou velocidade de dressagem

$v_s$ – Velocidade periférica do rebolo, ou velocidade de corte

$v_w$ – Velocidade da peça

$w_t$ – Ondulação teórica (macro efeito)

## SUMÁRIO


AGRADECIMENTOS ..... 7

RESUMO ..... 8

ABSTRACT ..... 9

LISTA DE ILUSTRAÇÕES ..... 10

LISTA DE TABELAS ..... 13

LISTA DE ABREVIATURAS E SIGLAS ..... 14

1 INTRODUÇÃO, OBJETIVOS E JUSTIFICATIVA ..... 18

**1.1 INTRODUÇÃO ..... 18**

**1.2 OBJETIVOS ..... 20**

**1.3 JUSTIFICATIVA PARA A REALIZAÇÃO DO TRABALHO ..... 20**

2 REVISÃO BIBLIOGRÁFICA ..... 22

**2.1 O PROCESSO DA RETIFICAÇÃO ..... 22**

2.1.1 A RETIFICAÇÃO TANGENCIAL PLANA ..... 23

2.1.1.1 COMPORTAMENTO DA PROFUNDIDADE DE CORTE ($a$) ..... 24

2.1.1.2 COMPORTAMENTO DA VELOCIDADE DE CORTE ($v_s$) ..... 25

2.1.1.3 COMPORTAMENTO DA VELOCIDADE DA PEÇA ($v_w$) ..... 25

2.1.2 FORÇAS DE CORTE NO PROCESSO DA RETIFICAÇÃO ..... 26

2.1.3 O REBOLO ..... 27

2.1.3.1 OS GRÃOS ABRASIVOS ..... 28

2.1.3.2 LIGANTES ..... 28

2.1.3.3 DUREZA ..... 29

2.1.3.4 GRANULOMETRIA ..... 29

2.1.3.5 ESTRUTURA ..... 30

**2.2 O PROCESSO DA DRESSAGEM ..... 30**

2.2.1 DRESSAGEM E TOPOGRAFIA ..... 31

2.2.2 DRESSADOR DE PONTA ÚNICA ..... 31

2.2.3 GRAU DE RECOBRIMENTO DO REBOLO ($U_d$). ..... 33

2.2.4 AGRESSIVIDADE DO REBOLO ..... 34

**2.3 MONITORAMENTO DO PROCESSO DE USINAGEM ..... 35**

**2.4 EMISSÃO ACÚSTICA ..... 36**

**2.5 PROCESSAMENTO DE SINAIS ..... 37**

2.5.1 VALOR EFICAZ DE UM SINAL (RMS) ..... 37

2.5.2 TAXA DE POTÊNCIA DE UM SINAL ..... 38
*2.5.3 POWER LAW* ..... 38
2.5.4 CFAR ..... 39
2.5.5 MVD ..... 39
2.5.6 TRANSFORMADA DISCRETA DE FOURIER ..... 40
2.5.7 MÉDIA E DESVIO PADRÃO ..... 40

**2.6 REDES NEURAIS ARTIFICIAIS ..... 41**
2.6.1 REDE NEURAL PERCEPTRON DE MÚLTIPLAS CAMADAS ..... 43
2.6.1.1 ALGORITMO *BACKPROPAGATION* ..... 44
2.6.1.2 ALGORITMO DE TREINAMENTO LEVENBERG-MARQUARDT ..... 45
2.6.2 REDES TDNN ..... 46
2.6.3 COEFICIENTE DE CORRELAÇÃO ..... 49

3 MATERIAIS E MÉTODOS ..... 50

**3.1 MONTAGEM DO BANCO DE ENSAIOS ..... 50**
3.1.1 CONFIGURAÇÃO DOS PARÂMETROS DE DRESSAGEM ..... 51
3.1.2 SISTEMA DE AQUISIÇÃO DE IMAGENS ..... 52
3.1.3 SISTEMA DE AQUISIÇÃO DE DADOS ..... 54

**3.2 PROCEDIMENTO DOS ENSAIOS ..... 55**

**3.3 CÁLCULO DOS VALORES DA LARGURA DE ATUAÇÃO DO DRESSADOR ..... 56**

**3.4 PROCESSAMENTO DO SINAL DE EMISSÃO ACÚSTICA ..... 58**

**3.5 MODELOS NEURAIS ..... 61**
3.5.1 TREINAMENTO DOS MODELOS NEURAIS ..... 62

4 RESULTADOS E DISCUSSÕES ..... 65

**4.1 ENSAIOS DE DRESSAGEM ..... 65**

**4.2 ANÁLISE DAS IMAGENS ..... 67**

**4.3 PROCESSAMENTO DOS SINAIS DE EMISSÃO ACÚSTICA ..... 71**
4.3.1 ESCOLHA DO FILTRO PASSA-BAIXA ..... 71
4.3.2 INFLUÊNCIA DO EXPOENTE VARIÁVEL (*v*) NO *POWER LAW* E CFAR ..... 73
4.3.3 ANÁLISE ESPECTRAL UTILIZANDO A FFT ..... 74
4.3.4 ANÁLISE ESPECTRAL UTILIZANDO A PSD ..... 76
4.3.5 ANÁLISE DOS VALORES MÉDIOS ..... 78
4.3.5.1 RMS ..... 79
4.3.5.2 ROP ..... 80
4.3.5.3 MVD ..... 81
4.3.5.4 POWER LAW ..... 81
4.3.5.5 CFAR ..... 82

**4.4 MODELOS NEURAIS ..... 83**
4.4.1 REDE DE ESTIMAÇÃO ..... 83
4.4.1.1 CORRELAÇÃO DAS ENTRADAS COM A SAÍDA ..... 89
4.4.2 REDE DE PREDIÇÃO ..... 90

5 CONCLUSÃO ..... 96

REFERÊNCIAS ..... 98

APÊNDICES ..... 103

**APÊNDICE A – Médias das Estatísticas ..... 104**

**APÊNDICE B – Instruções para Estimação do $b_d$ ..... 129**

**APÊNDICE C – Instruções para Predição do $b_d$ ..... 130**

# 1 INTRODUÇÃO, OBJETIVOS E JUSTIFICATIVA

## 1.1 INTRODUÇÃO

A retificação é um dos processos de maior complexidade da cadeia de usinagem. Ela é influenciada por diversos fatores, como a peça a ser usinada, a máquina retificadora, o rebolo e os ajustes dos parâmetros. A utilização do rebolo como ferramenta de corte é o principal fator que diferencia este processo dos demais entre os existentes na usinagem. A topografia do rebolo e as condições sob as quais ele é preparado possuem uma influência significativa no desempenho da retificação.

Para que a qualidade da peça retificada atenda aos padrões desejados, como em sua rugosidade ou dimensões finais, é necessário que o rebolo esteja com seus grãos abrasivos afiados para o corte. Após sucessivas retificações, o rebolo vai perdendo sua característica cortante e torna-se “empastado”. Continuar utilizando o rebolo nessas condições pode fazer com que as peças possuam uma rugosidade muito acima do tolerável, ou até mesmo provocar a sua queima, ocasionando em sua perda total. Nesse momento, é necessário realizar processos de recondicionamento do rebolo: a limpeza e a dressagem.

Os processos de recondicionamento do rebolo determinam a taxa de remoção do material, as forças da retificação, a qualidade superficial da peça e as propriedades da zona abaixo da superfície. Além disso, a preparação eficiente do rebolo exige um sistema sofisticado e complexo, que possa garantir os cuidados necessários por meio do tratamento e monitoramento da ferramenta (MARTINS *et al*., 2014).

O processo da dressagem, principal processo de recondicionamento do rebolo, consiste na sua afiação, reestabelecendo sua característica cortante original. Por isso ele é imprescindível sempre que a retificação é utilizada pelas indústrias mecânicas. A dressagem consiste em utilizar uma ferramenta pontiaguda – o dressador – composta por um material mais duro que o rebolo, por exemplo de diamante, para remover a camada superficial que se encontra recoberta com resíduos resultantes do processo, além de eliminar os grãos superficiais do rebolo que já não

possuem mais corte. Por isso, o *slogan* “Retificação é dressagem” é lembrado fortemente dentro da comunidade de retificação (WEGENER *et al*., 2011).

Atualmente, o monitoramento do dressador durante o processo da dressagem é feito manualmente por operadores que controlam a máquina. Eles monitoram o desgaste do dressador de forma visual, necessitando interromper o processo da máquina para verificar a condição do diamante e decidir até quando o dressador pode ser utilizado e quando é necessário substituí-lo. Esta metodologia resulta em ineficiência do tempo, atraso na operação e custos operacionais humanos (ZHOU *et al*., 2011).

Para automatizar esta tarefa, podem ser utilizados métodos indiretos de monitoramento através de sensores. Esses métodos evitam que a máquina necessite ser desligada para a verificação manual e permitem que sinais elétricos sejam coletados e processados, sem a necessidade de interromper o processo da dressagem. Entre eles estão a emissão acústica, força, vibração e corrente (D’ADDONA *et al*., 2016).

Os sinais processados através de estatísticas, são relacionados ao desgaste da ferramenta. Desta forma, a utilização de algoritmos de Inteligência Computacional são amplamente utilizados, tendo como informações de entrada, os dados dos sensores. As técnicas mais comuns de Inteligência Computacional são: redes neurais artificiais, modelos neuro-fuzzy, lógica fuzzy e redes Bayesian. O objetivo principal é treinar um sistema para aprender, através de um comportamento passado, e utilizar o aprendizado para tomar decisões durante a vida da ferramenta (DROUILLET *et al*., 2016).

A RNA (rede neural artificial) pode ser útil para diversos objetivos, como classificação de padrões e aproximação de funções, podendo ser utilizada para estimação e predição de valores físicos. Isto ocorre, pois, este tipo de Inteligência Computacional possui qualidades únicas, como não-linearidade, aprendizado adaptativo e capacidade de generalização. Portanto, as RNAs são muito utilizadas em pesquisas que envolvem o monitoramento da condição da ferramenta, podendo, por exemplo, classificar condições de peças como queimado ou sem queima após a retificação, estimar o desgaste de rebolos ou de dressadores, realizar a predição dos valores estimados, entre outros.

## 1.2 OBJETIVOS

O objetivo deste trabalho é propor uma metodologia eficaz para a predição da largura de atuação do dressador ($b_d$) durante o processo da dressagem, sem que, para isso, seja necessário interrompê-lo. Sabe-se que, durante o processo de dressagem, a ferramenta “dressador” se desgasta devido ao atrito que ocorre com o rebolo. Desta forma, o valor da largura de atuação do dressador, que é um importante parâmetro na dressagem, aumenta significativamente. Além de determinar a agressividade que é gerada na superfície do rebolo, a largura de atuação do dressador fornece informações a respeito de sua vida útil. Através dela, é possível determinar o momento em que o dressador deve ser substituído.

Para predizer a largura útil do dressador, deve-se, primeiro, estimá-lo. Para a estimação, os sinais de emissão acústica são processados utilizando diferentes estatísticas. Desta forma, utilizando redes neurais artificiais, os sinais são relacionados com os valores da largura de atuação do dressador obtidos a partir das imagens capturadas. O valor da largura de atuação estimada (saída da primeira rede) será utilizado como entrada para uma rede de predição com atraso por tempo, a fim de obter o valor um passo à frente.

Assim, a presente pesquisa teve como objetivo principal examinar o potencial das redes neurais artificiais para a predição deste parâmetro no processo da dressagem, a fim de informar ao sistema de maneira *online* o momento em que o processo deve ser interrompido.

## 1.3 JUSTIFICATIVA PARA A REALIZAÇÃO DO TRABALHO

Com a crescente exigência das indústrias em melhorar a qualidade de seus produtos, reduzir custos e aumentar a produtividade, o monitoramento dos sistemas se torna obrigatório visando a automatização das máquinas. Especificamente, no processo da dressagem, o monitoramento do desgaste da ferramenta permite diminuir a interferência humana no processo, acabar com tempos de paradas para verificação da condição da ferramenta e evitar a utilização excessiva ou insuficiente da vida útil do dressador. Muitas vezes, o dressador é descartado precocemente, antes de

alcançar o final de sua vida útil, quando ainda existe diamante que poderia ser utilizado, ou é utilizado após o final de sua vida útil, fazendo com que o corpo do dressador entre em contato com o rebolo, causando faiscamento e podendo danificar o rebolo. Isto acontece, pois a avaliação da ferramenta é feita de maneira empírica pelos operadores, dependendo de sua sensibilidade e seus sentidos.

Por isso, um sistema capaz de predizer um passo à frente a largura útil do dressador, evitaria uma má utilização da ferramenta, permitindo que ela seja descartada no momento certo. Desta forma, extingue-se a avaliação subjetiva humana da análise e padroniza-se a utilização da ferramenta através de uma metodologia comprovadamente eficiente. Assim, com a utilização de sensores e um sistema computacional, é possível melhorar a produtividade no processo da dressagem e reduzir os custos com o melhor aproveitamento da ferramenta e evitando falhas.

# 2 REVISÃO BIBLIOGRÁFICA

## 2.1 O PROCESSO DA RETIFICAÇÃO

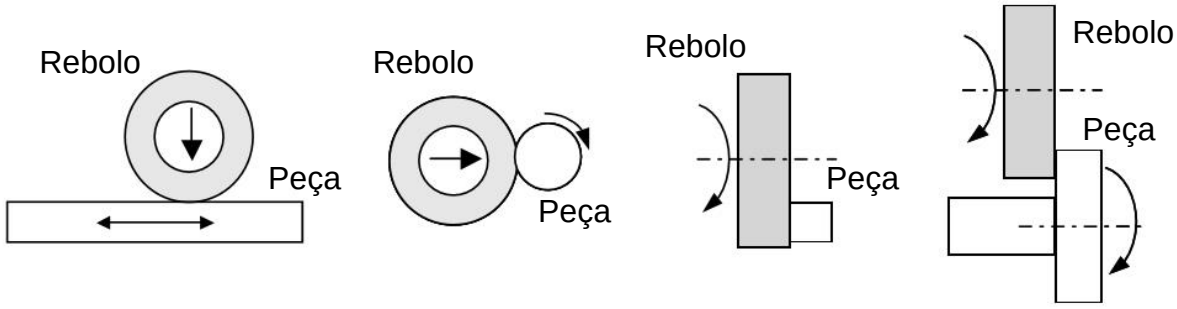
A retificação é amplamente utilizada nas indústrias que realizam operações de usinagem, pois permite obter um processo com alta qualidade e alta precisão superficial das peças. O processo da retificação consiste em uma integração aleatória de deslizamento, fricção e corte pelos inúmeros grãos abrasivos dispostos de forma irregular sobre o rebolo com a peça a ser retificada (WANG *et al*., 2016).

Através do processo da retificação, é possível alcançar uma alta precisão dimensional e geométrica das peças, assim como obter uma alta taxa de remoção de material. Desta forma, ela também pode ser aplicada para a manufatura de corte de materiais duros e ultraduros (AKBARI *et al*., 2016). No entanto, este processo é um dos mais complexos da cadeia de manufatura, pois é influenciado por diversos fatores, como o rebolo, a peça, a máquina e os ajustes dos parâmetros (TUAN; LEE, 2008). Por ser uma das últimas etapas da cadeia de produção, a retificação não tolera falhas, pois as peças já possuem um alto valor agregado. Por isso, a fim de assegurar que o processo apresente os resultados desejados, é necessário que sua dinâmica seja estudada com profundidade, além de uma alta capacitação dos operadores (DURGUMAHANTI; SINGH; RAO, 2010).

Outro fator que impacta fortemente na qualidade da retificação é a temperatura. Por isso, um bom sistema de resfriamento durante o processo utilizando fluidos de corte, como o MQL (*minimum quantity lubrication*) , é imprescindível para garantir melhores resultados na superfície da peça, reduzindo sua rugosidade e evitando uma eventual queima gerada pelas altas temperaturas provenientes do atrito entre o rebolo e a peça (KUMAR *et al.*, 2016; SARIKAYA *et al*., 2014). Segundo MALKIN e GUO (2007), se a temperatura se elevar acima de um determinado limite definido, danos térmicos podem ser ocasionados à peça usinada, como queima, transformações de fase, aumento ou diminuição da dureza, tensão residual de tração e trincas. As principais finalidades para se utilizar um fluido de corte são para resfriamento, expelir o cavaco, minimizar a corrosão, limpar o rebolo e lubrificação mecânica-química (MOLAIE *et al*., 2016).

As quatro operações básicas utilizadas com mais frequência estão apresentadas na Figura 2-1. Elas são classificadas de acordo com a superfície do rebolo que está em contato com a peça e com o avanço do rebolo. De acordo com MARINESCU *et al*., (2007), retificações do tipo plana geralmente se referem a superfícies com um movimento linear. Já as retificações cilíndricas se referem a peças que também rotacionam, sendo que a retificação pode acontecer em sua parte interna ou externa.

Figura 2-1 – Exemplo de quatro operações básicas de retificação.



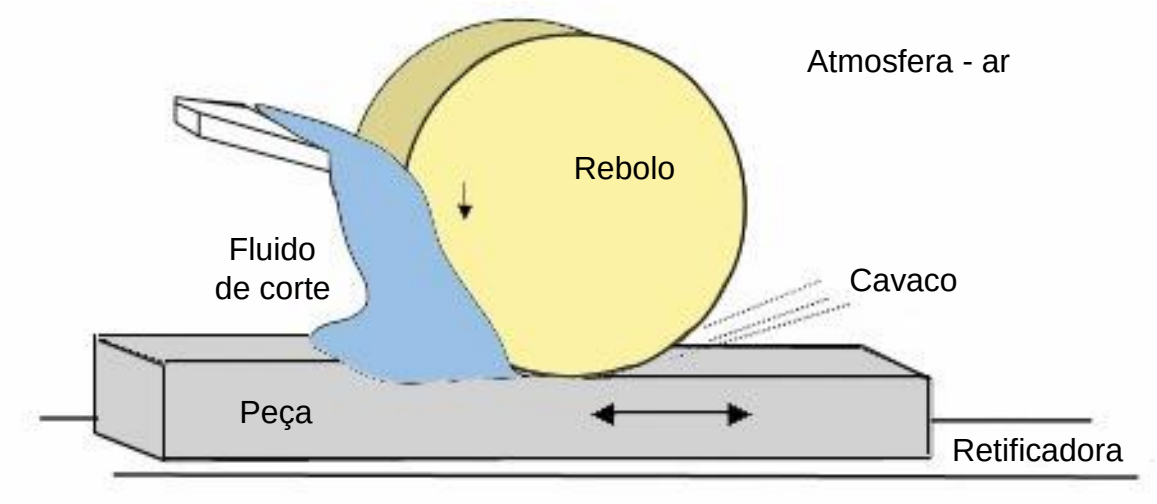

(a) Retificação tangencial plana | (b) Retificação tangencial cilíndrica | (c) Retificação lateral plana | (d) Retificação lateral cilíndrica

Fonte: Adaptado de MARINESCU *et al*. (2007).

### 2.1.1 A RETIFICAÇÃO TANGENCIAL PLANA

A retificação tangencial plana consiste na interação de seis elementos básicos: máquina retificadora, rebolo, peça a ser retificada, fluido de corte, atmosfera e cavaco gerado, conforme é apresentado na Figura 2-2. O cavaco é produzido a partir da mistura entre o material da peça, fluido de corte e partículas dos grãos abrasivos do rebolo, devendo ser descartado ou reciclado (MARINESCU *et al*., 2007).

Figura 2-2 – Os seis elementos básicos envolvidos na retificação tangencial plana.




Fonte: Adaptado de Marinescu et al. (2007).

A retificação plana promove uma interação entre o rebolo e a peça que depende dos seguintes parâmetros de entrada: taxa de remoção do material, velocidade de corte do rebolo e da peça e tempo de centelhamento (*spark out*) (KING e HAHN, 1992). Outra variável que também influencia na retificação é a agressividade do rebolo.

#### 2.1.1.1 COMPORTAMENTO DA PROFUNDIDADE DE CORTE (*a*)

A profundidade de corte (*a*) é definida pela penetração do rebolo na peça que está sendo usinada. Ela representa a espessura de material da peça que é removida a cada passagem do rebolo sobre a mesma (MARINESCU *et al*., 2007). A profundidade de corte é medida em micrometro [µm], em uma direção perpendicular ao avanço do rebolo ou da peça (DINIZ, MARCONDES e COPPINI, 2010). Quando a profundidade de corte é muito elevada, as forças de corte aumentam, podendo causar deformações entre o rebolo e a peça e prejudicando o acabamento das peças retificadas (LINKE, 2008).

### 2.1.1.2 COMPORTAMENTO DA VELOCIDADE DE CORTE ($v_s$)

A velocidade de corte na retificação, também denominada velocidade periférica do rebolo, é determinada pelo deslocamento de um ponto sobre a superfície de corte do rebolo por uma variação de tempo. Esta velocidade implica diretamente na vida do rebolo, pois ela altera a capacidade de remoção dos grãos abrasivos e no acabamento das peças (MALKIN e GUO, 2008).

De acordo com GRAF (2004), a velocidade do rebolo ($v_s$) pode ser expressa por:

$$v_s = \frac{\pi . d_s . n_s}{60000} \ [m/s] \quad (1)$$

Sendo:

$d_s$: diâmetro externo do rebolo, em [mm];

$n_s$: rotação do rebolo, em [rpm].

Quando a velocidade de corte é elevada, um mesmo grão abrasivo passa a remover um menor volume de cavaco, pelo aumento da sua freqüência de contato com a peça. Portanto, o número de grãos ativos é maior e a espessura do cavaco removido é menor, diminuindo as forças de corte, rugosidade da peça e desgaste do rebolo, pela menor solicitação de cada grão. Em contrapartida, pelo aumento da intensidade de contato dos grãos com a peça, ocorre uma elevação da temperatura que pode ocasionar um dano térmico na peça (BIANCHI *et al*., 1996).

### 2.1.1.3 COMPORTAMENTO DA VELOCIDADE DA PEÇA ($v_w$)

A velocidade da peça ($v_w$) é a mesma que a velocidade da mesa na retificação plana e normalmente é expressa em metros por minuto [m/min] (MARINESCU *et al*., 2007). Ela está relacionada aos impactos que os grãos abrasivos provocam na peça.

Quando a velocidade da peça é baixa e a penetração é grande, os impactos dos grãos abrasivos do rebolo sobre a peça são pequenos e os cavacos são

alongados. O tempo de contato grão/peça e o número de grãos ativos são maiores. Assim, a força em um grão abrasivo é pequena e atua durante um tempo longo. Os grãos abrasivos tendem a permanecer mais tempo em contato com a peça, o que provoca um desgaste maior. As forças de corte tendem a aumentar com o tempo de retificação, pelo desgaste das arestas cortantes. Com isto, o desgaste do rebolo tende a ser menor, considerando-se que os grãos abrasivos permanecem mais tempo presos ao ligante, o que minimiza a perda de grãos.

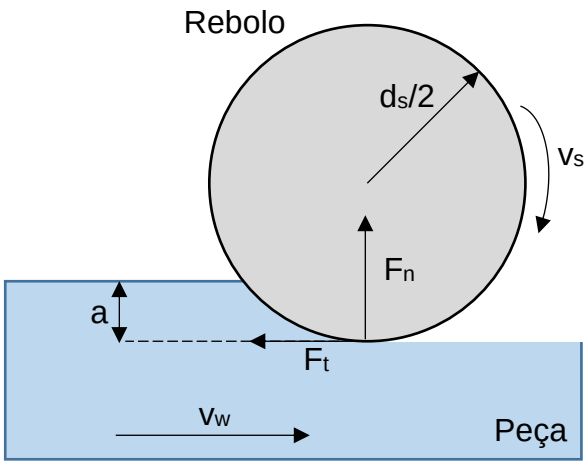
Quando a velocidade da peça é alta e a penetração do rebolo é pequena, os impactos dos grãos abrasivos do rebolo sobre a peça são grandes e os cavacos são curtos. O tempo de contato grão/peça e o número de grãos ativos são menores, gerando uma força por grão abrasivo grande e por pouco tempo. Os grãos tendem a se fraturar e a se desprender da superfície de corte do rebolo. Neste caso, as forças totais de corte tendem a uma estabilização pela troca constante de grãos abrasivos. O desgaste do rebolo tende a ser maior que no caso anterior (MALKIN e GUO, 2008).

### 2.1.2 FORÇAS DE CORTE NO PROCESSO DA RETIFICAÇÃO

Os esforços de corte no processo de retificação são gerados entre a interação do abrasivo e a peça em forma de deformação plástica e elástica, pela formação do cavaco e pelo atrito entre abrasivo, ligante e peça (REN, ZHANG e ZHOU, 2009).

Geralmente, essa força é decomposta em três componentes: normal (*Fn*) [N]; tangencial (*Ft*) [N]; e uma componente ao longo da direção de avanço longitudinal (axial - *Fa*) [N], que não possui muita relevância. A força tangencial afeta principalmente o consumo de energia e o tempo de vida de serviço do rebolo, assim afeta também na temperatura e rugosidade da peça usinada. As forças de corte na retificação plana são apresentadas na Figura 2-3.

Figura 2-3 – Forças de corte para a retificação tangencial plana.




Fonte: Adaptado de MALKIN e GUO (2008).

A força normal atual perpendicularmente à superfície do rebolo e depende da dureza do grão abrasivo e do material a ser usinado. Esta é maior que a tangencial e age diretamente na redução da profundidade de corte, sendo também responsável por deflexões da peça, rebolo e estrutura da máquina. A componente axial só ganhará importância quando houver certo deslocamento lateral do rebolo (MARINESCU, 2004).

### 2.1.3 O REBOLO

O rebolo é a ferramenta de revolução utilizada nos processos de retificação. O corpo abrasivo do rebolo é composto por grãos abrasivos unidos por um ligante. Esses grãos são responsáveis pela remoção de material através de suas arestas de corte de geometria indefinida. Pode-se considerar o rebolo como um sistema trifásico, sendo constituído por grãos abrasivos, aglomerante e poros. Desse modo, seu desempenho está relacionado ao tipo e tamanho do grão abrasivo, as propriedades abrasivas do material e porosidade do conjunto (MALKIN e GUO, 2008).

Além disso, o desempenho das peças retificados depende da excentricidade do rebolo. Os efeitos da excentricidade foram estudados por BADGER, MURPHY *et al*., (2011). Em seu trabalho, os autores afirmam que a excentricidade do

rebolo influencia diretamente nas forças de corte, podendo resultar na queima da peça.

As principais características que definem o tipo de um rebolo são: tipo do abrasivo; ligante; dureza; granulometria e estrutura (STEMMER, 1992). No presente trabalho, foram utilizados rebolos convencionais de óxido de alumínio com ligante vitrificado, dureza média e granulometria muito fina.

#### 2.1.3.1 OS GRÃOS ABRASIVOS

Os grãos abrasivos usados nas operações de retificação são partículas refratárias duras e frágeis que podem ser classificadas de acordo com sua dureza ou composição química (LIAO, 2007). A propriedade mais importante de um abrasivo é que este seja mais duro que o material a ser retificado. Casualmente define-se essa dureza em termos resistência e endentação estática, obtidos através de um teste de dureza Knoop (MALKIN e GUO, 2008).

Diferentemente de outros processos de usinagem, os quais utilizam ferramentas com geometrias definidas, os grãos abrasivos presentes no rebolo de retificação possuem bordas de corte irregulares (BARROS *et al*., 2014).

A avalição e escolha de certo abrasivo tomam por base a sua friabilidade. Essa característica pode ser definida como a tendência da desintegração do grão em pequenos fragmentos quando sob pressão. Essa tendência deve-se à forma, à integridade e à pureza do cristal que forma o grão abrasivo (MARINESCU, 2004).

Os grãos abrasivos podem ser classificados em dois grupos distintos, os grãos naturais e os grãos artificiais, pode-se ainda subdividir estes em mais dois grupos, os abrasivos convencionais e os superabrasivos (SALMON, 1992).

#### 2.1.3.2 LIGANTES

Os ligantes são responsáveis por unir os grãos abrasivos em uma ferramenta abrasiva (SALMON, 1992). Tendo como principais funções: reter o grão

durante o processo de usinagem; desgastar-se numa taxa controlada; resistir à força centrífuga em altas velocidades; e a de rapidamente expor o grão ao trabalho (WEBSTER, 2007). Os principais ligantes utilizados são os resinoides, os vitrificados e os metálicos. O uso correto do ligante durante a fabricação dos rebolos tem como objetivo tornar a distribuição dos grãos sobe o rebolo o mais uniforme possível, prejudicando da menor forma possível o processo de retificação (HEINZEL e RICKENS, 2009).

#### 2.1.3.3 DUREZA

A dureza de um rebolo está relacionada com a força com que o ligante retém o grão abrasivo na sua posição sob as forças de retificação. É determinada pela quantidade de ligante misturado com os grãos abrasivos (SALMON, 1992). Essa dureza é diretamente dependente das propriedades mecânicas do ligante, pois se este possuir uma resistência mecânica elevada, a possibilidade de ruptura dos grãos abrasivos será reduzida, isto devido a uma acomodação dos impactos sofridos pelo rebolo. Além disso, uma resistência elevada ao desgaste do material ligante dificulta a remoção de grãos inteiros, já que a ancoragem dos grãos se mantém estável durante toda a vida do rebolo (KING e HAHN, 1992).

#### 2.1.3.4 GRANULOMETRIA

Para rebolos convencionais, o tamanho do grão abrasivo é classificado através do método de peneiramento, sendo designado pelo número que corresponde à divisão linear da área de uma polegada quadrada. Assim, quanto mais fino o grão, maior será o seu número na escala da granulometria (MALKIN e GUO, 2008). O tamanho do grão influencia a taxa de remoção e o acabamento obtido na retificação. Os grãos classificados como grossos são usados comumente para operações grosseiras. Sendo aplicados geralmente na usinagem de materiais moles, dúcteis ou fibrosos (DINIZ, MARCONDES, and COPPINI 2010). A utilização de grãos mais

grossos permite uma maior taxa de remoção de material enquanto que grãos mais finos produz um acabamento melhor (MALKIN e GUO, 2008).

#### 2.1.3.5 ESTRUTURA

Uma propriedade adicional aos rebolos é sua estrutura: densidade de grãos e porosidade. Caso seja feita uma mistura de grãos muito finos com uma quantidade grande de ligante sob elevada pressão, resulta em baixa porosidade. Entretanto, se for utilizado grãos grossos, o resultado será uma estrutura mais aberta e, consequentemente, mais porosa. Para induzir a porosidade no rebolo, podem ser usados elementos voláteis durante o estágio verde, antes do forno (SALMON, 1992). A porosidade pode ser descrita como a medida de espaçamento entre os grãos abrasivos. Corresponde a um efeito local na estrutura do rebolo que faz com que haja fluxo de fluido e acomodação do cavaco (WEBSTER, 2007).

## 2.2 O PROCESSO DA DRESSAGEM

Idealmente, as partículas abrasivas da superfície de corte do rebolo deveriam ser afiadas automaticamente conforme o rebolo é desgastado, já que, a partir do desprendimento integral ou fratura dessas partículas abrasivas, há exposição de novas partículas com arestas de corte afiadas. Contudo, na prática tanto a geometria como as características funcionais do rebolo devem ser restauradas periodicamente através da operação de dressagem. Dressagem consiste em uma operação de afiamento concebida para gerar uma topografia particular na superfície de corte do rebolo (JACKSON, 2007).

Entender a operação de dressagem é um fator crítico para a obtenção de ótimo processo de retificação (MARINESCU *et al*., 2007). Inicialmente a topografia e forma macroscópica do rebolo são geradas pela preparação do mesmo por meio da dressagem (MALKIN e GUO, 2008).

A dressagem - do inglês *dressing* - é o processo conjunto entre perfilar e afiar o rebolo. No afiamento do rebolo ocorre a remoção do ligante entre os grãos

abrasivos. Assim, a dressagem tem como objetivo restaurar a eficiência de corte da ferramenta (MARINESCU *et al*., 2007).

### 2.2.1 DRESSAGEM E TOPOGRAFIA

Segundo (LIN, LIU e HUAN, 2008), a topografia do rebolo é caracterizada pelo número de arestas de corte, de modo que essa topografia tem influência sobre a geometria do cavaco produzido e no processo de retificação como um todo. Pode-se então considerar que o processo de retificação engloba tanto a dressagem como a própria retificação. Do ponto de vista de remoção do material, as propriedades estáticas mais importantes da topografia do rebolo são os parâmetros relacionados à aresta de corte e sua distribuição. Tais parâmetros são a afiação, a largura e densidade de arestas. Sendo a largura e a densidade, relacionadas ao número de arestas de corte ativas por unidade de área da superfície de corte do rebolo. O número de arestas ativas depende das condições impostas de dressagem. E a superfície de corte do rebolo é gerada pela fratura do grão ou do ligante (SALEH, BISHWAS e RAHMAN, 2009).

### 2.2.2 DRESSADOR DE PONTA ÚNICA

O dressador de ponta única é a ferramenta de dressagem mais simples, sendo largamente utilizado nas operações de dressagem (SALMON, 1992), (MARINESCU, *et al*., 2007). A operação de dressagem realizada com um dressador de ponta única também é conhecida por dressagem mecânica (HARIMKAR, 2006).

O dressador de ponta única carrega um único diamante, que deve formar um ângulo de ataque em relação ao rebolo para que o processo de dressagem seja eficiente. Se o diamante estiver perpendicular ao rebolo durante a dressagem, ele será gasto rapidamente. Se o ângulo do diamante for igual ao da superfície do rebolo a região de contato irá gerar muito calor, podendo danificar o diamante (SALMON, 1992). O dressador de ponta única é usualmente instalado com um ângulo relativo entre a ferramenta e o rebolo de $\alpha_d$ entre 10º e 15º (MALKIN e GUO, 2008).

Segundo (MALKIN e GUO, 2008), a operação de dressagem de ponta única produz dois efeitos na superfície do rebolo, o macro e o micro efeito, que são definidos como:

- Macro efeito: gerado a partir do formato do dressador, da profundidade de penetração do dressador e do passo de dressagem. Este fenômeno determina a posição das novas arestas dos grãos abrasivos na superfície do rebolo;
- Micro efeito: gerado pelo arrancamento dos grãos gastos, isso é com baixa ancoragem ao ligante, e pela fratura dos grãos que não se desgastaram por completo, onde novas arestas de corte são geradas.

Na operação de dressagem de rebolos convencionais, é usual que o dressador passe pelo rebolo rotacionado, como ilustrado na Figura 2-4. Durante cada passada do dressador através do rebolo, é removida uma profundidade $a_d$ do raio do rebolo. Esse tipo de movimento de dressagem é análogo ao de torneamento. O avanço axial do dressador por revolução é chamado de passo de dressagem, $s_d$, e é dado pela Equação 2.

$$s_d = \frac{\pi . d_s . v_d}{v_s} \ [mm] \tag{2}$$

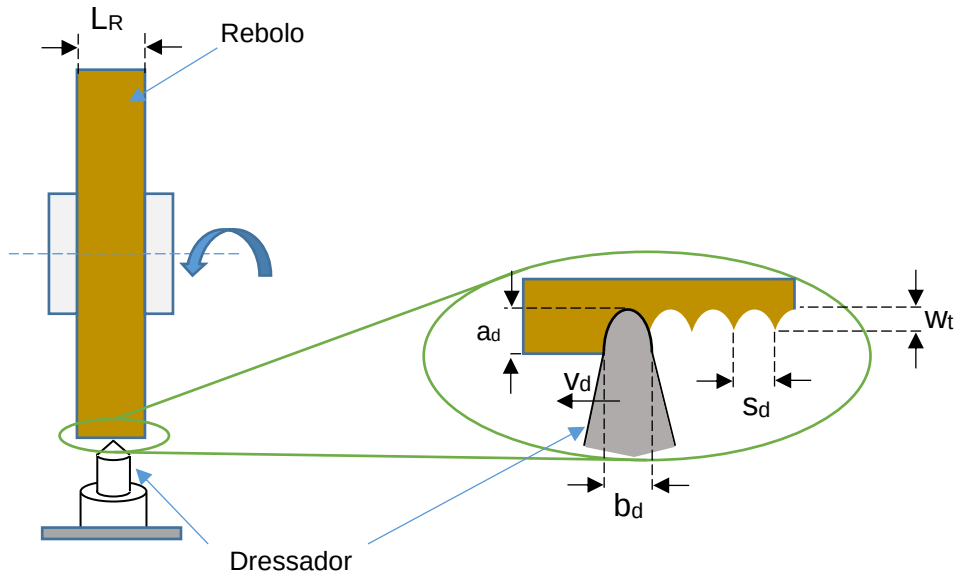
Sendo:

$d_s$: diâmetro externo do rebolo, em [mm];

$v_d$: velocidade de dressagem, em [mm/s];

$v_s$: velocidade de corte do rebolo [mm/s].

Figura 2-4 – Representação esquemática do processo de dressagem.




Fonte: Adaptado de OLIVEIRA e BIANCHI (1992).

### 2.2.3 GRAU DE RECOBRIMENTO DO REBOLO ($U_d$).

O grau de recobrimento de dressagem ($U_d$) é um parâmetro de dressagem de extrema importância que foi criado por (KONIG e KLOCKE, 1980) e que tem como objetivo relacionar os parâmetros de dressagem e a topografia do rebolo gerada na operação. A definição do grau de recobrimento na dressagem com dressador de ponta única é a de determinar quantas vezes um ponto da superfície do rebolo é recoberto pela largura útil do dressador ($b_d$) pelo passo de dressagem ($s_d$) (MALKIN e GUO, 2008). A Equação 3 relaciona as três grandezas.

$$U_d = \frac{b_d}{s_d} \tag{3}$$

Sendo:

$b_d$: largura útil do dressador, em [mm];

$s_d$: passo de dressagem, em [mm].

Outro parâmetro importante é o tempo de contato entre o rebolo e o dressador ($t_d$) , que é apresentado na Equação 4.

$$t_d = \frac{L_R . U_d . 60}{n . b_d} \ [s] \tag{4}$$

Sendo:

$L_R$: largura do rebolo, em [mm];

$U_d$: grau de recobrimento do rebolo;

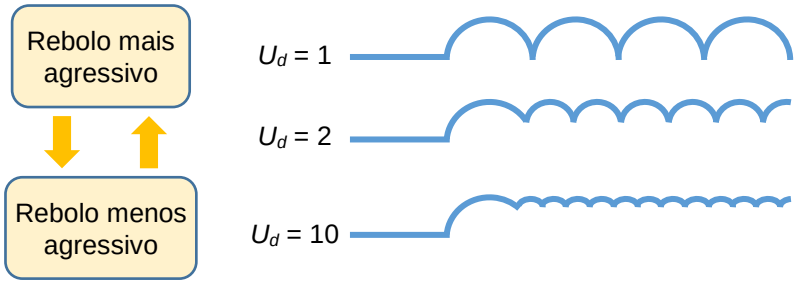
$n_s$: velocidade de rotação do rebolo, em [rpm];

### 2.2.4 AGRESSIVIDADE DO REBOLO

Normalmente, no processo da retificação, o rebolo deve ser preparado com uma agressividade específica, de acordo com a peça que será retificada. Um rebolo mais agressivo possui uma superfície formada por arestas maiores provenientes do macro efeito da dressagem, e por grãos abrasivos mais afiados, provenientes do micro efeito da dressagem (MOIA *et al*., 2015).

Devido ao macro efeito, quando o grau de recobrimento é igual a 1, o valor de $b_d$ é igual ao de $s_d$ (Equação 3). Isto demonstra que a aresta gerada pela ponta do dressador está no mesmo nível da superfície do rebolo, ou seja, o rebolo possui uma alta agressividade. À medida que o grau de recobrimento aumenta, a largura de atuação torna-se maior do que o passo de dressagem, gerando uma superfície com arestas menores no rebolo e, consequentemente, o rebolo torna-se menos afiado, como demonstra a Figura 2-5 .

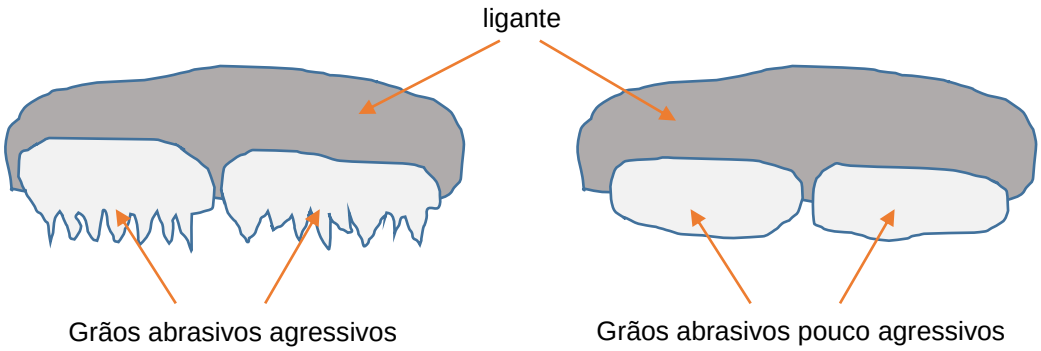
Figura 2-5 – Agressividade do rebolo em função de seu grau de recobrimento.




Fonte: Adaptado de HASSUI e DINIZ (2003).

O micro efeito da dressagem também influencia diretamente na agressividade produzida no rebolo. Quando este efeito é alto, o rebolo possui uma grande quantidade de grãos abrasivos com arestas expostas (afiadas). Assim, o processo de formação de arestas torna-se mais eficiente e com menores perdas devido à deformação plástica e elástica da peça em torno da zona de corte (HASSUI e DINIZ, 2003). A Figura 2-6 ilustra o micro efeito para grãos abrasivos agressivos e com pouca agressividade, respectivamente.

Figura 2-6 – Reprentação do micro efeito nos grãos abrasivos.




Fonte: Adaptado de WEGENER *et al*. (2011).

## 2.3 MONITORAMENTO DO PROCESSO DE USINAGEM

A fim de atender as demandas da indústria atual para uma alta precisão e produtividade das peças fabricadas, a otimização dos processos da retificação e dressagem se tornou uma tarefa cada vez mais importante. No entanto, a otimização desses processos é ainda o maior desafio das indústrias de usinagem (AGARWAL, 2016).

O desenvolvimento de um sistema de monitoração e controle em tempo real é de fundamental importância para se obter automação dos processos de usinagem. De modo que se tenha um processo capaz de estabelecer o momento da troca de uma ferramenta, realizar a troca e realizar mudanças nos parâmetros de operação visando a otimização do processo (AGUIAR *et al*., 2009).

A tecnologia de emissão acústica (EA) tem avançado significativamente sendo amplamente investigada como um método não destrutivo para o monitoramento de processos de usinagem. A emissão acústica é definida como a liberação de ondas oscilatórias emitidas por um material reagindo a um esforço. As emissões acústicas geradas durante os processos de usinagem são relacionadas com o estado do processo e condições da ferramenta e peça (WANG, 2005).

Através de uma série de experimentos, XUE *et al*. (2002) confirmaram que a emissão acústica é um mecanismo eficiente no monitoramento da dressagem tanto quanto para o processo de retificação. Embora existam vários estudos sobre dressagem e sua influência nas variáveis de saída do processo de retificação, a maioria dos trabalhos analisa este ponto de forma qualitativa.

O processo de dressagem pode ser monitorado para produzir uma qualidade constante na superfície do rebolo. A partir do monitoramento das amplitudes e frequências características do sinal de EA é possível definir a vida do rebolo (INASAKI e OKAMURA, 1985).

Segundo XUE *et al*. (2002), a ponta do dressador é um fator que afeta significativamente a rugosidade da peça quando comparado com outros parâmetros do processo de retificação, tais como profundidade de corte e velocidade da mesa. O monitoramento dos parâmetros de dressagem resulta em valores mais consistentes de rugosidade para a operação de retificação.

Erros de dressagem podem afetar diferentemente a qualidade da dressagem devido a flutuações da profundidade real de dressagem, desgaste do dressador e outros distúrbios. Um sistema de monitoramento pode detectar essas condições indesejáveis (XUE *et al.*, 2002).

## 2.4 EMISSÃO ACÚSTICA

Emissão acústica é a propagação de uma onda elástica na rede dos materiais cristalinos devido ao rearranjo da estrutura interna do material. Quando ocorre uma deformação no material (modificado por corte, atrito, trinca entre outros) acontece um desarranjo da estrutura do material que tende a se reestruturar. Nesse

momento são geradas ondas vibracionais que se deslocam a velocidade do som, daí o nome de emissão acústica. Estes sinais são captados por meio de um sensor que transforma os sinais mecânicos em sinais elétricos (WILLIAMS, 1978). Uma grande variedade de sensores de emissão acústica, especialmente os produzidos para o propósito de monitoramento, tem sido aplicados na indústria. Eles reúnem características importantes tais como: baixo custo, fácil montagem, resistência à influência externas, e são capazes de monitorar peças em rotação (MARINESCU *et al*., 2007).

## 2.5 PROCESSAMENTO DE SINAIS

O processamento de um sinal consiste em se aplicar transformações a um sinal analógico, ou digital, com o objetivo de eliminar ruídos e extrair características do sinal. Algumas operações comumente utilizadas no processamento de sinais são: ampliação, filtragem, transformações matemáticas, integração de sinais, conversão analógico para digital.

Pesquisadores como (KARPUSCHEWSKI, WEHMEIER e INASAKI, 2000), (INASAKI e OKAMURA, 1985), (KWAK, SEOB e HA, 2004), (LEE, 2006) entre outros, utilizaram técnicas de aquisição de dados e processamento de sinais em estudos relacionados ao monitoramento do processo de retificação.

### 2.5.1 VALOR EFICAZ DE UM SINAL (RMS)

O valor médio quadrático (do inglês, *Root Mean Square*) de um sinal puro discreto pode ser expresso pela Equação 5 (NILSSON e RIEDEL, 2003).

$$RMS = \sqrt{\frac{1}{N}\sum_{n=1}^{N} X^2(n)} \tag{5}$$

Sendo:

*N*: número discreto de dados do sinal *X*;

*X*: sinal puro discreto;

### 2.5.2 TAXA DE POTÊNCIA DE UM SINAL

A taxa de potência de um sinal (do inglês, *ratio of power*) observa o sinal quanto ao seu espectro de frequência (MIRANDA *et al*. 2015). Para cada bloco de sinal de EA o valor ROP é dado pela Equação 6.

$$ROP = \frac{\sum_{K=n_1}^{n_2} |X_K|^2}{\sum_{K=0}^{N-1} |X_K|^2} \quad (6)$$

Sendo:

*N*: tamanho do bloco do sinal;

$n_1$ e $n_2$: faixa de frequência para análise.

### *2.5.3 POWER LAW*

Em aplicações para a detecção de eventos transientes, uma estatística que tem obtido bons resultados é a power law Nuttall (WANG *et al*., 2001), obtido através da Equação 7.

$$T_{pl}(X) = \sum_{k=0}^{N-1} X_k^v \quad (7)$$

Sendo:

$X_k$: k-ésimo elemento do valor absoluto da transformada rápida de Fourier (FFT);

*N*: quantidade total de dados;

*v*: expoente com valor ajustável.

De acordo com (WANG *et al*., 2001), $v = 1$ e $v = \infty$ correspondem a um detector de energia e $\max\{x_k\}$, respectivamente. Para $2 < v < 3$, tem-se obtido um bom desempenho da estatística pra uma ampla faixa.

### 2.5.4 CFAR

Embora a estatística *power law* possua um bom desempenho para alguns modelos e seja de fácil implementação, ela necessita de dados pré-normalizados (WANG *et al*., 2001). Devido à flutuação do sinal de emissão acústica durante os processos de usinagem, a estatística CFAR (*constant false alarm rate*) pode ser utilizada de acordo com a Equação 8.

$$T_{cfar}(X) = \frac{\sum_{k=0}^{N-1} X_k^v}{(\sum_{k=0}^{N-1} X_k)^v} \quad (8)$$

Sendo que os parâmetros são os mesmos que os apresentados na estatística anterior. Os valores $T_{cfar}$ claramente não são afetados pela amplitude do sinal.

### 2.5.5 MVD

A estatística MVD (*mean value deviance)* tem se mostrado eficiente na detecção de transientes para algumas aplicações, incluindo a detecção de queima. (WANG *et al*., 2001). A Equação 9 apresenta o cálculo para

$$T_{mvd}(X) = \frac{1}{N} \sum_{k=0}^{N-1} \log \frac{\bar{X}}{X_k} \quad (9)$$

Sendo:

$X_k$: k-ésimo elemento do valor absoluto da transformada rápida de Fourier (FFT);

$N$: quantidade total de dados;

$\bar{X}$: valor médio de $\{X_k\}$.

### 2.5.6 TRANSFORMADA DISCRETA DE FOURIER

Uma das ferramentas mais poderosas encontrada na área de processamento digital de sinais é a transformada de discreta de Fourier. É um procedimento matemático usado para determinar o conteúdo harmônico ou de frequência de um sinal discreto no tempo. A DFT é calculada de acordo com a Equação 10.

$$X(m) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi nm/N} \qquad (10)$$

Sendo:

*X*: valor da DFT;

*m*: índice da componente de saída da DFT no domínio da frequência;

*x*: sequência de amostras do sinal discreto;

*n*: índice de amostras no domínio do tempo, n = 0, 1, 2, 3, ... , N-1;

$j = \sqrt{-1}$;

*N*: número de amostras.

Embora a DFT seja um dos procedimentos matemáticos mais diretos para determinar o conteúdo de frequência de um sinal discreto, ela é ineficaz devido à lentidão do processo. Uma forma eficiente de se calcular o conteúdo harmônico do sinal é utilizar a transformada rápida de Fourier (FFT) (YANG e CHEN, 2002).

### 2.5.7 MÉDIA E DESVIO PADRÃO

A média e o desvio padrão são comumente empregados para a determinação do valor médio e da dispersão de um sinal, respectivamente. (MORETTIN, 1999) Estas estatísticas descrevem a amplitude da distribuição, a simetria e a sua forma. A média é calculada a partir da Equação 11.

$$\bar{x} = \frac{\sum_{i=1}^{N} x_i}{N} \quad (11)$$

Sendo:

$\bar{x}$: valor médio dentro do intervalo;

*N*: quantidade de amostras;

$x_i$: valor da amostra *i*.

O desvio padrão normalmente é usado para indicar a variação em um conjunto de amostras. O desvio padrão de uma população de valores é definido pela Equação 12 (MORETTIN, 1999).

$$\sigma = \sqrt{\frac{\sum_{i=1}^{N}(x_i - \bar{x})^2}{N-1}} \quad (12)$$

Sendo:

σ: desvio padrão;

$\bar{x}$: valor médio dentro do intervalo;

*N*: quantidade de amostras;

$x_i$: valor da amostra *i*.

## 2.6 REDES NEURAIS ARTIFICIAIS

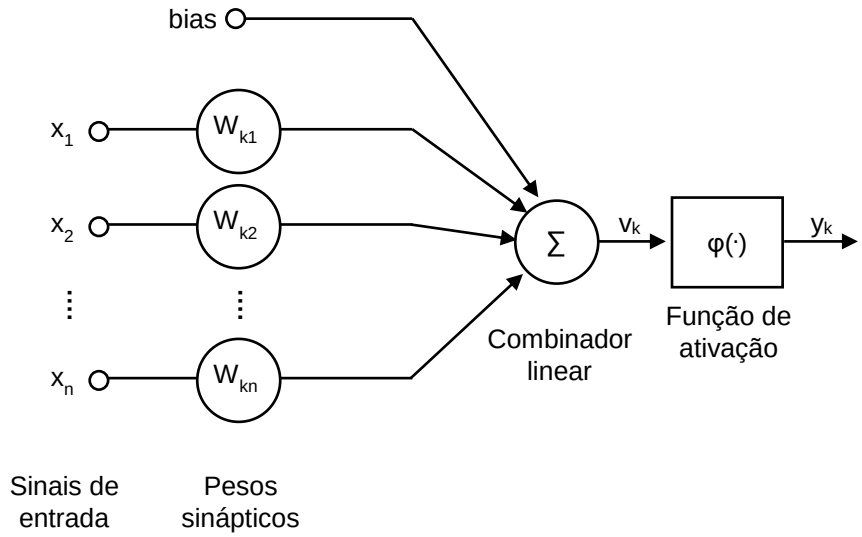
As redes neurais artificiais (RNAs) são uma maneira de criar modelos matemáticos, com capacidade de processar informações, inspirados em uma estrutura natural: o cérebro humano. Estes modelos foram inspirados em algumas operações conhecidas do cérebro, ou seja, apresentam capacidade de aprender, de tomar decisões, e de adaptar-se mesmo em presença de sinais ruidosos (HARTMANN, 2002). As características garantem à RNA a capacidade de aprender através de exemplos e então generalizar os padrões do conjunto de dados de treinamento, tornando possível a interpretação de outros padrões similares, mas não idênticos, aos utilizados durante o aprendizado.

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

Os componentes básicos da RNA são os neurônios e seus pesos. Estes pesos são ajustáveis e correspondem a sinapses biológicas. Um 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).

O princípio básico da RNA é baseado em um neurônio biológico. Ele recebe estímulos (sinapse) nas suas conexões de entrada (dendritos). Se as condições necessárias são satisfeitas, um sinal é emitido na saída (axônio) (NEGNEVITSKY, 2005). Na representação matemática do neurônio, o neurônio artificial, as entradas recebidas são multiplicadas por pesos sinápticos, que correspondem à força de determinada entrada para a emissão da saída e uma soma ponderada é calculada. O resultado dessa soma é comparado a um limite de ativação do neurônio (HAYKIN, 1999). A Figura 2-7 apresenta o modelo de um neurônio artificial.

Figura 2-7 – Modelo de um neurônio artificial.




Fonte: Adaptado de HAYKIN (1999).

Um neurônio artificial *k* pode ser descrito pelas Equações 13 e 14 (HAYKIN, 1999).

$$v_k = \sum_{i=1}^{n} w_{ki}.x_i \tag{13}$$

$$y_k = \varphi(v_k + b_k) \tag{14}$$

Sendo:

*n*: número de entradas;

$x_i$: sinais de entrada;

$w_i$: pesos sinápticos;

$v_k$: saída do combinador linear;

$b_k$: limiar de ativação

$\varphi$: função de ativação;

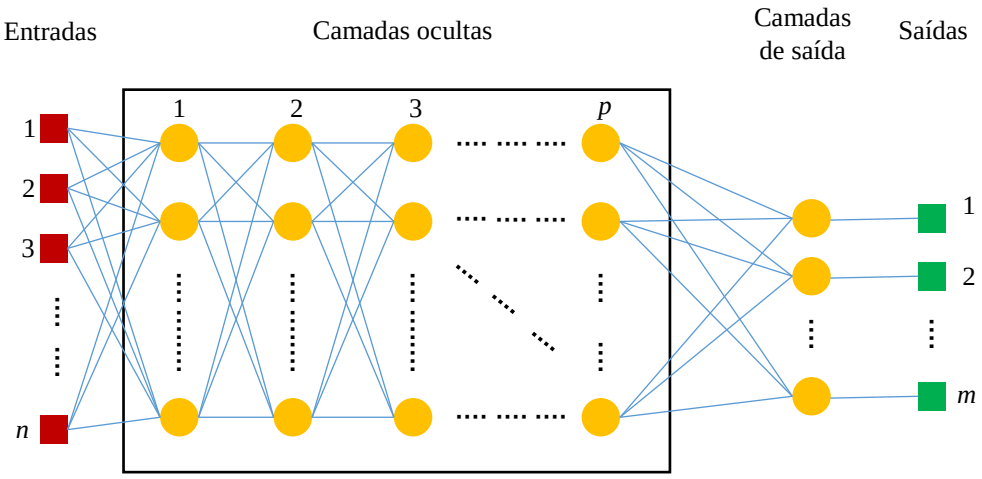
$y_k$: saída do neurônio.

### 2.6.1 REDE NEURAL PERCEPTRON DE MÚLTIPLAS CAMADAS

Atualmente, a rede *perceptron* de múltiplas camadas (MLP – *Multi-Layer Perceptron*), tem sido a arquitetura de RNA mais usada, sendo amplamente apresenta na maioria das literaturas sobre redes neurais. Redes MLP são redes alimentadas adiante (*feedforward*) que possuem uma ou mais camadas de neurônios entre as camadas de entrada e saída, estas camadas são denominadas de camada oculta. Esta camada oculta adiciona um poder maior a rede em relação às redes perceptron de camada única, que classifica apenas padrões linearmente separáveis, sendo os neurônios ocultos os responsáveis por capturar a não linearidade dos dados. Na rede MLP (*multi-layer perceptron* – perceptron de múltiplas camadas) os neurônios são conectados aos neurônios da camada subsequente, não havendo ligação entre os neurônios da mesma camada e também não ocorre realimentação (HAYKIN, 1999).

A Figura 2-8 ilustra uma rede *Perceptron* de Múltiplas Camadas com *n* entradas, *m* saídas e *p* camadas ocultas. Cada camada oculta pode ser formada por diferentes quantidades de neurônios.

Figura 2-8 – Rede Neural Perceptron de Múltiplas Camadas.




Adaptado de HAYKIN (1999).

### 2.6.1.1 ALGORITMO *BACKPROPAGATION*

O processo de aprendizagem da rede neural MLP é iterativo, conhecido como aprendizagem por experiência, cujos padrões de treinamento são apresentados à rede, e, com base nos erros obtidos, são realizados ajustes nos pesos sinápticos com o intuito de diminuir este erro para as próximas iterações. O algoritmo de treinamento comumente empregado é o de retropropagação de erro (*error backpropagation*), que é um algoritmo de 1ª ordem e, consequentemente, possui um processamento lento.

O algoritmo *backpropagation* é baseado na regra de aprendizagem por correção de erro, que consiste em dois passos. O primeiro passo, para frente, é chamado de propagação, os valores provindos dos neurônios de entrada são aplicados aos neurônios ocultos, e posteriormente, suas saídas são aplicadas como entradas aos neurônios da camada de saída, obtendo a resposta da rede. No segundo passo, para trás, ocorre o ajuste dos pesos sinápticos, por meio do cálculo do erro

obtido na camada de saída. O ajuste dos pesos é realizado de acordo com uma regra de correção (HAYKIN, 1999).

Uma das dificuldades do uso de RNAs consiste em identificar o melhor ponto de parada do treinamento, pois o erro de treinamento inicia com um valor alto, decresce rapidamente, e continua diminuindo mais lentamente, tendendo a atingir um mínimo local na superfície de erro. Assim, para se identificar o momento ideal de parar o processo de aprendizado, buscando obter a melhor generalização possível, é indicado utilizar a técnica da regra de parada antecipada, com base na validação cruzada. Esta técnica consiste em se validar o modelo obtido durante o treinamento, utilizando-se de um conjunto de dados diferentes dos usados no processa de aprendizado da rede (HAYKIN, 1999).

### 2.6.1.2 ALGORITMO DE TREINAMENTO LEVENBERG-MARQUARDT

O algoritmo de Levenberg-Marquardt foi criado como um método de otimização do algoritmo *backpropagation*. Ele consiste no método gradiente de 2ª ordem para a busca do mínimo de uma função multivariada expressa como a soma de quadrados de funções não lineares (LEVENBERG, 1944), (MARQUARDT, 1963).

Como comumente nas redes neurais, a função erro corresponde a uma soma de quadrados. Este algoritmo foi desenvolvido com o objetivo de acelerar o treinamento da rede neural utilizando métodos de segunda ordem sem o cálculo da matriz Hessiana. Por ser baseado no método dos mínimos quadrados para modelos não lineares, o método busca o menor erro levando em conta o local do ponto de análise. A direção de busca do método Levenberg-Marquardt é definida como a solução da Equação 15.

$$(J(x_k)^T J(x_k) + \eta_k I) p_k^{LM} = -J(x_k)^T r(x_k) \quad (15)$$

sendo $\eta_k$ um escalar não negativo. Pode-se notar na Equação 16 que, dado $\eta_k > 0$, existe $\Delta = \Delta(\eta_k) > 0$ tal que o vetor $p_k^{LM}$ é a solução do subproblema restrito.

$$\min_{p \in R^n} \frac{1}{2} \|J(x_k)p + r(x_k)\|_2^2 \quad (16)$$

Para que as condições sejam satisfeitas, deve-se:

$$\|p\|_2 \leq \Delta \tag{17}$$

Quando o método estiver distante do ponto mínimo de erro, o algoritmo tem um passo maior de atualização, e, quando o mesmo estiver próximo de um mínimo global do erro, o algoritmo diminui o passo para a convergência. Tal fato resulta em um ganho de tempo de processamento em relação ao algoritmo de *perceptron*, que utiliza métodos de aproximação de primeira ordem (MUÑOZ, 2009).

### 2.6.2 REDES TDNN

Redes neurais do tipo com Atraso no Tempo (TDNN – *Time Delay Neural Network*) são caracterizadas pela utilização de uma topologia especial, voltada ao reconhecimento de sub-padrões independentes dentro de um padrão de entrada contínuo (WAIBEL, *et al*., 1989).

A técnica TDNN (WAIBEL *et al*., 1989) é uma técnica que introduz atraso no tempo. As redes TDNN são alimentadas adiante, com múltiplas camadas, cujos elementos das camadas escondidas e da camada de saída são duplicados ao longo do tempo. A topologia de uma rede TDNN está embutida em uma rede PMC (*Perceptron* multicamadas), em que cada conexão é representada por um filtro de impulso de resposta com duração finita, conhecido como FIR (*Finite Duration Impulse Response*). Esse tipo de rede, conhecida como FIR MLP é treinada através da criação de uma rede estática equivalente. Essa rede é obtida desdobrando a FIR MLP no tempo. Desta forma, pode ser utilizado o algoritmo backpropagation padrão (BRAGA, LUDERMIR e CARVALHO, 2000). Utilizou-se a técnica de janelas de tempo como uma técnica TDNN, pois esta introduz atraso de tempo através da formatação dos dados de entrada (FERREIRA, 2004).

Pode-se, ainda, considerar uma rede neural TDNN, que, em essência, é uma arquitetura *feedforward*, na qual sua resposta no tempo *t* é baseada nas entradas no tempo (*t* – 1), (*t* – 2),. . . , (*t* – *n*). Assim, é considerado no treinamento da rede um histórico da sequência temporal dos dados.

Originalmente, as redes TDNN foram propostas para reconhecimento de som. Para o presente trabalho algumas considerações foram feitas, tais como:

1) A rede é composta por múltiplas camadas e conexões, e é focada em aprendizado não-linear;

2) A rede deve ser capaz de representar relacionamentos entre eventos em tempo;

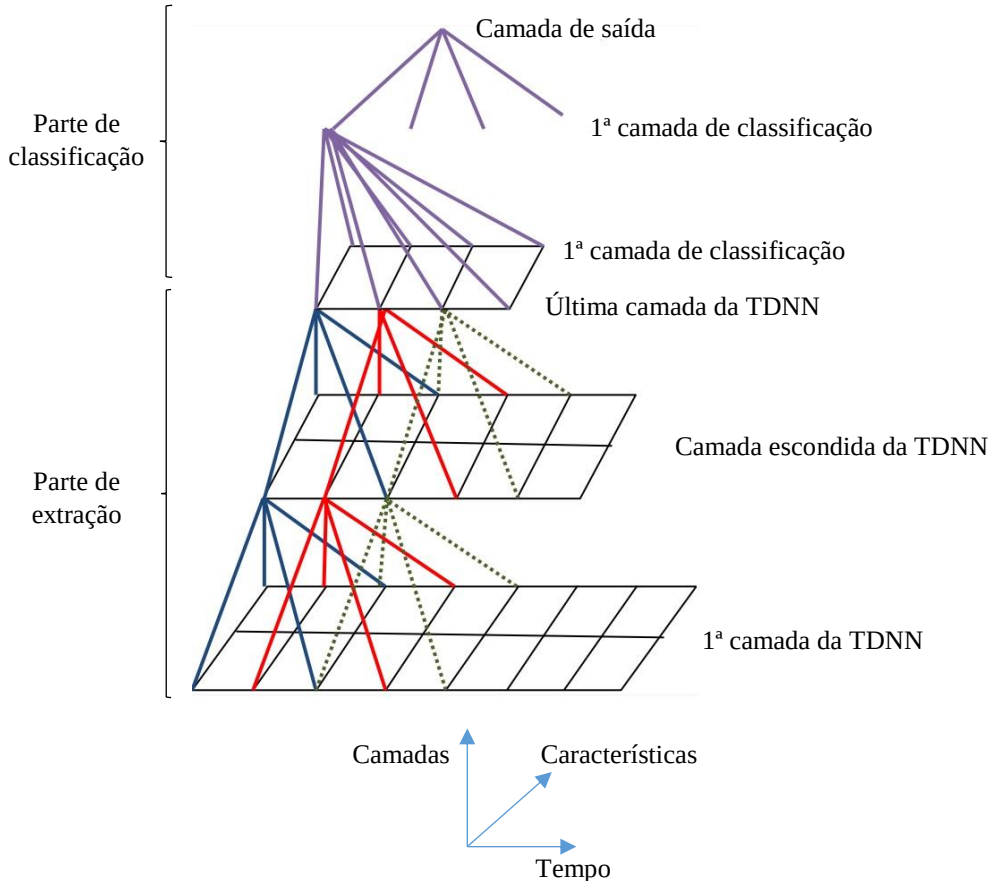
3) O número de pesos na rede deve ser suficientemente pequeno comparando com a quantidade de dados treinados. Dessa forma, a rede é forçada a codificar os dados observados, extraindo regularidades e comportamentos repetitivos.

Em redes neurais convencionais, um neurônio é responsável por calcular uma soma ponderada de todas as suas entradas e, após isso, propagá-la por meio de uma função não-linear (geralmente função de corte ou sigmóide) para as próximas unidades. Na rede TDNN, as entradas são modificadas para introduzir *n* atrasos à entrada de dados. Dessa maneira, uma camada de entrada composta por y elementos gera $z = y\ (n + 1)$ entradas para a rede. Dessa forma, a rede necessita de *z* pesos para *y* entradas. Enquanto em redes neurais convencionais cada neurônio geralmente conecta-se somente uma vez com outro da camada sucessora, no modelo TDNN são realizadas diversas conexões com pesos independentes. Antes do cálculo do peso de cada conexão, os dados sofrem um atraso que os elimina do cálculo da soma de pesos. Uma vez que cada conexão é associada a um comum atraso correspondente, as conexões atuam como o mecanismo de memória de curto prazo, possibilitando relatar e comparar o vetor de entrada atual aos dados observados anteriormente. As saídas de cada camada são computadas e utilizadas como valores de entrada para as camadas sucessoras, até chegar à camada de saída. Os valores de saída são comparados aos valores esperados, calculando o erro, que é propagado pela rede, atualizando os pesos e, consequentemente, decrementando o erro global. O procedimento é repetido até a rede convergir para a saída desejada. Dessa maneira, uma predição eficiente somente é possível após o treinamento repetitivo da rede (DODONOV e MELLO, 2008).

A Figura 2-9 apresenta a estrutura geral da rede TDNN. Ela mostra as duas partes principais desta rede: A parte de extração correspondendo às camadas

inferiores, as quais implementam as sucessivas convoluções para transformarem gradualmente as características do sinal (diversos valores baixos entre dois picos, por exemplo) em amplitudes mais significantes; e a parte de classificação, que corresponde à convencional rede MLP.

Figura 2-9 – Estrutura geral da TDNN.




Fonte: Adaptado de BENMAHDJOUB *et al*. (2013).

A TDNN é um tipo de rede de convolução. Ela possui uma janela deslizante que define um campo limitado de visão do sinal. Os valores desta janela podem ser utilizados para a predição dos próximos valores. É uma rede do tipo *feedforward*, em que a informação é propagada da entrada para a saída, sem realimentação, e os atrasos são aplicados na camada de entrada.

### 2.6.3 COEFICIENTE DE CORRELAÇÃO

De acordo com TETI *et al*., (2010), é possível encontrar as configurações que melhor caracterizam as condições de desgaste da ferramenta. Através do coeficiente de correlação de Pearson, é possível verificar a relação entre diferentes variáveis, como sinais provenientes de sensores com o desgaste das ferramentas (QUAN, ZHOU e LUO, 1998). O coeficiente de correlação ($\rho$) entre uma variável de entrada *x* e uma variável de saída *y* pode ser expresso por:

$$\rho = \frac{(\sum_i (x_i - \bar{x})(y_i - \bar{y}))^2}{\sum_i (x_i - \bar{x})^2 \sum_i (y_i - \bar{y})^2} \tag{18}$$

Sendo:

$\bar{x}$ e $\bar{y}$: valores médios de *x* e *y*, respectivamente.

O coeficiente de correlação é uma medida da força da dependência linear entre *x* e *y*. Quanto menor este coeficiente, menor a chance da variável de entrada apresentar qualquer tendência em relação à variável de saída. Por outro lado, quanto mais próximo de 1, maior é a dependência da variável de saída em relação à entrada.

# 3 MATERIAIS E MÉTODOS

Este capítulo aborda os equipamentos utilizados e a metodologia adotada na execução dos ensaios de dressagem, bem como a forma de configurar e implementar os modelos neurais.

Os ensaios de dressagem foram realizados no Laboratório de Usinagem por Abrasão (LUA) pertencente à Faculdade de Engenharia de Bauru, da Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP).

## 3.1 MONTAGEM DO BANCO DE ENSAIOS

Para a realização dos ensaios de dressagem foi utilizada uma máquina retificadora plana tangencial da marca Sulmecânica, modelo 1055E. Ela foi equipada com um rebolo de abrasivo convencional de óxido de alumínio da marca NORTON, modelo 38A220KVS, com ligante vitrificado, dureza L (média), granulometria de 150 (muito fina) e estrutura com dimensões 355,6 x 12,7 x 127 mm.

Foram utilizados três dressadores naturais piramidais modelo RP10 da marca Master Diamond, como exemplificado na Figura 3-1. A fixação do dressador à mesa retificadora foi realizada através de um suporte metálico com 15º de inclinação, cuja magnetização da mesa garantiu a posição inalterável do suporte. O suporte também serviu para a fixação do sensor de emissão acústica.

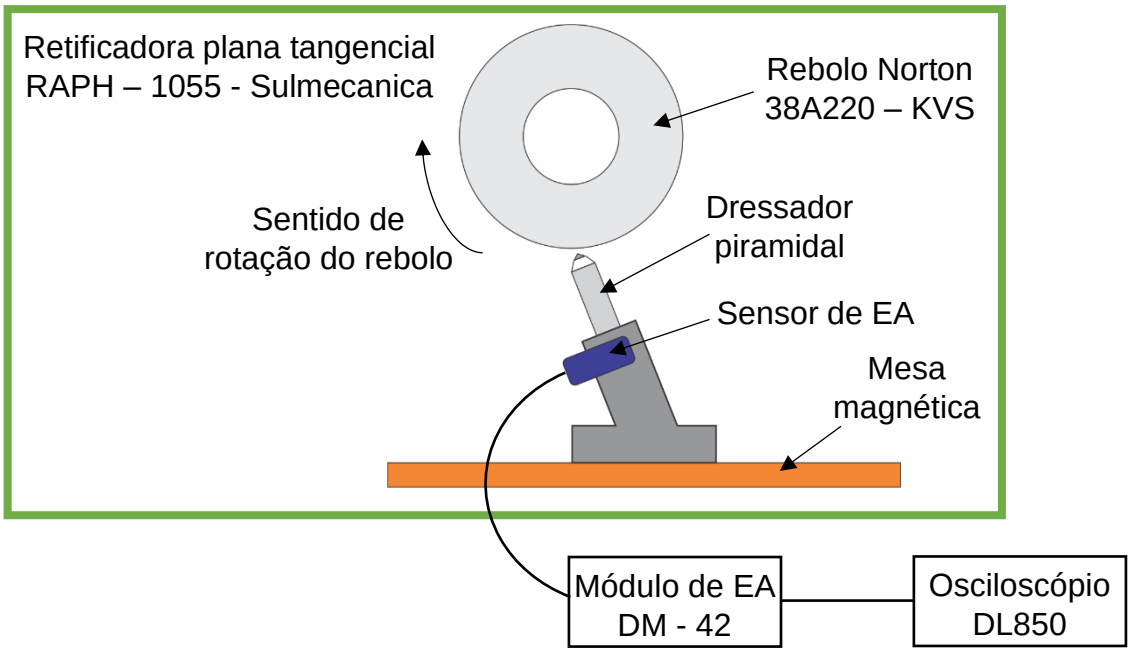
Figura 3-1 – Um dos dressadores naturais piramidais utilizados nos ensaios.



Os sinais de emissão acústica foram aquisitados utilizando um sensor do tipo piezelétrico, modelo DM42, de alta sensibilidade da marca Sensis, cuja faixa de leitura é de 20 kHz a 500 kHz. O sinal do sensor foi condicionado para aquisição através de um módulo de processamento de emissão acústica modelo DM42, da mesma fabricante, o qual permite a aquisição dos sinais através do ajuste adequado do ganho e da redução de ruídos. Então, o sinal é coletado por um osciloscópio da Yokogawa, modelo DL850, a uma taxa de 2 milhões de amostras por segundo.

A Figura 3-2 apresenta a montagem dos equipamentos e o processo de aquisição de dados.

Figura 3-2 – Esquemático da montagem do banco de ensaios.




### 3.1.1 CONFIGURAÇÃO DOS PARÂMETROS DE DRESSAGEM

Os parâmetros de dressagem foram controlados para garantir que os ensaios para os três dressadores apresentassem condições semelhantes. Durante todos os ensaios, não foi utilizado fluido de corte, pois desejou-se obter o desgaste do diamante mais rapidamente. O grau de recobrimento de dressagem ($U_d$) no início dos ensaios foi igual a 2 e a profundidade de dressagem ($a_d$) foi de 40 µm. A partir do valor inicial do $b_d$ de cada diamante, calculou-se o tempo de contato entre o diamante e o

rebolo ($t_d$). Este tempo foi utilizado para o ajuste da velocidade de dressagem, a partir de uma relação empírica previamente obtida entre o tempo de contato diamante-rebolo e a velocidade ajustada no inversor de frequência, em rpm. A Tabela 3-1 resume os parâmetros de dressagem empregados nos ensaios.

Tabela 3-1 – Parâmetros de dressagem utilizados nos ensaios.

| **Parâmetro** | **Especificação** | |
|---|---|---|
| Refrigeração: | Sem fluido de corte | |
| Rebolo: | Tipo: | 38A220KVS |
| | Abrasivo: | Óxido de alumínio |
| | Ligante: | Vitrificado |
| | Dureza: | L |
| | Granulometria: | 150 |
| | Dimensões: | 355,6 x 25,4 x 127 mm |
| | Rotação: | 1790 rpm |
| | $v_s$: | 33,3 m/s |
| Profundidade de dressagem: | 40 µm | |
| Velocidade transversal do dressador: | Variável para cada dressador | |
| *Ud* no início do ensaio: | 2 | |

### 3.1.2 SISTEMA DE AQUISIÇÃO DE IMAGENS

Para realizar as medições da largura de atuação do dressador, foi utilizado um dispositivo dotado com câmera, modelo *Galaxy Note 5* (SM-N920G), da marca SAMSUNG, cujos parâmetros da óticos foram fixados para todas as fotos, conforme é apresentado na Tabela 3-2.

A iluminação foi feita através da luz ambiente adicionada com uma lâmpada de luz branca fria fluorescente compacta de 45 W disposta no interior de uma *soft box* para uma difusão uniforme da luz, eliminando-se, assim, a possibilidade de ocorrência de sombras.

Tabela 3-2 – Parâmetros utilizados no dispositivo para a captura de imagens

| | |
|---|---|
| Modelo: | Samsung Galaxy Note 5 (SM-N920G) |
| Resolução: | 5312 x 2988 px (16 MP) |
| Velocidade do obturador: | 1/350 s |
| ISO: | 800 |
| Foco: | Automático |
| Abertura do diafragma: | F 1.9 |

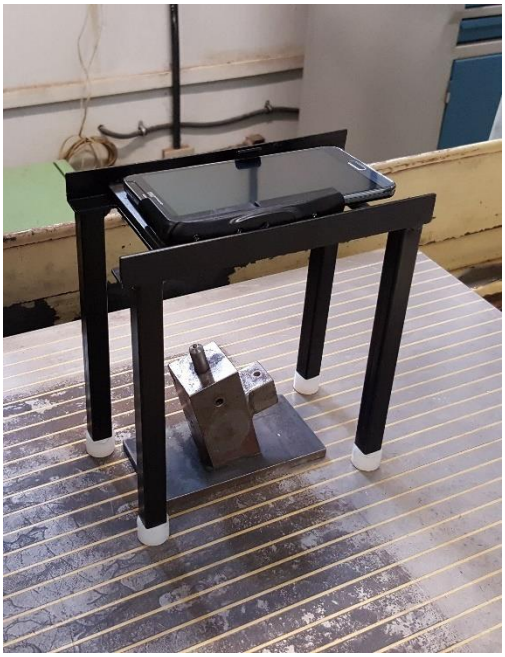
Durante os ensaios, fotos do diamante foram capturadas em dois ângulos diferentes: vista frontal e vista superior. A vista frontal teve como objetivo a medição do valor do $b_d$, cujo procedimento para a obtenção dos valores da largura de atuação do dressador será descrito na Seção 3.3. Para esta foto frontal, a câmera foi posicionada a uma distância fixa de 15 cm da ponta do dressador, sobre um suporte metálico especialmente construído para alinhá-la de acordo com a borda da mesa magnética. Já a vista superior teve como objetivo apenas a observação do comportamento do desgaste do diamante ao longo das passadas. Para ela, um outro suporte foi construído de forma a garantir que o dispositivo dotado com câmera ficasse a uma distância de 15 cm da ponta do dressador, estando paralelo à mesa.

A Figura 3-3 apresenta o banco de ensaios para a aquisição das imagens para as duas vistas registradas. O procedimento utilizado para o cálculo dos valores da largura de atuação do dressador a partir das imagens será descrito na Seção 3.3.

Figura 3-3 – Sistema para a aquisição das imagens e foto do dressador para vista frontal (a) e (b) e vista superior (c) e (d).



(a)



(c)



(b)



(d)

### 3.1.3 SISTEMA DE AQUISIÇÃO DE DADOS

O sinal de emissão acústica foi pré-processado através do módulo de processamento DM42 da fabricante Sensis. Desta forma, foi possível amplificar o sinal para a aquisição e reduzir os ruídos. O ajuste foi realizado a partir do ganho de entrada do amplificador, de modo que o sinal não apresente amplitudes muito baixas e não se sature.

Os sinais foram aquisitados em sua forma pura utilizando um osciloscópio modelo DL850 da marca Yokogawa, a uma frequência de amostragem de 2 MS/s. Os

parâmetros de configuração do sistema de aquisição de dados são apresentados na Tabela 3-3.

Tabela 3-3 – Parâmetros de configuração do sistema de aquisição de dados.

| **Parâmetro** | **Especificação** | |
|---|---|---|
| Tipo de sensor: | Passivo | |
| Módulo de EA: | Ganho de entrada:<br>Ganho de sinal:<br>Redutor de ruído: | 4<br>4<br>10 |
| Tipo de sinal: | Puro | |
| Frequência de amostragem: | 2 MS/s | |

## 3.2 PROCEDIMENTO DOS ENSAIOS

Após a montagem do banco de ensaios e da configuração dos equipamentos, foi realizada a coleta dos sinais de emissão acústica e a captura das imagens dos dressadores. Cada dressador foi utilizado até o final de sua vida útil ou até atingir o total de 200 passadas. O final da vida útil do dressador é alcançado quando o corpo metálico do dressador entra em contato com o rebolo, gerando faiscamento.

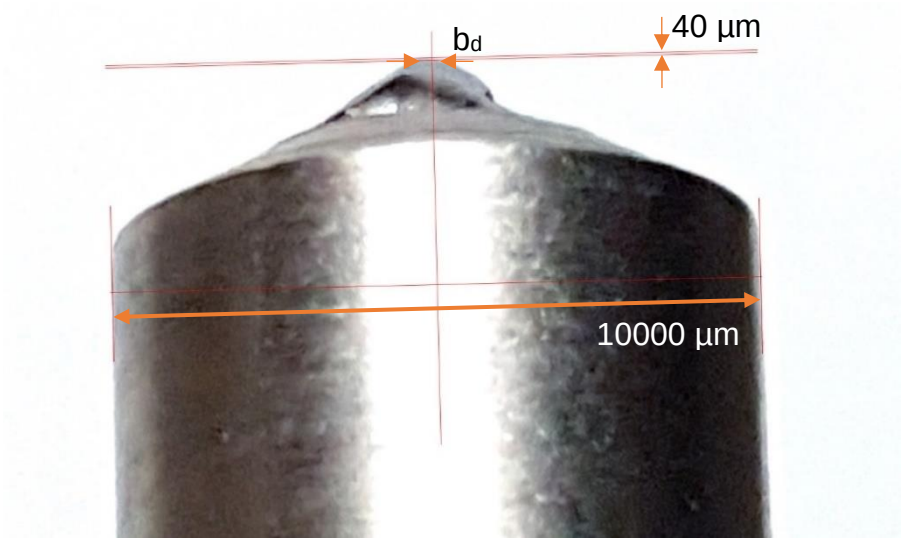
Cada passada é definida como uma ida e uma volta do rebolo sobre o dressador, sendo que o contato rebolo-dressador acontece apenas durante a ida. Para cada passada, é gerado um arquivo binário para o sinal de EA, o qual é armazenado pelo osciloscópio. Após cada passada, o rebolo era avançado 40 µm em direção ao dressador, ou seja, a penetração do dressador foi de 40 µm por passada. A cada 20 passadas (800 µm de penetração), a retificadora era desligada para a captura das imagens.

Para cada ensaio, foi utilizado um rebolo novo, pois a velocidade periférica ($v_s$) varia de acordo com seu diâmetro. Desta forma, uma diminuição máxima de 8 mm do rebolo acarretaria em uma variação insignificante de velocidade.

## 3.3 CÁLCULO DOS VALORES DA LARGURA DE ATUAÇÃO DO DRESSADOR

As imagens obtidas da ponta dos dressadores foram analisadas utilizando o aplicativo *Photoshop*. Nesta etapa, foram obtidas as medidas do $b_d$ dos diamantes através da relação de *pixels* do corpo do dressador com a ponta do diamante. A Figura 3-4 apresenta o processo de extração do $b_d$ do diamante. Utilizando esses valores obtidos, foi possível observar a evolução da largura de atuação do dressador durante todo o ensaio.

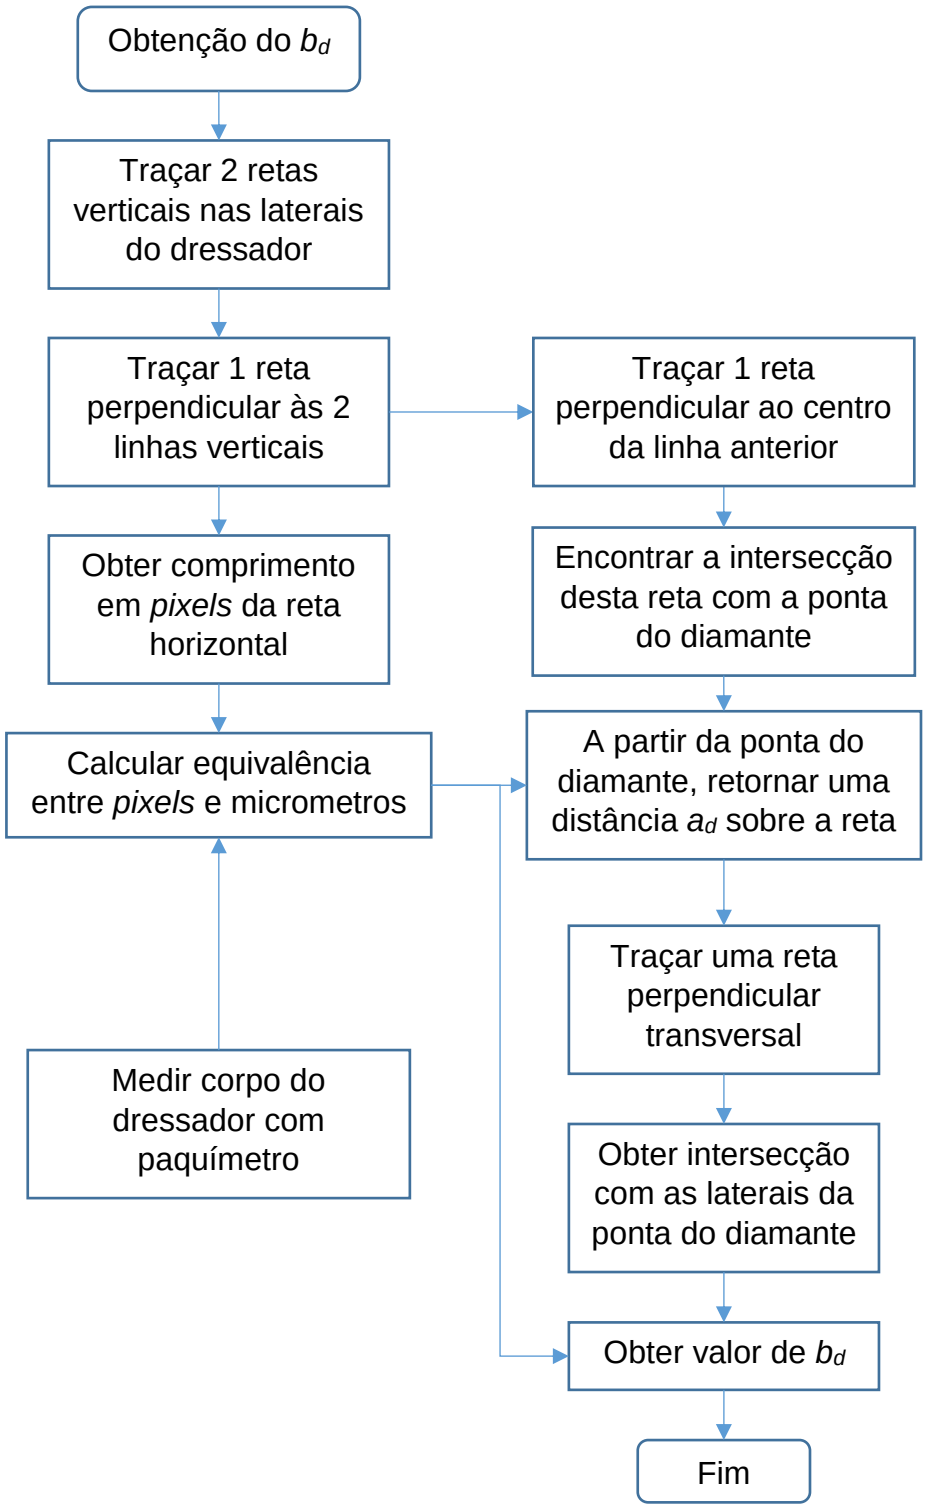
Figura 3-4 – Processo de extração do valor do $b_d$ através da análise das imagens.




Primeiramente, a largura do corpo do dressador foi medida utilizando um paquímetro. Esta medida foi relacionada com a quantidade de *pixels* equivalente na imagem. A partir do ponto central do corpo do dressador, uma linha perpendicular foi traçada até atingir a ponta do diamante. Então, a quantidade em *pixels* equivalente ao $a_d$ utilizado foi extraída desta linha, determinando o $b_d$.

A Figura 3-5 apresenta o fluxograma utilizado para a extração do valor da largura útil do dressador através das imagens capturadas.

Figura 3-5 – Fluxograma para obtenção do valor do $b_d$.



## 3.4 PROCESSAMENTO DO SINAL DE EMISSÃO ACÚSTICA

Após o término dos ensaios de dressagem e tendo posse de todos os arquivos de emissão acústica, foi realizado o processamento digital de sinais utilizando o aplicativo MATLAB. Ferramentas digitais como filtros e estatísticas foram aplicadas sobre os arquivos dos sinais do dressador 1, a fim de extrair características que sejam interessantes para o estudo.

A partir dos sinais puros de EA, foram utilizados filtros passa-faixa do tipo *Butterworth* de ordem 5 para a eliminação de ruídos ou para a seleção de bandas. A escolha deste tipo de filtro foi determinada através de trabalhos anteriores do grupo que compararam filtros convencionais e *Butteworth*. Em estudos anteriores, filtros *Butterworth* apresentaram respostas mais rápidas que os convencionais. Além disso, filtros de ordem 5 provocaram melhores atenuações sem distorções, baixas ondulações na banda de passagem e na banda de rejeição, assim como um ganho constante.

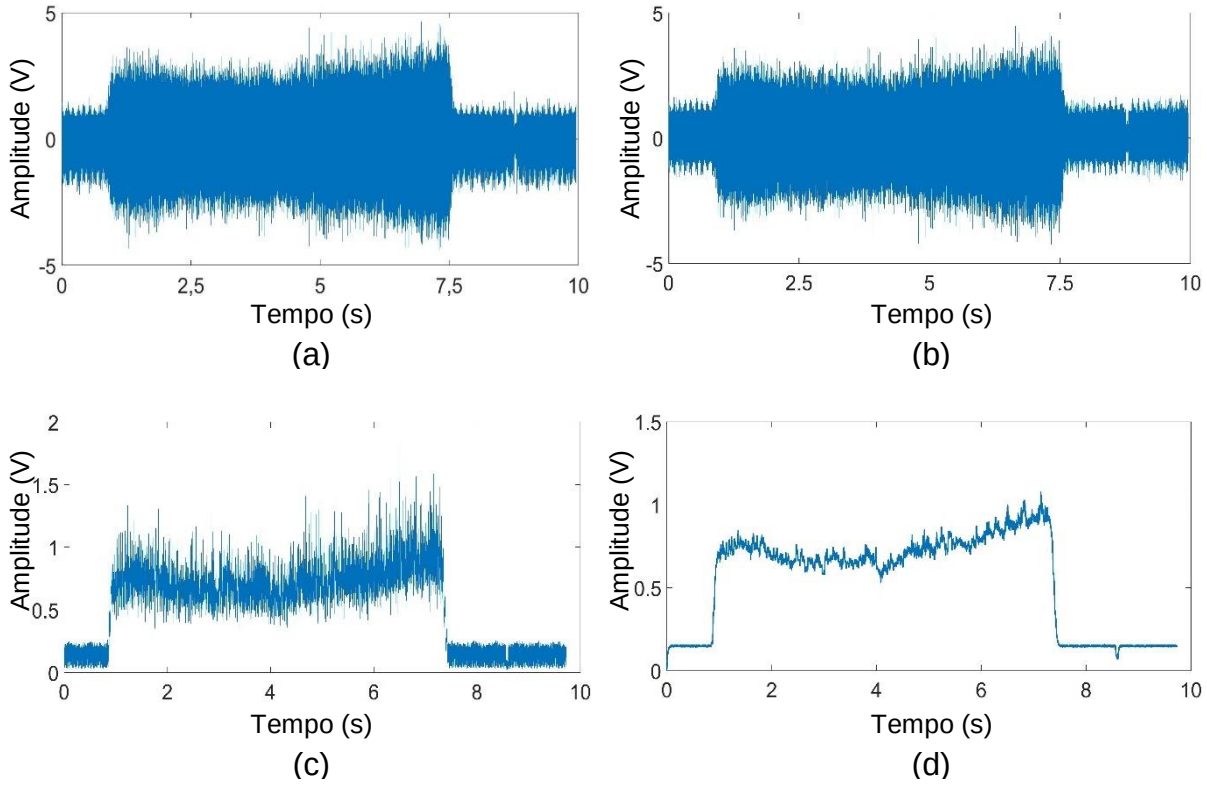
Os sinais foram utilizados considerando todo o espectro de frequências e em algumas bandas específicas. Para o estudo de todo o espectro, foi utilizado um filtro passa-faixa de 20 kHz a 500 kHz para a eliminação de ruídos. Para o estudo do sinal em bandas específicas, foram selecionadas faixas de frequências a partir da análise espectral com as ferramentas FFT e PSD.

Após os sinais serem filtrados, foram aplicadas as estatísticas: RMS, ROP, MVD, CFAR e *Power Law*. As estatísticas RMS, ROP, MVD foram calculadas utilizando 2048 pontos. As estatísticas CFAR e *Power Law* foram calculadas utilizando 8192 pontos. Estes valores foram determinados empiricamente através da observação dos resultados de quando a estatística é aplicada. Ao se utilizar valores menores de pontos para CFAR e *Power Law*, não foi possível identificar o trecho de contato na passada.

Em seguida, utilizou-se um filtro passa-baixas do tipo *Butterworth* de ordem 1 para eliminação de ruídos e melhor definição do sinal. Para cada estatística estudada, o melhor filtro foi escolhido, de forma a eliminar informações dispensáveis e manter informações importantes no sinal. Isto é observado com a redução do ruído na amplitude do sinal. A Figura 3-6 exemplifica o processamento digital para uma

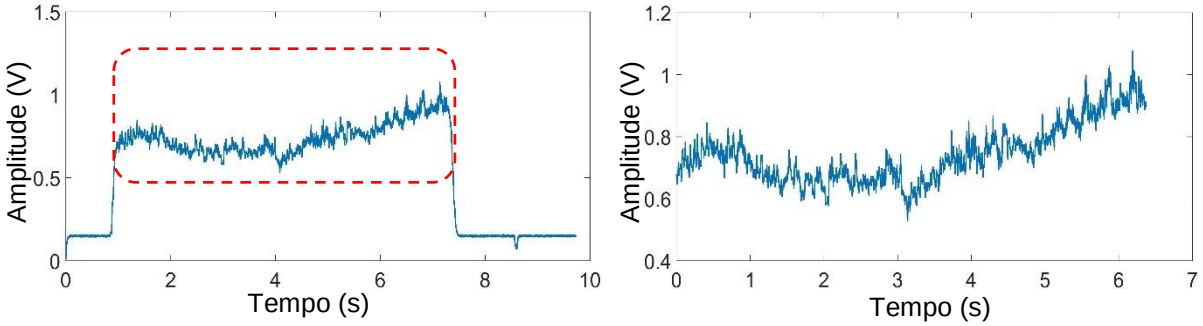
passada do sinal RMS sem seleção de banda, desde o sinal puro até sua última filtragem.

Figura 3-6 – Primeira passada do sinal EA sendo: (a) sinal puro; (b) filtro passa-faixa de ordem 5; (c) estatística RMS e (d) filtro passa-baixa de ordem 1.




Em seguida, o trecho de contato rebolo-dressador foi identificado manualmente para todas as passadas, sendo extraído do restante dos dados aquisitados, como é ilustrado na Figura 3-7. Desta forma, tem-se os dados processados apenas para o trecho de contato das ferramentas.

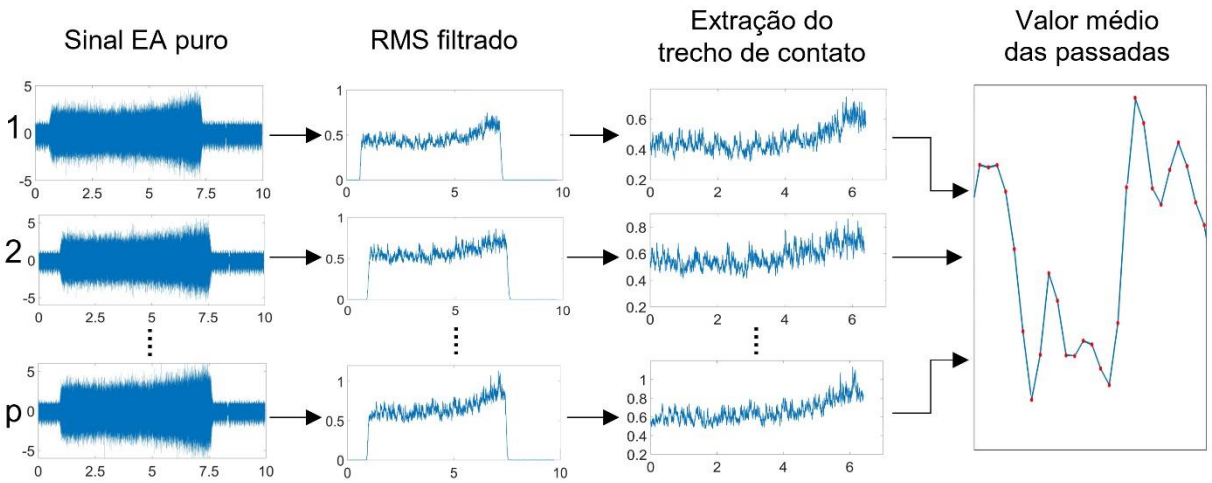
Figura 3-7 – Seleção do trecho de contato entre o rebolo e a ferramenta (a) e trecho extraído (b).




Tendo apenas o trecho de interesse extraído, calculou-se a média de seus valores, obtendo um valor médio para cada passada. Assim, foi possível montar um vetor de dados que contém um valor médio para cada passada ao longo do ensaio. Este processo foi repetido para todas as estatísticas e bandas escolhidas.

A Figura 3-8 apresenta, de forma resumida, as etapas do processamento dos sinais de EA para a obtenção da curva característica. Para a análise do dressador 1, as passadas de 1 a *p* foram processadas de forma a se obter um vetor com *p* elementos, representando as médias das passadas. Este vetor será utilizado como entrada das redes neurais, a fim de associar o valor real do $b_d$ com os sinais dos sensores.

Figura 3-8 – Processo de tratamento do sinal EA para obtenção da curva de valores médios das passadas.



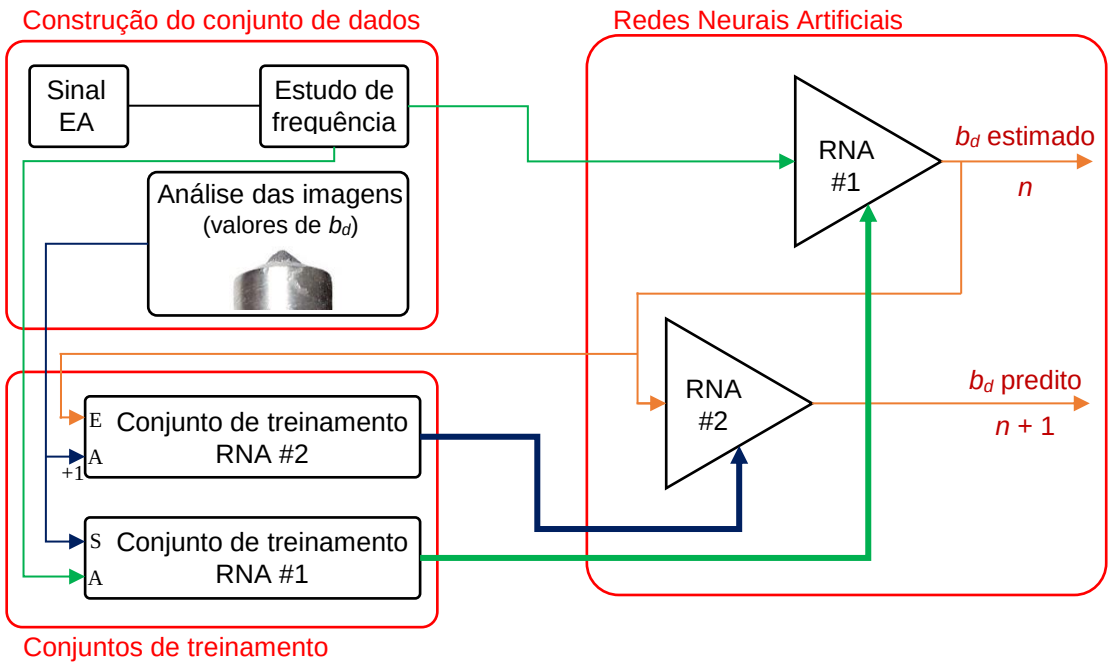
## 3.5 MODELOS NEURAIS

Para a construção dos modelos neurais, foram utilizados dois tipos de redes, um para a estimação e outro para a predição. A rede de estimação foi construída utilizando a rede neural *Perceptron* de Multi-Camadas (MLP – do inglês, *Multi-Layer Perceptron*), a qual teve como entradas os vetores com os valores médios das passadas para as diferentes estatísticas e bandas, conforme descrito no item anterior. Sua saída foi o valor do $b_d$ estimado. Em seguida, o $b_d$ estimado foi utilizado como entrada para uma segunda rede neural, a rede de predição TDNN (do inglês *Time-Delay Neural Network*). A saída obtida desta rede é o $b_d$ predito.

O objetivo da primeira rede neural, a rede de estimação, é obter um valor numérico para o $b_d$ do dressador no instante atual. Este valor é fornecido à segunda rede, que irá predizer o valor do $b_d$ um passo à frente. O valor do $b_d$ predito é o objetivo final, pois a informação futura deste valor (um passo à frente) é de grande utilidade no processo, pois informa ao operador, ou ao sistema, o momento correto de substituir a ferramenta.

A Figura 3-9 apresenta a relação dos sinais de EA processados com as redes de estimação e predição, bem como a saída de cada uma delas. Nela, é possível observar o conjunto de dados, composto pelos sinais de EA processados e separados em bandas de frequência e dos valores de $b_d$ obtidos das imagens. Esses dados são organizados de forma a se obter o conjuntos de treinamentos que serão utilizados nas redes de estimação e predição. O conjunto de treinamento da RNA #1 (estimação) possui como entrada (E) as médias dos sinais de EA e como alvo (A) os valores de $b_d$. O conjunto de treinamento da RNA #2 (predição) possui como entrada os valores de $b_d$ estimado e como alvo os valores de $b_d$ predito deslocados no tempo um passo à frente. Então, a RNA #1 será construída de forma a se ter como entrada os sinais EA, treinada com o conjunto de treinamento RNA #1 e terá como saída o valor de $b_d$ estimado. A RNA #2 terá como entrada o valor do $b_d$ estimado, será treinada com o conjunto de treinamento RNA #2 e terá como saída o valor de $b_d$ predito um passo à frente.

Figura 3-9 – Construção dos modelos neurais para estimação e predição.




Para a construção dos modelos neurais de estimação, foram escolhidas as 6 melhores configurações de bandas e estatísticas através dos gráficos dos valores médios das passadas. Os melhores gráficos foram os que apresentaram alguma tendência ao longo do ensaio, a qual será importante para o bom desempenho da rede neural. Com o objetivo de encontrar a melhor rede dentre as configurações testadas, minimizando os erros de estimação, um algoritmo iterativo foi desenvolvido para testá-las, variando seus parâmetros internos após cada ciclo de treinamento.

Para os modelos neurais de predição, foi utilizada apenas a configuração de estimação que apresentou o melhor desempenho. Para o melhor $b_d$ estimado, que age como entrada da rede de predição, foram testadas diversas topologias de rede para se obter a melhor configuração de predição, a qual apresentou o menor erro.

### 3.5.1 TREINAMENTO DOS MODELOS NEURAIS

Para o treinamento da rede neural de estimação, cada média da passada processsada digitalmente representou um elemento do vetor. Portanto, a entrada da rede neural irá conter 6 linhas por $p$ colunas, sendo que as linhas representam as melhores estatísticas separadas nas melhores bandas e as colunas representam a

quantidade de passadas até o final da vida útil do dressador. O vetor de saída desta rede também deverá conter 1 linha por *p* colunas, sendo obtido através da interpolação dos valores médios dos $b_d$'s obtidos para os três diamantes, calculados para todas as passadas da vida útil do dressador.

A rede de estimação foi construída de forma a utilizar 70% da massa de dados para treinamento, 15% para validação e 15% para teste. Ela utilizou a função *feedforwardnet* do MATLAB com o algoritmo de treinamento *trainlm* (*Levenberg-Marquardt backpropagation*) e seleção randômica de validação dos dados. Foram feitas todas as combinações possíveis entre as 6 entradas escolhidas e foram testadas 155 topologias diferentes de redes, variando de 1 a 3 camadas ocultas e de 5 a 30 neurônios por camada. Para cada combinação de entradas ativas com cada topologia de rede, foram realizados 5 treinamentos, a fim de obter o menor erro de treino e de teste. O critério de parada utilizado foi o número máximo de épocas igual a 2000. A Tabela 3-4 apresenta os principais parâmetros de configuração da rede neural MLP.

Tabela 3-4 – Parâmetros da rede neural de estimação

| **Parâmetro** | **Especificação** |
|---|---|
| Função de treinamento | *Levenberg-Marquardt backpropagation* |
| Número máximo de falhas de validação | 15 |
| Número máximo de épocas | 2000 |
| Quantidade de camadas ocultas | Variável: 1, 2 e 3 |
| Quantidade de neurônios por camada oculta | Variável: 5, 10, 15, 20 e 30 |
| Quantidade de treinamentos por configuração | 5 |
| Divisão de dados (T-V-T) | 70%, 15%, 15% |

Realizado o treinamento do modelo neural, o erro de classificação desse modelo foi calculado com base no conjunto referente aos 15% de dados separados para teste. O valor do erro e os parâmetros utilizados no modelo foram armazenados para os 5 treinamentos, a fim de testar a estabilidade do conjunto de configurações. Após a realização de todo o processo, os modelos neurais foram organizados de

acordo com o erro e o desvio padrão observados nas 5 repetições. Assim, o modelo escolhido foi aquele que apresentou o menor erro e desvio padrão.

Para a rede de predição, foi considerada como entrada o resultado da melhor rede de estimação. Foi utilizada a função *timedelaynet* do MATLAB, sendo testada a mesma tabela de neurônios, com 155 topologias, um passo à frente. Também foi utilizada a função de treinamento *Levenberg-Marquardt backpropagation*. A melhor rede de predição foi escolhida de acordo com o menor erro e desvio padrão e maior regressão observados.

# 4 RESULTADOS E DISCUSSÕES

## 4.1 ENSAIOS DE DRESSAGEM

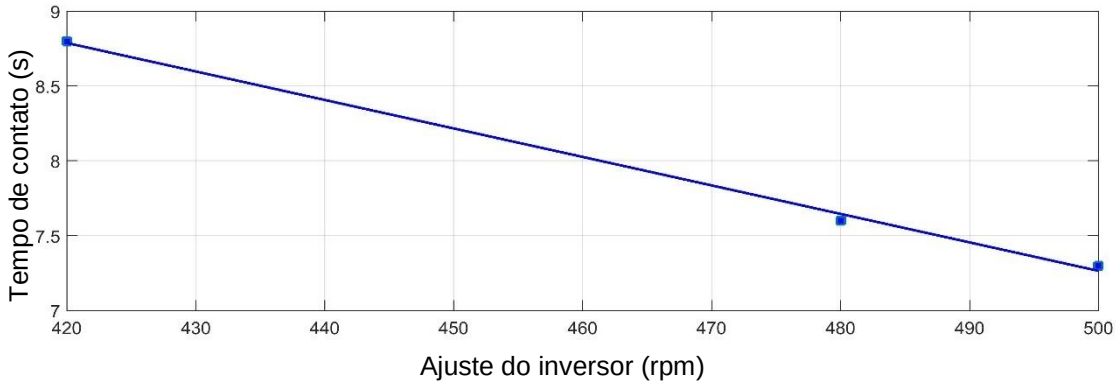
Antes do início dos ensaios, uma análise precisou ser feita para a configuração dos parâmetros da dressagem. Sabe-se que para haver consistência na comparação entre três ensaios diferentes, deve-se manter a mesma agressividade de dressagem para eles, fazendo com que $U_d$ seja igual no início dos ensaios. Para este trabalho, foi definido o $U_d$ inicial igual a 1, por definir uma alta agressividade na dressagem, muito utilizada na prática nas indústrias. Por isso, este capítulo apresenta os resultados obtidos durante esta análise.

Primeiramente, tentou-se estabelecer uma relação entre o tempo de contato dressador-rebolo e o ajuste do inversor, em rpm. Para isso, com um rebolo e um dressador velhos, foram testados 3 ajustes no inversor, e obtidos os tempos de contato pelo osciloscópio:

- 420 rpm = 8,8 s
- 480 rpm = 7,6 s
- 500 rpm = 7,3 s

Como a relação é linear, um gráfico foi traçado a fim de se obter o valor a ser colocado no inversor que seja equivalente ao tempo desejado da passada, como é apresentado na Figura 4-1.

Figura 4-1 – Relação entre o ajuste do inversor com o tempo de contato entre o rebolo e o diamante.



A partir da reta interpolada do gráfico da Figura 4-1, é possível estabelecer sua equação como sendo:

$$Ajuste\ inversor = \frac{16{,}7869 - t_d}{0{,}0190}\ [\mathrm{rpm}] \quad (19)$$

em que $t_d$ é o tempo de contato entre o rebolo e o diamante.

Tendo posse da equação que relaciona o tempo de contato com o ajuste de velocidade do inversor de frequência, deve-se, para cada dressador, encontrar o $t_d$ que forneça o $U_d$ = 2. Antes de iniciar cada ensaio, o dressador novo foi fixado, uma foto frontal foi capturada e, por ela, o $b_d$ foi calculado. A partir do $b_d$ inicial, foi calculado o tempo de contato da passada referente a este $b_d$ através da Equação 4, sendo a largura do rebolo de 24,5 mm, o grau de recobrimento possuindo valor inicial igual a 2; a velocidade do rebolo, considerada 1800 rpm e $b_d$ é a largura de atuação do dressador dada em milímetros. Os resultados para os três diamantes são apresentados na Tabela 4-1.

A diferença de ajuste no inversor aconteceu, pois o equipamento não apresentou precisão nos ajustes. Quando seu ajuste era alterado e depois retornado a um valor já utilizado, observou-se que havia uma variação na velocidade. Por isso, o ajuste fino foi feito de maneira empírica para tentar alcançar o valor de $t_d$. Então, o procedimento dos ensaios foi realizado como descrito no capítulo anterior.

Tabela 4-1 – Parâmetros de ajuste dos ensaios.

| | **$b_d$ inicial (μm)** | **$t_d$ (s)** | **Ajuste do inversor calculado (rpm)** | **Ajuste do inversor utilizado (rpm)** |
|---|---|---|---|---|
| **Ensaio 1 (dressador 1)** | 270 | 6,27 | 553 | 550 |
| **Ensaio 2 (dressador 2)** | 335 | 4,77 | 632 | 690 |
| **Ensaio 3 (dressador 3)** | 325 | 5,21 | 609 | 680 |

O Ensaio 1 contou com 200 passadas, sendo que o diamante chegou próximo ao final de sua vida útil. O Ensaio 2 contou com 160 passadas, sendo desgastado completamente. O Ensaio 3 contou com 200 passadas, sendo que o diamante chegou próximo ao final de sua vida útil. A Tabela 4-2 apresenta os valores de $d_s$ no início e no final de cada ensaio.

Tabela 4-2 – Diâmetro do rebolo no início e no final de cada ensaio.

| | **$d_s$ (mm)** | |
|---|---|---|
| | **Início** | **Fim** |
| **Ensaio 1** | 355,6 | 338 |
| **Ensaio 2** | | 343 |
| **Ensaio 3** | | 338 |

De acordo com a Tabela 4-2, é possível observar que o desgaste máximo do rebolo foi de 17,6 mm, o que representa 4,95% de redução em relação ao diâmetro inicial. Este valor divergiu do teórico (8 mm), pois a máquina perde a precisão da profundidade de dressagem na passada seguinte ao desligamento do motor para a captura das imagens. Como o rebolo foi substituído em cada ensaio a fim de não haver uma variação significativa em seu diâmetro, pode-se considerar que a velocidade periférica do rebolo se manteve constante.

## 4.2 ANÁLISE DAS IMAGENS

Durante os ensaios, foram capturadas 22 imagens para o diamante 1, 18 para o diamante 2 e 22 para o diamante 3, sendo que metade das fotografias são da vista frontal e metade da vista superior. A Tabela 4-3 apresenta os valores dos $b_d$'s obtidos a partir da análise das imagens dos dressadores 1, 2 e 3.

Tabela 4-3 – Valores de $b_d$ para os três ensaios.

| Número da passada | $b_d$ (µm) | | |
|---|---|---|---|
| | Ensaio 1 | Ensaio 2 | Ensaio 3 |
| 0 | 270 | 355 | 325 |
| 20 | 813 | 450 | 495 |
| 40 | 830 | 620 | 556 |
| 60 | 940 | 1190 | 873 |
| 80 | 1170 | 1270 | 926 |
| 100 | 1340 | 1485 | 1043 |
| 120 | 1620 | 1490 | 1100 |
| 140 | 1620 | 1680 | 1800 |
| 160 | 1813 | 2080 | 1990 |
| 180 | 2020 | - | 2473 |
| 200 | 2080 | - | 2670 |

A partir dos pontos da Tabela 4-3, fez-se a interpolação linear para cada um dos dressadores, como está apresentado na Figura 4-2.

A partir da reta média do $b_d$ para os três dressadores, calculou-se a média e o desvio padrão entre eles, conforme é apresentado na Figura 4-3. Devido ao fato de os diamantes serem naturais e apresentarem geometrias diferentes, além da presença de impurezas, os ensaios não apresentaram a mesma quantidade de passadas. Por isso, para se realizar uma análise da evolução do $b_d$ tendo repetição dos dados para o cálculo da média e do desvio padrão para cada medição, foi adotado o total de passadas do menor ensaio como quantidade máxima de passadas. Assim, os valores foram truncados até a 160ª passada, que corresponde ao Ensaio 2.

Figura 4-2 – Evolução do $b_d$ durante as passadas para os três dressadores.

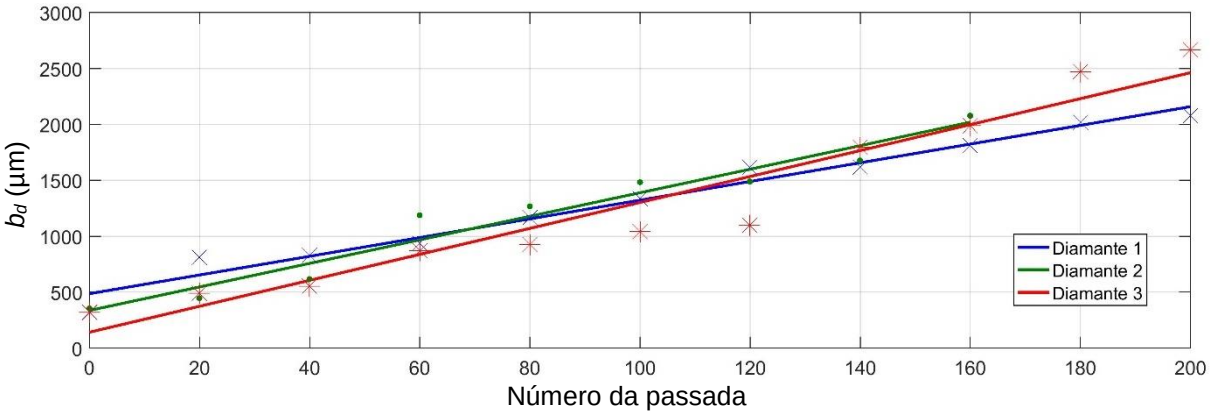
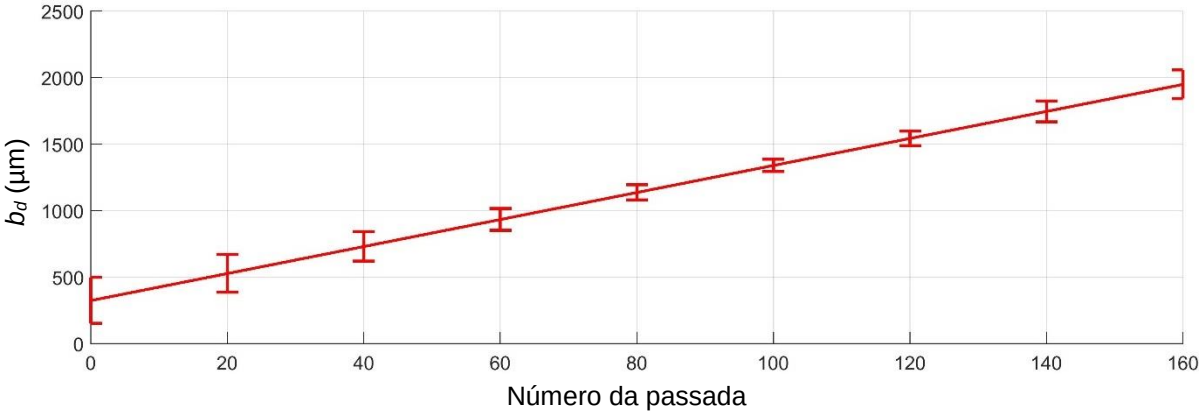



Figura 4-3 – Média e desvio padrão do $b_d$ a partir dos valores dos três ensaios.




A partir da regressão apresentada na Figura 4-3, pode-se observar que existe linearidade entre os dados, com o desvio padrão indicando uma dispersão. O coeficiente angular da reta é de 10,2, indicando que a cada passada, em média, o valor de $b_d$ aumenta 10,2 µm.

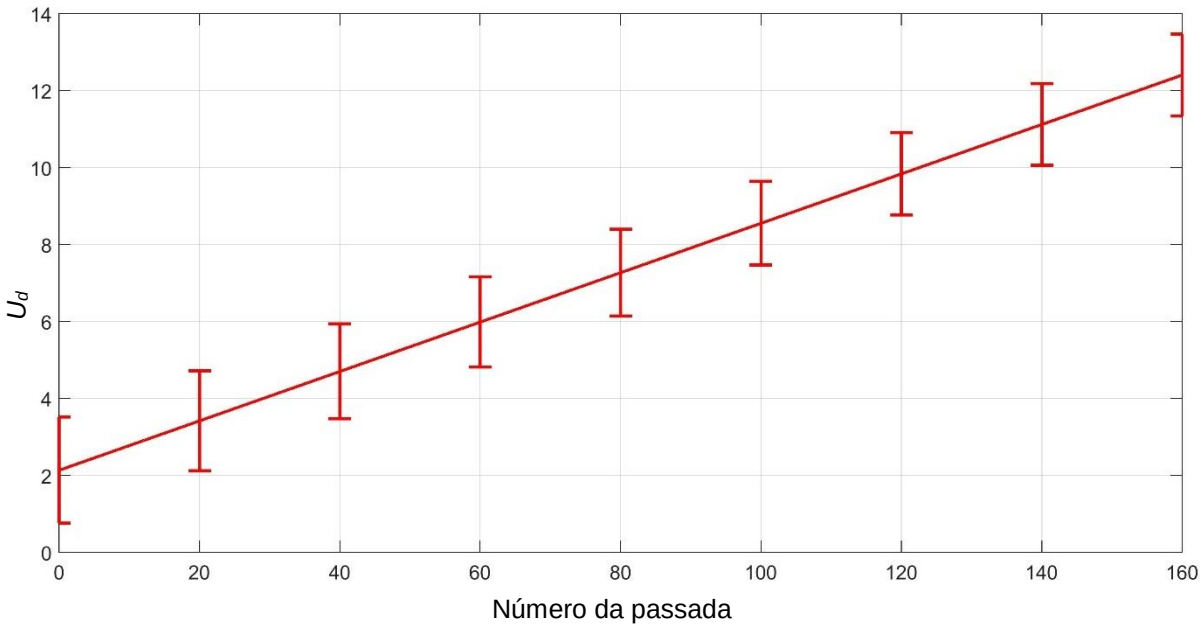
A Tabela 4-4 apresenta os valores médios dos $b_d$'s e seus desvios padrão para cada 20 passadas. Os valores sobre a reta apresentados nesta tabela foram utilizados para o treinamento das redes neurais de estimação. Para algumas passadas, observa-se um desvio padrão consideravelmente alto. Este comportamento já era esperado, pois, pelo falo dos diamantes serem naturais e, consequentemente, assimétricos, já tinha sido possível observar visualmente que o $b_d$ inicial dos diamantes são bem diferentes um do outro.

Tabela 4-4 – $b_d$ médio e desvio padrão.

| Número da passada | $b_d$ médio (μm) | Desvio padrão (μm) |
|---|---|---|
| 0 | 323,5 | 172,7 |
| 20 | 527,7 | 141,1 |
| 40 | 729,9 | 110,4 |
| 60 | 933,1 | 81,4 |
| 80 | 1136,3 | 57,0 |
| 100 | 1339,5 | 45,3 |
| 120 | 1542,6 | 55,1 |
| 140 | 1745,8 | 78,7 |
| 160 | 1949,0 | 107,4 |

A partir dos valores de $b_d$ obtidos através das retas médias de cada dressador aprentadas na Figura 4-2, foi possível observar o nível de agressividade gerado no rebolo que decresce quando o parâmetro $U_d$ aumenta. Com esses dados, foram calculadas as médias e os desvios padrão do grau de recobrimento, que são apresentados na Figura 4-4.

Figura 4-4 – Média e desvio padrão do $U_d$ a partir do valor médio dos três ensaios.



A partir da Figura 4-4, é possível observar que o grau de recobrimento médio se inicia em 2, caracterizando a formação de um rebolo mais agressivo. À medida que o ensaio avança, $U_d$ aumenta na mesma proporção em que $b_d$ aumenta. Isto acontece porque o grau de recobrimento depende diretamente da condição em que se encontra a ponta do diamante introduzida no rebolo a uma certa profundidade, ou seja, sua largura de atuação. No final do ensaio, $b_d$ está tão grande que a dressagem faz com que o rebolo fique pouco agressivo. Para esta análise, $L_R$ foi considerado constante, conforme foi discutido na seção 4.1. A variação do desvio padrão ao longo das passadas foi pequena. No entanto, estes desvios podem ser considerados altos, como já era previsível, pois a diferença de composição e geometria de diamantes naturais é muito grande.

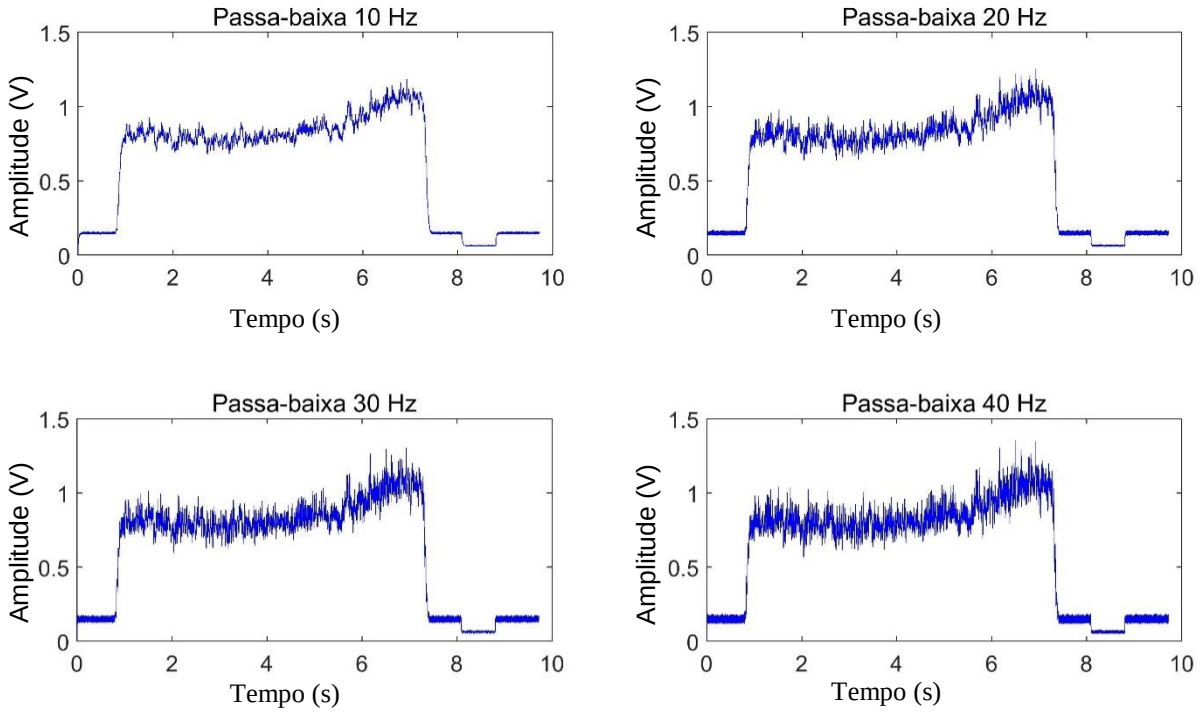
## 4.3 PROCESSAMENTO DOS SINAIS DE EMISSÃO ACÚSTICA

Os sinais de emissão acústica foram processados a fim de se obter características que correlacionassem o sinal ao valor do $b_d$ obtido pelas imagens. Em uma análise preliminar, foram estudados os filtros passa-baixa de ordem 1 que seriam utilizados no processamento logo após o cálculo das estatísticas. Em seguida, foi realizada a análise espectral utilizando a FFT e a PSD para a seleção das bandas de interesse que seriam utilizadas no estudo. Por fim, os sinais foram processados para as estatísticas e bandas convenientes, obtendo, então, os valores médios das passadas.

### 4.3.1 ESCOLHA DO FILTRO PASSA-BAIXA

Para a escolha do filtro passa-baixa, uma passada foi processada variando a frequência de corte do filtro. A partir de uma passada RMS, o sinal foi processado utilizando frequências de 10 a 40 Hz, como está apresentado na Figura 4-5.

Figura 4-5 – Comparação de filtros passa-baixa para uma mesma passada RMS.

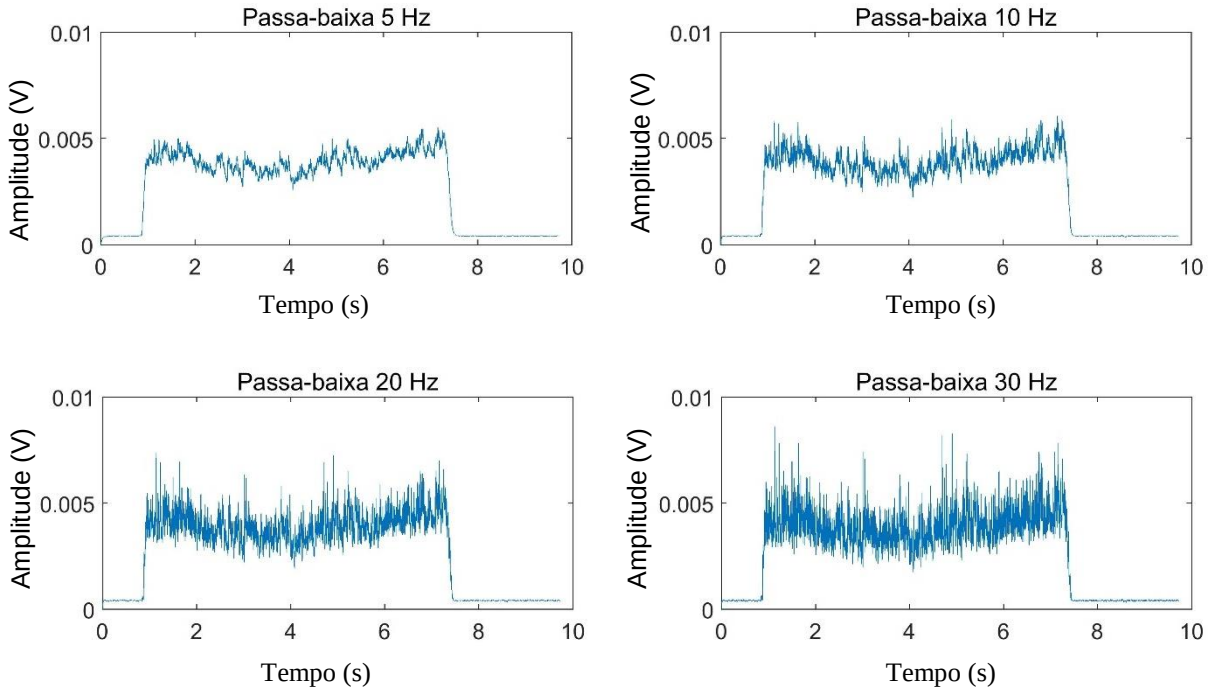



A partir da Figura 4-5 é possível observar que quanto maior a frequência de corte, mais informações contém o sinal, pois apenas frequências acima deste valor são atenuadas. No entanto, para a abordagem deste trabalho, julgou ser suficiente as informações abaixo de 10 Hz, pois são mantidas as características de interesse para o posterior cálculo das médias.

Todas as passadas processadas utilizando RMS, ROP e MVD apresentaram comportamentos semelhantes com o uso do filtro passa-baixa. Por isso, para essas estatísticas, foi utilizado o filtro de 10 Hz.

Já para as estatísticas *power law* e CFAR, filtros de 5 Hz apresentaram melhores resultados, como exemplifica a Figura 4-6. Pode-se observar que o filtro de 10 Hz se apresenta muito mais ruidoso do que o mesmo filtro quando foi utilizado para o RMS. Por isso, para todas as passadas processadas utilizando *power law* e CFAR, foi utilizado o filtro de 5 Hz.

Figura 4-6 – Comparação de filtros passa-baixa para uma mesma passada CFAR.




### 4.3.2 INFLUÊNCIA DO EXPOENTE VARIÁVEL (*v*) NO *POWER LAW* E CFAR

A fim de comparar o expoente *v* para o cálculo das estatísticas *power law* e CFAR, uma passada foi plotada para diferentes valores desta variável, utilizando um filtro passa-baixa de 5 Hz. A Figura 4-7 e a Figura 4-8 apresentam variações para o *power law* e a para o CFAR, respectivamente.

Figura 4-7 – Comparação para diferentes valores de *v* utilizando *power law*. Da esquerda para direita, *v* é 0,5; 2,5 e ∞.

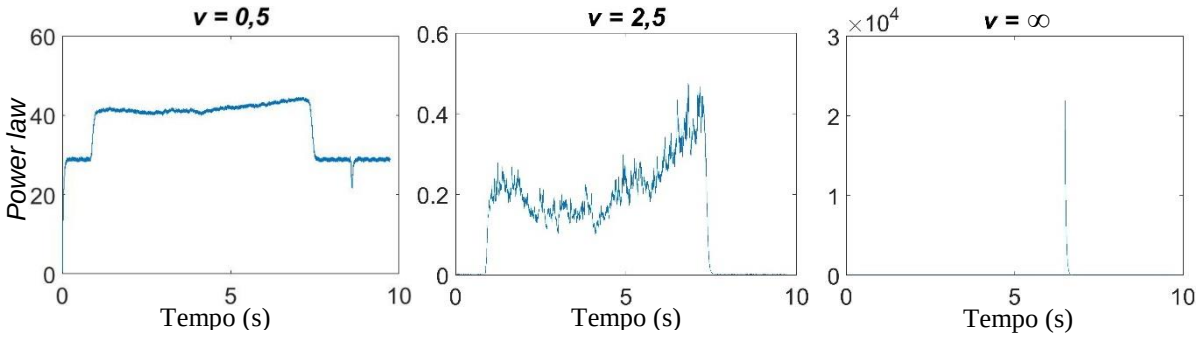
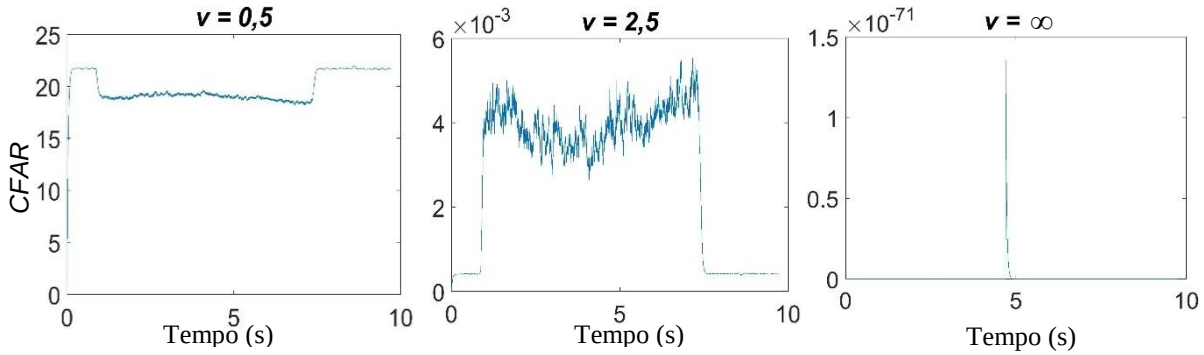


Figura 4-8 – Comparação para diferentes valores de *v* utilizando CFAR. Da esquerda para a direita, *v* é 0,5; 2;5 e ∞.



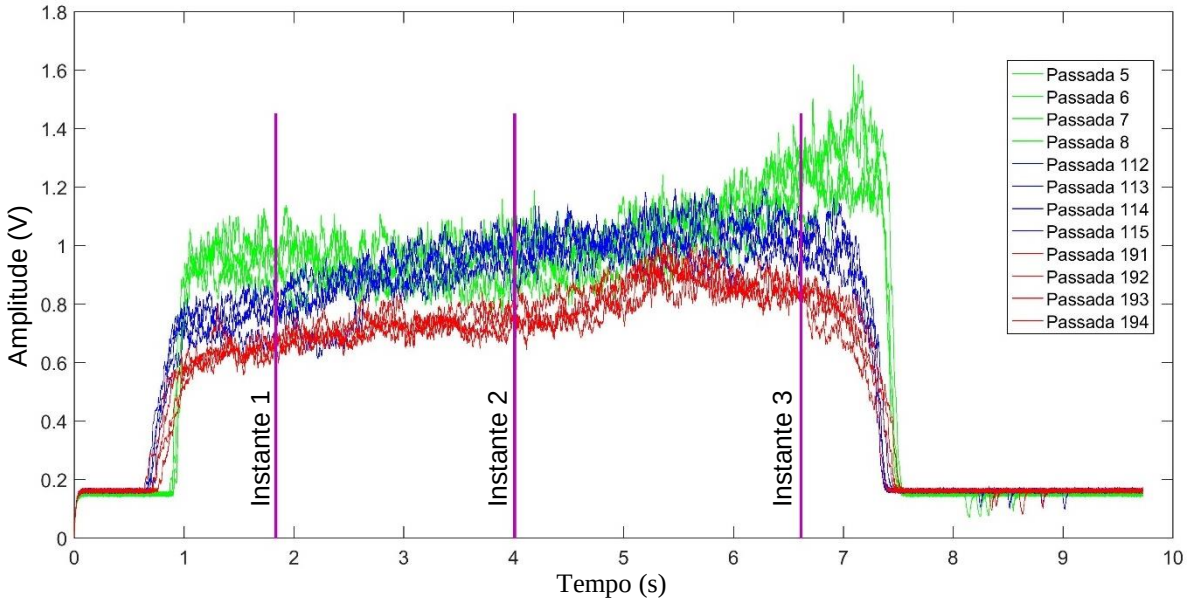

A partir da Figura 4-7 e da Figura 4-8, pode-se observar que o momento de contato se torna bem definido e com maior diferença de amplitude que o restante da passada quando *v* = 2,5. De fato, de acordo com os resultados obtidos por Z. Wang, Willett, DeAguiar, & Webster (2001), um valor considerado adequado foi de 2,5, o qual também será adotado para este trabalho.

### 4.3.3 ANÁLISE ESPECTRAL UTILIZANDO A FFT

Para poder observar o espectro de frequências do sinal, doze passadas processadas com a estatística RMS foram plotadas, sendo quatro do início do ensaio, quatro do meio e quatro do fim. As passadas do início representam o diamante em condição de novo; as do meio em condição de meia-vida e as do fim em condição de desgastado. Em seguida, foram selecionados três instantes para as passadas: início, meio e fim da passada.

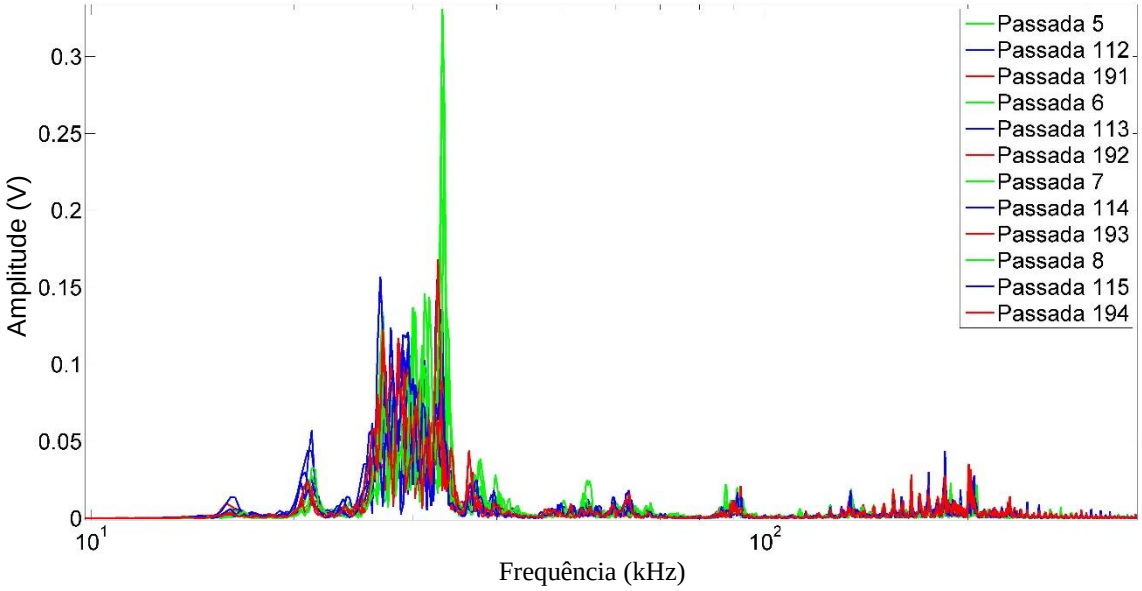
A Figura 4-9 apresenta as doze passadas escolhidas, sendo que as passadas verdes representam a condição de novo, as azuis meia vida e as vermelhas desgastado. As linhas verticais indicam os três instantes de tempo escolhidos para o início, meio e fim das passadas.

Figura 4-9 – Passadas RMS para as condições novo, meia-vida e desgastado.




A FFT foi obtida para cada uma das passadas em cada instante de tempo utilizando 2048 pontos. Então, para cada passada, foram calculadas três FFTs, uma para cada instante. A FFT resultante de cada passada foi calculada através da média das FFTs para os três instantes. Desta forma, para cada passada haverá uma FFT, que foi obtida através da média dos três instantes. A Figura 4-10 apresenta a análise espectral para as doze passadas selecionadas.

Figura 4-10 – Análise espectral de diferentes passadas utilizando a FFT.



A partir do espectro obtido, pode-se observar que a percepção do sensor aconteceu com maior intensidade em frequências em torno de 30 kHz. Então, algumas bandas foram selecionadas a partir deste espectro, como é apresentado na Tabela 4-5. Elas foram escolhidas de forma que as faixas apresentassem amplitudes altas e diferentes níveis de amplitude para cada comportamento.

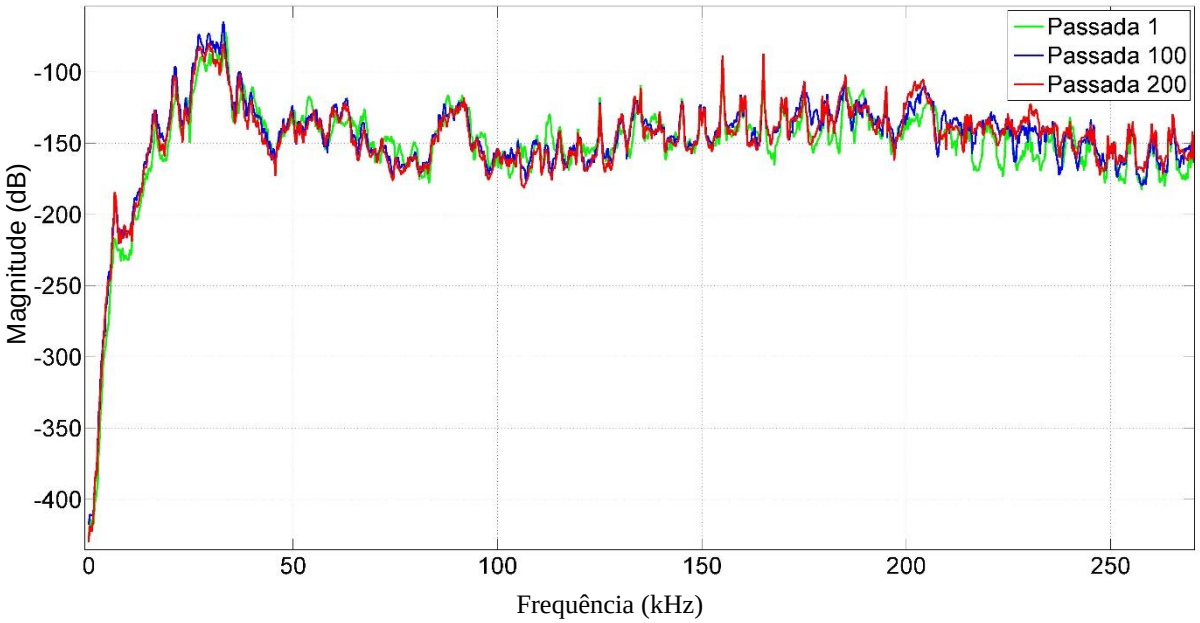
Tabela 4-5 – Bandas de frequência selecionadas a partir da análise espectral pela FFT.

| **Faixas de frequência (kHz)** |
|---|
| 21 a 25 |
| 29 a 31 |
| 30 a 34 |
| 50 a 55 |

### 4.3.4 ANÁLISE ESPECTRAL UTILIZANDO A PSD

A análise espectral também foi realizada utilizando a densidade espectral de potência (PSD) dos sinais de emissão acústica. Foi analisado um trecho de $10^6$ pontos do sinal puro, a partir do ponto equivalente a 3 segundos. Foram utilizados 8192 pontos da DFT para estimar a PSD. O resultado para três passadas, uma para cada condição, é apresentado na Figura 4-11.

Figura 4-11 – Análise espectral de diferentes passadas utilizando a PSD.




A partir do espectro obtido, foram selecionadas as bandas utilizando os mesmos critérios para a FFT. As bandas escolhidas são apresentadas na Tabela 4-6.

Tabela 4-6 – Bandas de frequência selecionadas a partir da análise espectral pela PSD.

| **Faixas de frequência (kHz)** |
|---|
| 24 a 29 |
| 25 a 30 |
| 41 a 44 |
| 63 a 68 |
| 72 a 75 |
| 95 a 99 |
| 105 a 107 |
| 111 a 114 |
| 120 a 124 |
| 131 a 134 |
| 199 a 204 |
| 216 a 219 |

### 4.3.5 ANÁLISE DOS VALORES MÉDIOS

Todas as bandas selecionadas através da FFT e PSD para a análise dos sinais de EA são apresentadas na Tabela 4-7.

Tabela 4-7 – Bandas de frequência selecionadas para análise.

| Banda | Faixas de frequência (kHz) |
|---|---|
| 1 | 21 a 25 |
| 2 | 24 a 29 |
| 3 | 25 a 30 |
| 4 | 29 a 32 |
| 5 | 30 a 34 |
| 6 | 32 a 34 |
| 7 | 41 a 44 |
| 8 | 50 a 55 |
| 9 | 63 a 68 |
| 10 | 72 a 75 |
| 11 | 95 a 99 |
| 12 | 105 a 107 |
| 13 | 111 a 114 |
| 14 | 120 a 124 |
| 15 | 131 a 134 |
| 16 | 199 a 204 |
| 17 | 216 a 219 |

Para cada banda selecionada para análise, foram aplicadas as estatísticas RMS, ROP, MVD, *power law* e CFAR, bem como os filtros descritos no item 4.3.1. Em seguida, foi realizada a média para cada passada, cujos gráficos que apresentaram melhores resultados são exibidos a seguir.

#### 4.3.5.1 RMS

A estatística RMS foi calculada utilizando a Equação 5. As situações que apresentaram melhores resultados, baseado na tendência das curvas, foram: sem seleção de banda e bandas de 1 a 8. No entanto, para implementação da rede neural, foram utilizados apenas dois casos, a fim de comparação: sem seleção de banda e a melhor banda (banda 6), que são apresentados na Figura 4-12 e Figura 4-13, respectivamente.

Todas as outras figuras utilizando a estatística RMS são apresentadas no Apêndice A. Faixas com diferentes colorações foram utilizadas alternadamente nas figuras apenas para identificar os momentos em que a operação da dressagem foi interrompida para a captura das imagens, ou seja, de 20 em 20 passadas.

Figura 4-12 – Média das passadas RMS sem seleção de banda.

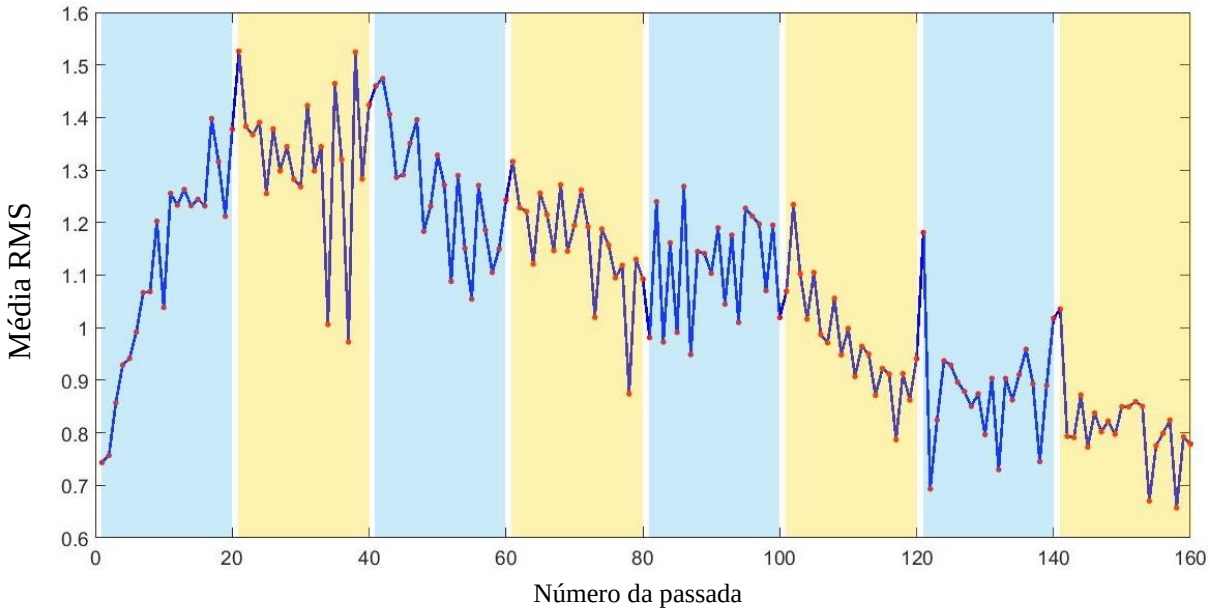
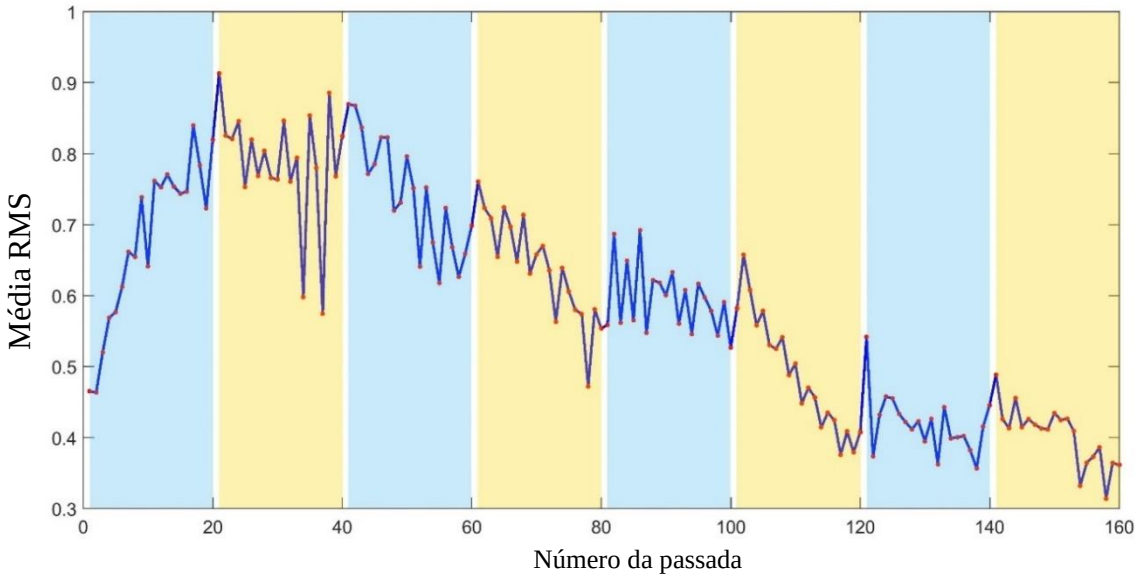


Figura 4-13 – Média das passadas RMS para a banda 6 (32 kHz a 34 kHz)




#### 4.3.5.2 ROP

A estatística ROP foi calculada utilizando a Equação 6. As situações que apresentaram melhores resultados, baseado na tendência das curvas, foram: sem seleção de banda e bandas de 4 a 6. No entanto, para implementação da rede neural, foi selecionada apenas a melhor banda: banda 6, que é apresentada na Figura 4-14. Todas as outras figuras utilizando a estatística ROP são apresentadas no Apêndice A.

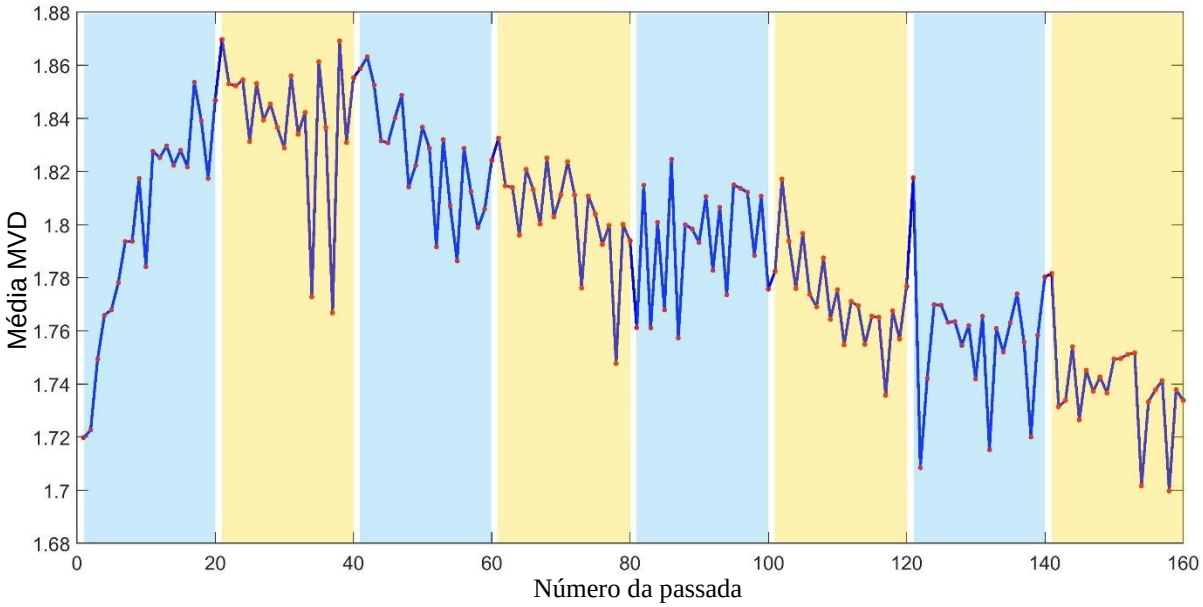
Figura 4-14 – Média das passadas ROP para a banda 6 (32 kHz a 34 kHz)



#### 4.3.5.3 MVD

A estatística MVD foi calculada utilizando a Equação 9 com 2048 pontos para a DFT sem seleção de banda. Já a estatística MVD com seleção de banda foi calculada utilizando 16384 pontos para a DFT. Esta mudança foi necessária quando há seleção de banda, pois, para menores valores, não é possível diferenciar, no sinal, o trecho de contato diamante-rebolo. Como o MVD com seleção de banda não apresentou resultados satisfatórios para alguns testes realizados, ele não foi calculado para todas as bandas. A Figura 4-15 apresenta a curva de médias para o MVD sem seleção de banda. O Apêndice A apresenta o gráfico de médias par ao MVD calculado na banda 6, o qual não apresentou resultado satisfatório. Para a rede neural, foi utilizado apenas a estatística MVD sem seleção de banda.

Figura 4-15 – Média das passadas MVD sem seleção de banda.

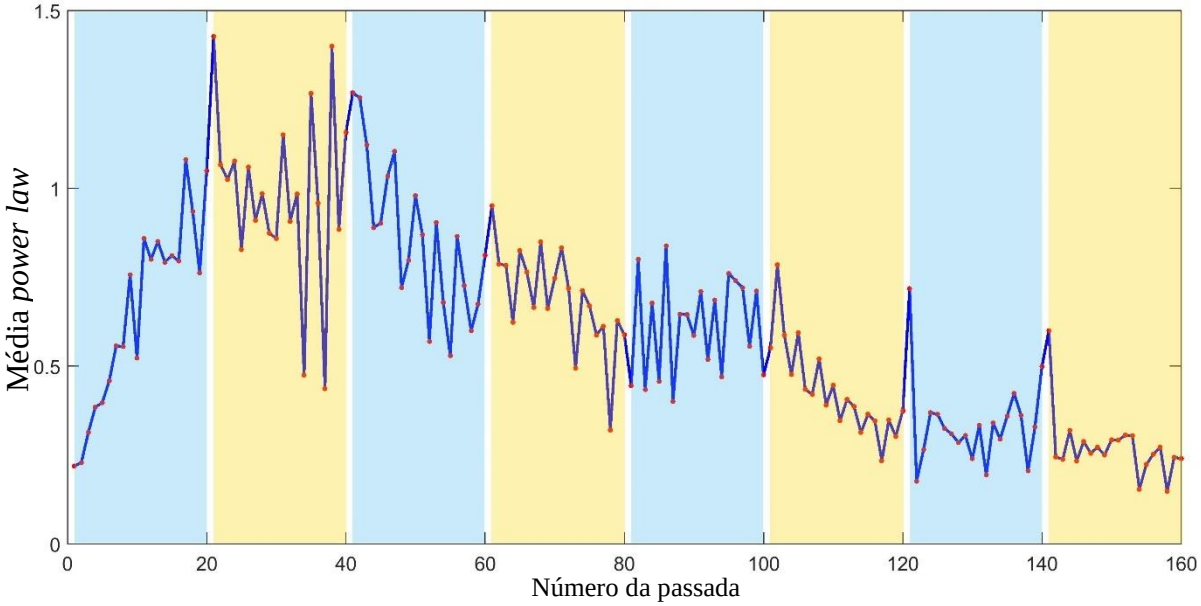



#### 4.3.5.4 POWER LAW

A estatística *power law* foi calculada utilizando a Equação 7. As situações que apresentaram melhores resultados, baseado na tendência das curvas, foram: sem seleção de banda e bandas de 1 a 6. No entanto, para a rede neural, foi considerada

apenas a estatística sem seleção de banda, a qual é apresentada na Figura 4-16. Todas as outras figuras utilizando a estatística *power law* são apresentadas no Apêndice A.

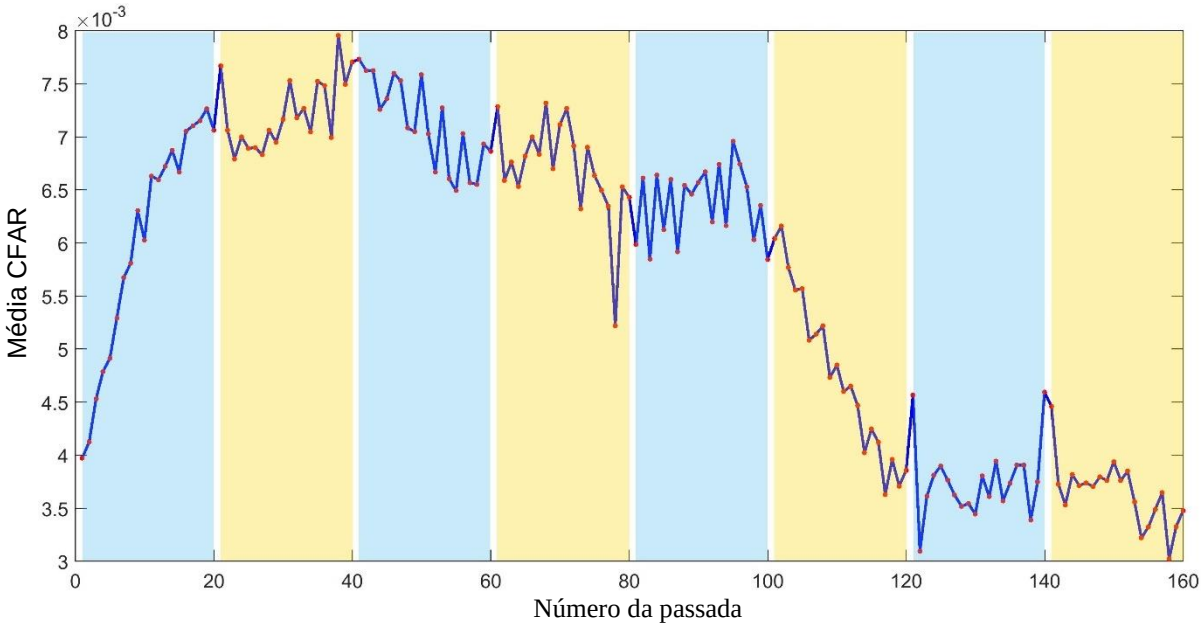
Figura 4-16 – Média das passadas *power law* sem seleção de banda.




#### 4.3.5.5 CFAR

A estatística CFAR foi calculada utilizando a Equação 8. A única situação que obteve resultado satisfatório para esta estatística foi sem seleção de banda, como é apresentado na Figura 4-17. Quando alguma banda foi selecionada, não foi possível observar uma tendência no decorrer das passadas e o gráfico de médias se mostrou caótico. Por isso, para a rede neural, esta estatística foi utilizada apenas sem seleção de banda. As figuras obtidas utilizando a estatística CFAR com seleção de bandas são apresentadas no Apêndice A.

Figura 4-17 – Média das passadas CFAR sem seleção de banda.



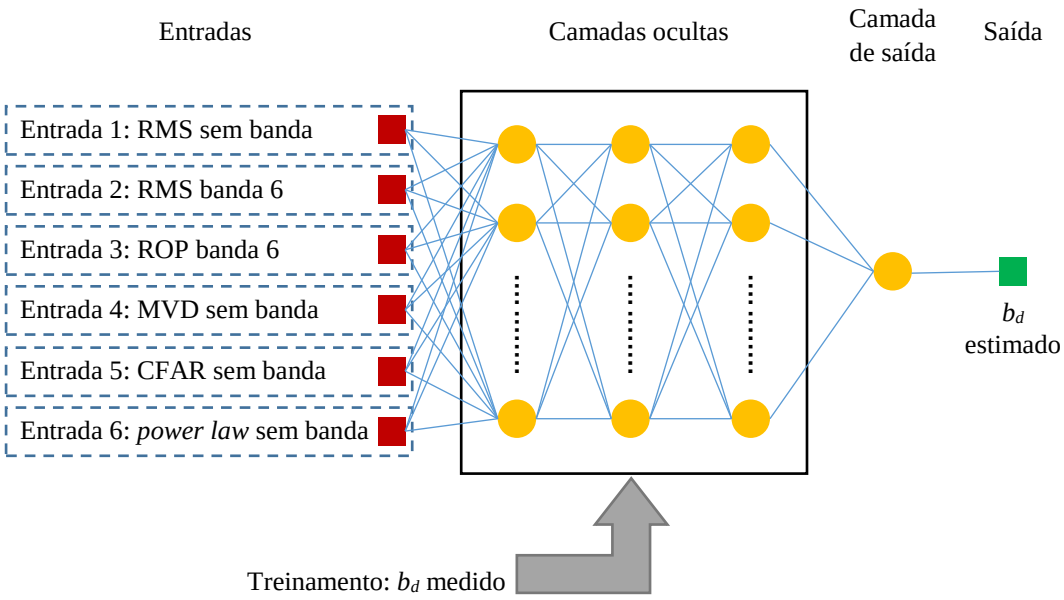

## 4.4 MODELOS NEURAIS

Para se obter os melhores modelos neurais, foram testadas diversas combinações de estruturas para as redes. Após organizar os resultados dos testes, selecionaram-se aqueles modelos que apresentaram o menor erro médio e desvio padrão para os cinco treinamentos do modelo.

### 4.4.1 REDE DE ESTIMAÇÃO

A rede neural de estimação teve como entradas os vetores de médias das melhores estatísticas obtidas no item 4.3.5. O vetor alvo da rede é o valor de $b_d$ apresentado na Figura 4-3 ao longo das 160 passadas. Sua saída é o vetor do $b_d$ estimado. A Figura 4-18 apresenta a estrutura da rede de estimação, representando suas entradas, o vetor alvo e sua saída.

Figura 4-18 – Estrutura geral da rede de estimação.




O treinamento da rede foi realizado alterando a quantidade de entradas ativas. Inicialmente, a rede foi treinada utilizando apenas 1 entrada por vez. O resultado da melhor rede foi anotado, como é exibido na primeira linha da Tabela 4-8. Em seguida, foram treinadas redes fazendo combinações das entradas duas a duas. O resultado da melhor rede para este caso é exibido na segunda linha da tabela. E assim por diante: considerando combinações das entradas três a três, quatro a quatro, cinco a cinco e, por fim, com todas as entradas ativas.

Após o treinamento de todas as redes, fazendo a combinação das entradas ativas de 1 a 6, foram observados os valores da regressão para os dados de ensaio e teste. A Tabela 4-8 apresenta os melhores resultados para cada quantidade de entradas ativas. Seu objetivo é verificar se há melhoria do resultado da rede quando é utilizado um maior número de entradas.

De acordo com a Tabela 4-8, é possível observar que, para as redes testadas com apenas 1 estatística de entrada, a melhor rede obtida foi a que utilizou a entrada 3 (ROP banda 6). A melhor topologia encontrada para esta rede possui apenas duas camadas ocultas, com 5 neurônios em cada uma delas. O valor da regressão representa o quanto a saída da rede se aproximou do valor alvo, sendo que uma regressão de 1,00000 indicaria que a saída é exatamente igual ao valor desejado, ou seja, um erro de 0%. As instruções utilizadas no MATLAB para a rede de estimação são apresentadas no Apêndice B.

Tabela 4-8 – Melhores RNAs para diferentes entradas ativas.

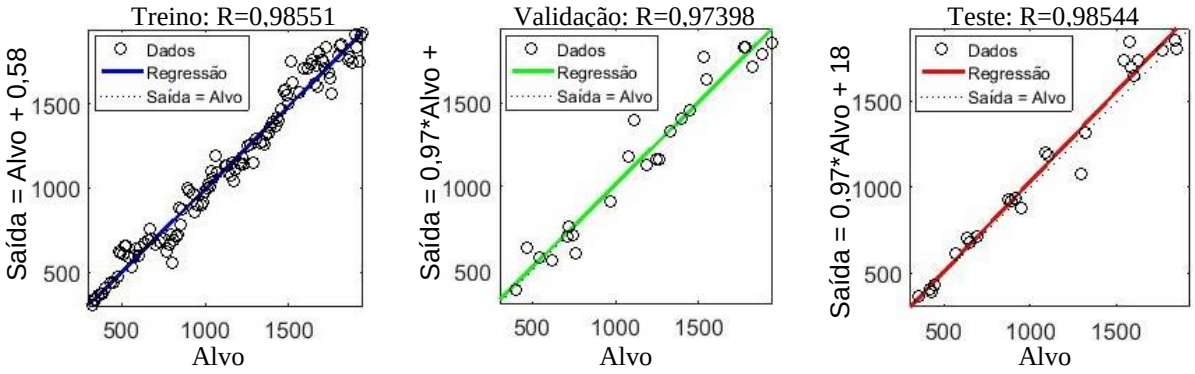
| Entradas ativas | Neurônios por camada oculta | Regressão de treino | Regressão de teste |
|---|---|---|---|
| 3 | 5, 5 e 0 | 0,93868 | 0,97111 |
| 3 e 5 | 10, 15 e 10 | 0,98551 | 0,98544 |
| 1, 3 e 5 | 5, 0 e 0 | 0,97829 | 0,98147 |
| 1, 3, 4 e 5 | 5, 5 e 20 | 0,98536 | 0,98829 |
| 1, 2, 3, 4 e 5 | 10, 10 e 20 | 0,98694 | 0,98740 |
| 1, 2, 3, 4, 5 e 6 | 10, 5 e 10 | 0,98654 | 0,98707 |

Além disso, pode-se observar que a melhor rede encontrada utilizou 4 entradas: 1 (RMS sem banda), 3 (ROP banda 6), 4 (MVD sem banda) e 5 (CFAR sem banda). A topologia para esta rede é de 10 neurônios na primeira camada oculta, 10 na segunda e 20 na terceira. O valor da regressão de treino é de 0,98536 e de teste é de 0,98829.

No entanto, observa-se que a diferença entre a melhor rede que utiliza 4 entradas com a melhor rede que utiliza 2 entradas é muito pequena, somente 0,0029 para regressão de teste. Por isso, para este trabalho, será optada pela rede de 2 entradas, tendo em vista a simplificação do modelo, já que o incremento de desempenho optando por mais entradas pode ser desprezado.

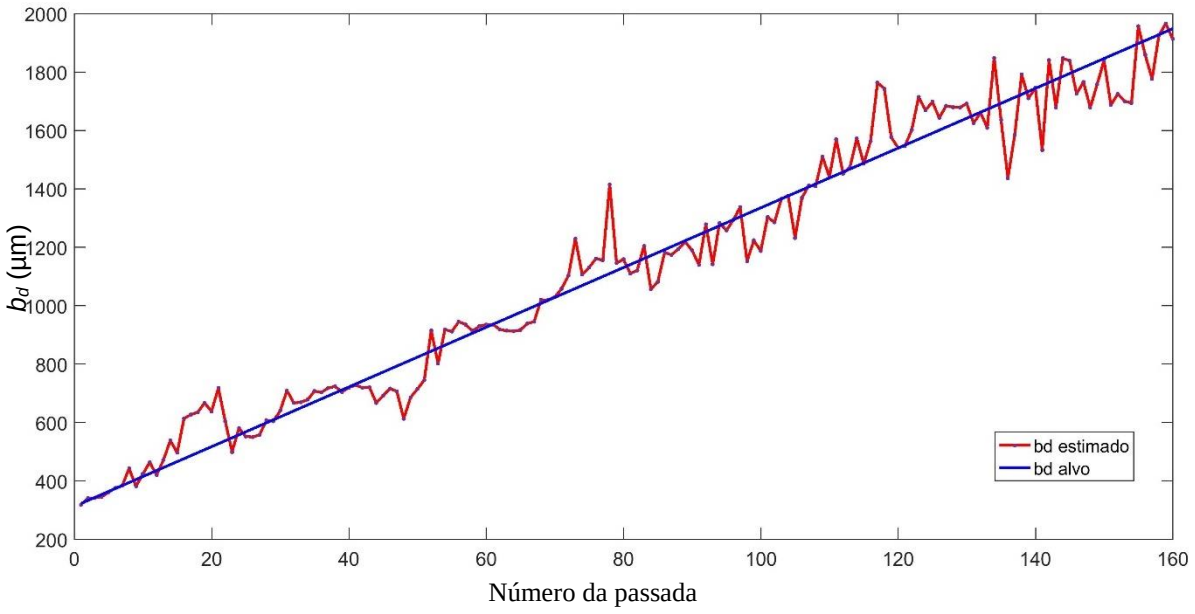
A RNA escolhida para estudo possui 2 entradas: entrada 3 (ROP banda 6) e entrada 5 (CFAR sem banda). A topologia desta rede é de 10 neurônios na primeira camada oculta, 15 na segunda e 10 na terceira. O valor da regressão de treino é de 0,98551, de validação é de 0,97398 e de teste é de 0,98544. A Figura 4-19 apresenta os gráficos de regressão para treino, validação e teste, respectivamente.

Figura 4-19 – Regressão para treino e teste da rede de estimação com 2 entradas.




A Figura 4-20 apresenta o gráfico da saída do $b_d$ estimado, em comparação com o $b_d$ desejado para a melhor rede neural de duas entradas (ROP banda 6 e CFAR sem banda).

Figura 4-20 – Saída da melhor rede neural de estimação com 2 entradas.

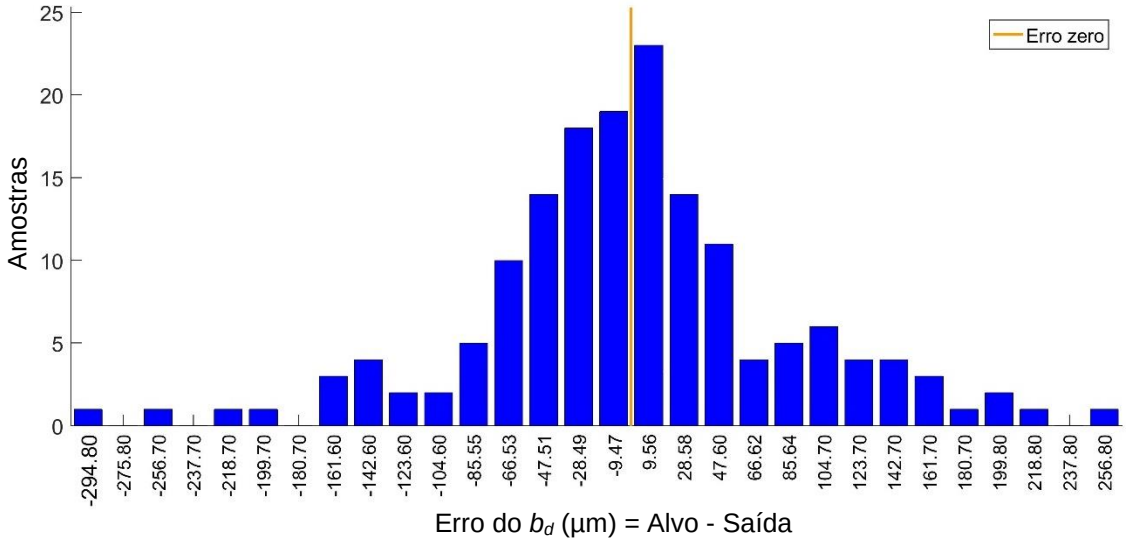



A partir de uma análise pontual da Figura 4-20, pode-se observar que alguns valores estimados se afastaram significativamente do valor real. A maior diferença entre o $b_d$ desejado e o $b_d$ estimado ocorreu na passada 78, tendo como valor 304,29 µm.

A Figura 4-21 apresenta o histograma de erro da rede de estimação de estudo. Nela, é possível observar a linha central vertical, que indica o erro zero. As

barras em azul indicam a quantidade de passadas que obtiveram os erros apresentados, indicados no eixo horizontal. A soma da quantidade de amostras deve ser igual a 160 passadas.

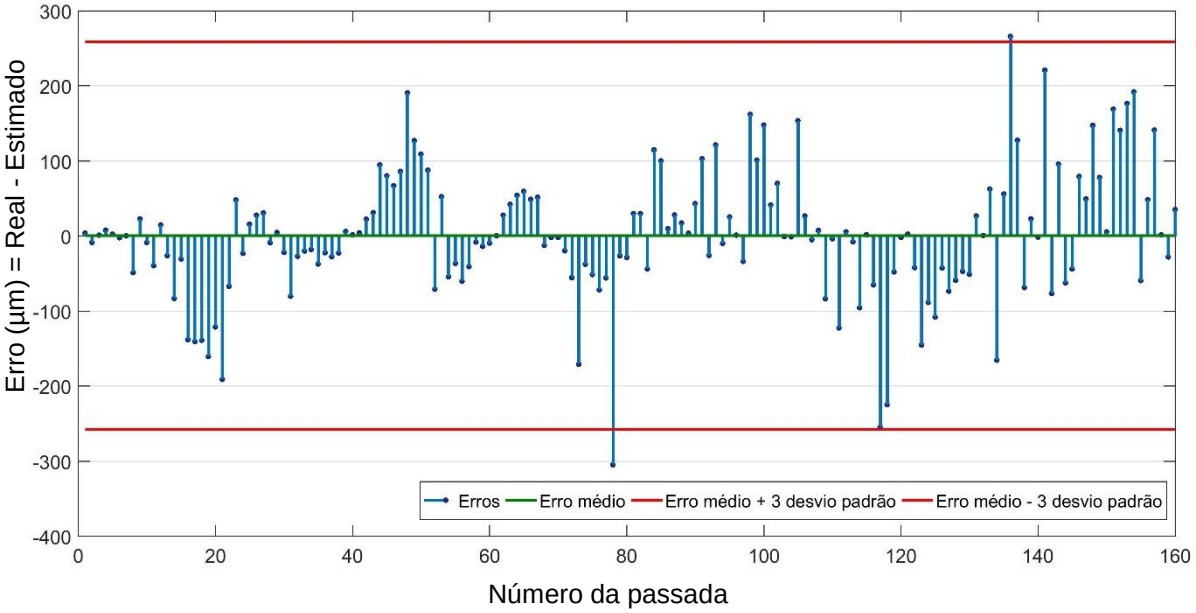
Figura 4-21 – Histograma de erro da melhor rede neural de estimação com 2 entradas.




A partir da Figura 4-21, pode-se observar que a maior parte das amostras se concentram próximas à linha de erro zero. Em uma condição ideal, todas as amostras se concentrariam sobre esta linha.

A Figura 4-22 apresenta os erros entre os valores estimados e os valores reais para o $b_d$. O erro médio observado é de 0,82 µm, o desvio padrão é de 86,05 µm e o erro varia de -304,30 µm a 266,30 µm.

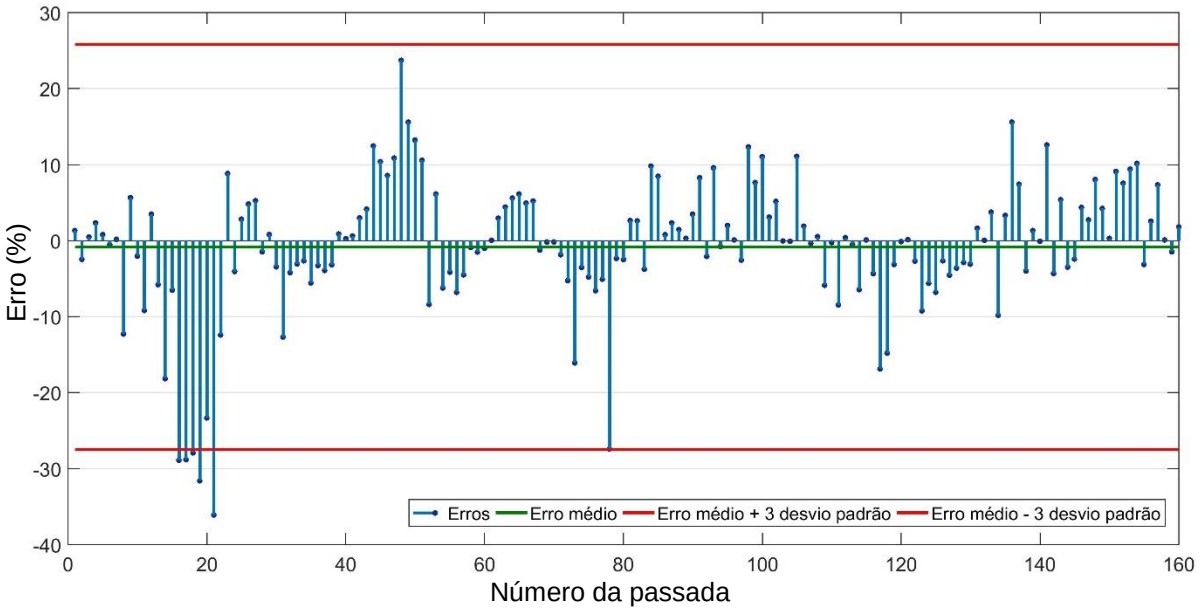
Figura 4-22 – Erros de estimação para o $b_d$.




Apesar de o desvio padrão ser baixo, existem dois pontos que excedem o limite de controle, que foi adotado como sendo o Erro ± 3σ. Isto demonstra que o método pode ser frágil para essas passadas e poderia ser necessário fazer alguns ajustes para um sistema com maior exatidão. No entanto, em uma análise lógica, esta metodologia é eficaz, pois o monitoramento da condição da ferramenta não é feito de forma pontual, mas sim através da evolução do $b_d$. Por isso, como a tendência do $b_d$ é apenas aumentar durante a evolução das passadas, o $b_d$ estimado para a situação de grande erro positivo (passada 136) não pode ser menor que os valores anteriores. Por isso, o sistema poderia ser programado para descartar automaticamente valores acima do limite superior de controle, os quais são impossíveis de acontecer. Por outro lado, valores estimados que estão abaixo do limite inferior de controle, como a passada 78, indicam que o $b_d$ possui um valor muito maior do que ele realmente possui. Isto não é um problema grave, pois mesmo considerando este valor de erro, a ferramenta não poderia ser descartada alegando-se como no final de sua vida útil, pois este valor ainda é muito menor do que a ferramenta na condição de desgastada.

A Figura 4-23 apresenta os mesmos erros da figura anterior, mas em forma de porcentagem em relação ao valor real.

Figura 4-23 – Erros de estimação em porcentagem para o $b_d$.




Nota-se que, no início das passadas, o erro em porcentagem se torna muito grande. Isto acontece porque a influência dos erros, mesmo sendo valores aceitáveis em micrometros, possuem um peso maior para valores mais baixos de $b_d$. Para passadas no final do ensaio, os erros são atenuados pelo valor do $b_d$ real, que é grande. O erro em porcentagem da estimação varia de -36,10% a 23,75%. O erro médio é de -0,82% e o desvio padrão é de 8,89%.

#### 4.4.1.1 CORRELAÇÃO DAS ENTRADAS COM A SAÍDA

Foi calculado o coeficiente de correlação entre as entradas e a saída da rede de estimação, a fim de identificar a força do relacionamento entre elas. A Tabela 4-9 apresenta o coeficiente de correlação entre cada entrada utilizada na rede com a saída (valor do $b_d$).

A partir da Tabela 4-9, pode-se observar que o maior coeficiente de correlação obtido se refere à entrada 3 (ROP banda 6). De fato, pela Tabela 4-8, observa-se que a melhor rede neural obtida com 1 entrada utilizou a entrada 3. Por outro lado, a entrada 6 apresentou o menor coeficiente de correlação e foi a útima entrada a aparecer no resultado das melhores redes.

Tabela 4-9 – Correlação para cada entrada utilizada na RNA.

| Entrada | Coeficiente de correlação |
|---|---|
| 1 | 0,49 |
| 2 | 0,69 |
| 3 | 0,86 |
| 4 | 0,49 |
| 5 | 0,59 |
| 6 | 0,48 |

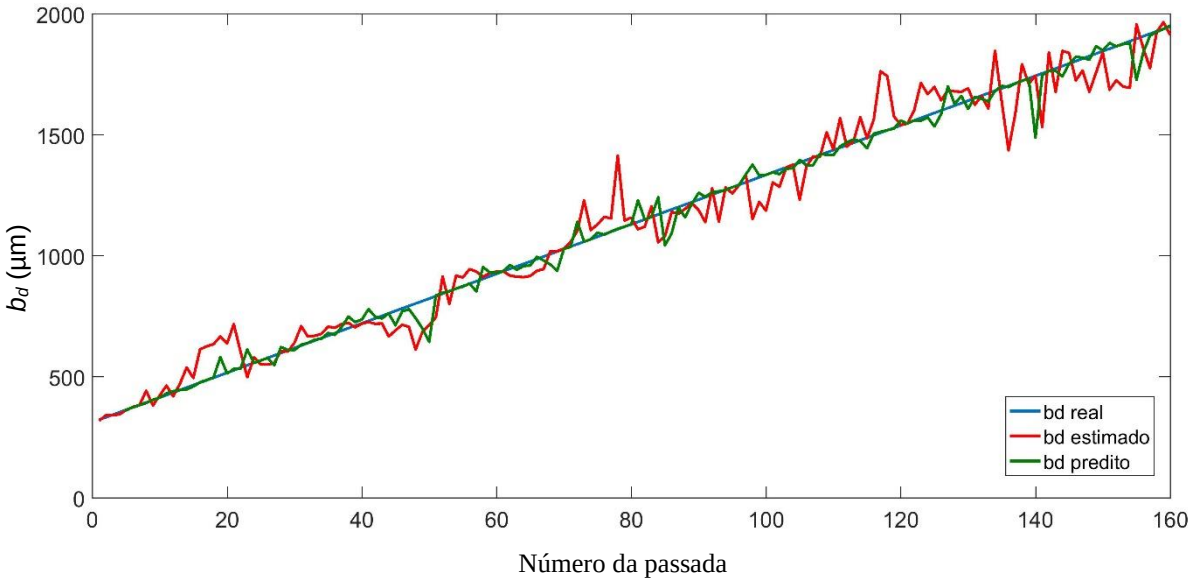
Sabe-se que, quanto mais o coeficiente de correlação se aproxima de 1, maior é a correlação entre a entrada e a saída, ou seja, a saída está, de alguma forma e com diferentes pesos, relacionada com a entrada. Por isso, pode-se afirmar que alterações no valor das entradas (variáveis independentes) provocam alterações no valor da saída (variável dependente).

### 4.4.2 REDE DE PREDIÇÃO

A melhor rede TDNN encontrada possui 15 neurônios na primeira camada oculta, 15 na segunda e 10 na terceira. As linhas de comando utilizadas no MATLAB são apresentadas no Apêndice C. A Figura 4-24 apresenta o melhor resultado da rede de predição, junto com a rede de estimação escolhida anteriormente e o valor real do $b_d$ medido. O gráfico de estimação foi mesclado ao de predição para um melhor entendimento global do processo de predição e para poder comparar o comportamento de ambas as redes. Na rede de predição, foi utilizada uma janela de 4 elementos, ou seja, o algoritmo utiliza 4 elementos para predizer o seguinte.

O valor real do $b_d$ é apresentado em azul, que é a mesma curva apresentada na Figura 4-3. O valor estimado é apresentado em vermelho, que é a mesma curva apresentada na Figura 4-20 para a rede *feedforward* de 2 entradas (ROP sem banda e CFAR). O valor predito pela rede TDNN um passo à frente é apresentado em verde.

Figura 4-24 – Valores de $b_d$ estimado e predito, em comparação com os reais.




Da Figura 4-24 é possível observar que os valores preditos, em verde, ficaram, na maior parte do tempo, entre os outros dois valores, real e estimado, indicando uma boa correlação entre ambos. Além disso, a rede de estimação apresentou picos maiores, se distanciando mais do valor real do que a rede de predição.

A Tabela 3-1 apresenta os primeiros valores dos $b_d$'s observados na figura anterior. Pode-se observar que uma janela de 4 passadas foi utilizada para o predizer o valor da passada seguinte. Ou seja, os valores das passadas de 1 a 4, predizeram a passada 5; os valores das passadas de 2 a 5 predizeram a passada 6; e assim por diante. Os erros obtidos entre o valor predito com o valor real são desprezíveis.

Tabela 4-10 – Valores dos $b_d$'s das redes.

| Passada | Entrada $b_d$ estimado | Alvo $b_d$ real | Saída $b_d$ predito | Erro (%) |
|---|---|---|---|---|
| 1 | 319,19 | 323,53 | – | – |
| 2 | 342,02 | 333,75 | – | – |
| 3 | 342,32 | 343,98 | – | – |
| 4 | 345,91 | 354,20 | – | – |
| 5 | 361,48 | 364,43 | 364,51 | 0,00% |
| 6 | 376,53 | 347,65 | 374,47 | -0,08% |
| 7 | 384,09 | 384,87 | 383,43 | 0,01% |
| 8 | 443,51 | 395,09 | 392,93 | 0,01% |
| 9 | 382,39 | 405,32 | 406,36 | -0,01% |
| | ⋮ | ⋮ | ⋮ | ⋮ |

Os valores obtidos para a regressão da rede de predição foram 0,99969 para treinamento, 0,98940 para validação e 0,98195 para teste, conforme é apresentado na Figura 4-25.

Nota-se que o valor da regressão obtido para o treino se aproximou fortemente de 1. Os dados de saída estão muito próximos dos valores alvo. A regressão para o teste também apresentou resultados satisfatórios. A Figura 4-26 apresenta o histograma de erro para a rede de predição.

A Figura 4-27 apresenta os erros entre os valores preditos um passo à frente e os valores reais para o $b_d$. O erro médio observado é de 5,11 µm, o desvio padrão é de 40,61 µm e o erro varia de -92,03 µm a 254,73 µm.

Figura 4-25 – Regressão para treinamento e teste para a rede de predição.

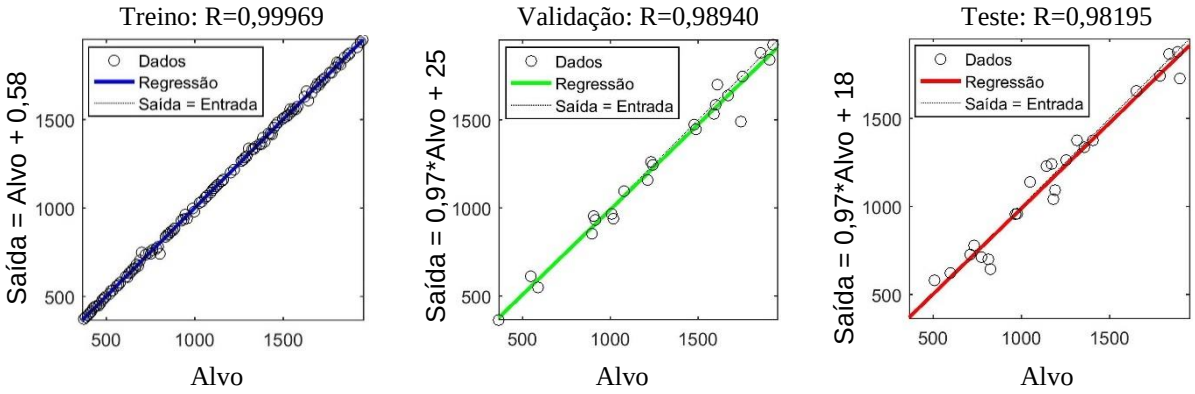



Figura 4-26 – Histograma de erro da melhor rede de predição.

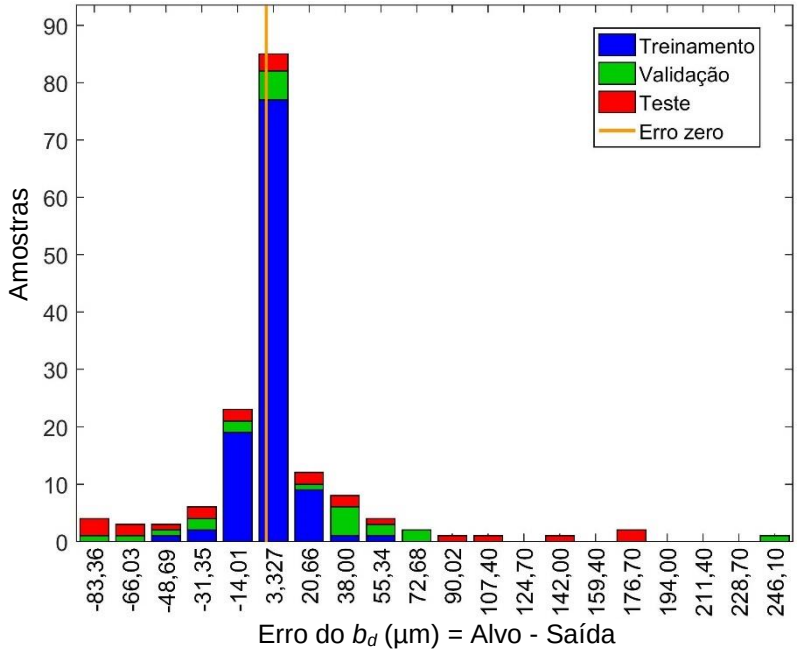
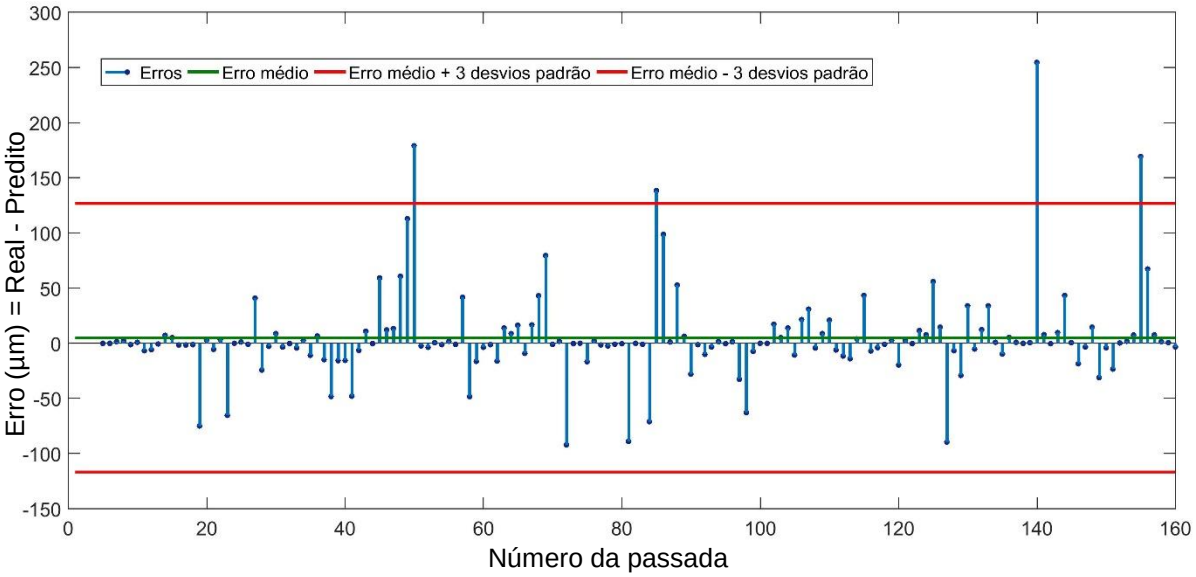


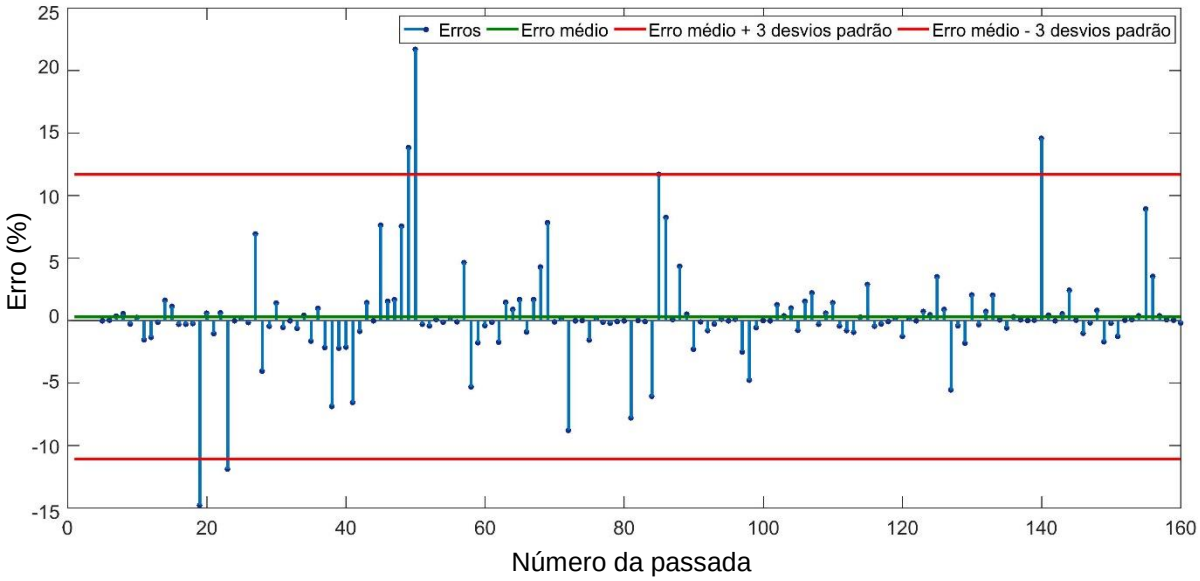
Figura 4-27 – Erros de predição para o $b_d$.




Apesar de o desvio padrão ser baixo, existem quatro pontos que excedem o limite de controle, que foi adotado como sendo o Erro ± 3σ. Isto demonstra que o método pode ser frágil para essas passadas e poderia ser necessário fazer alguns ajustes para um sistema com maior exatidão. No entanto, em uma análise lógica, esta metodologia é eficaz, pois o monitoramento da condição da ferramenta não é feito de forma pontual, mas sim através da evolução do $b_d$. Por isso, como a tendência do $b_d$ é apenas aumentar durante a evolução das passadas, o $b_d$ predito para essas situações de grandes erros não pode ser menor que os valores anteriores. Por isso, o sistema poderia ser programado para descartar automaticamente valores acima do limite de controle, os quais são impossíveis de acontecer.

A Figura 4-28 apresenta os mesmos erros da figura anterior, mas em forma de porcentagem em relação ao valor estimado.

Figura 4-28 – Erros de predição em porcentagem para o $b_d$.




Nota-se que, em alguns pontos, o erro fica fora dos limites de controle. No entanto, os erros da predição foram muito menores que os erros observados na estimação. O erro da rede de predição varia de -14,77% a 21,73%. O erro médio é de 0,31% e o desvio padrão é 3,81%.

# 5 CONCLUSÃO

Um comparativo entre os dois modelos de redes neurais, tanto de estimação como de predição, mostrou que os valores estimados se distanciaram mais dos valores reais, quando comparados aos valores preditos, que pode ser constatado pelo maior desvio padrão nos erros dos valores estimados.

Os erros encontrados nas redes neurais apresentaram dispersões que oscilaram em todo o campo de controle. Em alguns pontos, ultrapassaram os limites superior e inferior. No entanto, os valores de erros médios ficaram próximos a zero, indicando a centralidade do método.

A aplicação deste processo para o monitoramento da largura de atuação do dressador mostrou bons resultados, visto que os limites estabelecidos de controle foram excedidos em locais pontuais, tanto para as redes de estimação, como para as redes de predição.

No entanto, alguns ajustes nas redes podem ser realizados em trabalhos futuros, a fim de reduzir os erros percentuais de estimação e predição que foram observados em alguns pontos. Outras entradas poderiam ser utilizadas com a finalidade de verificar a correlação com a saída, outras topologias de redes neurais poderiam ser testaas, assim como a aplicação outros tipos de redes, como a realimentada em cascata, aplicação de processos de otimização, entre outras ferramentas.

A predição da largura de atuação do dressador se mostrou com um alto potencial através do método apresentado neste trabalho. O processo industrial poderia se beneficiar fortemente com um sistema que apresenta o valor da largura de atuação do dressador um passo à frente, evitando o uso indevido de dressadores após o final de sua vida útil ou o descarte de dressadores que ainda poderiam ser utilizados. Desta forma, elimina-se a responsabilidade dos operários das máquinas sobre a decisão da condição das ferramentas, evitando que falhas humanas ocorram.

O método apresentado neste trabalho é importante para aplicação para o qual foi proposto, apesar dos erros observados. Para o objetivo apresentado, os resultados foram satisfatórios, pois seria possível predizer a largura de atuação do

dressador de forma a identificar a situação em que se encontra a ferramenta. No entanto, para um sistema mais preciso, o método deveria ser aprimorado a fim de melhorar o desempenho das redes neurais em alguns pontos.

No entanto, é importante salientar que o diamante utilizado foi do tipo natural. Isto provocou no sinal de EA variações de amplitude em algumas passadas que se diferencivam em excesso das passadas adjascentes. Isto foi observado já durante os ensaios, pois em momentos em que o diamante sofria uma micro-fratura, o sinal monitorado em tempo real sofria fortes influências. Para diamantes sintéticos, pode-se esperar um sinal mais comportado, pois a geometria do diamante tende a ser simétrica e sua composição uniforme.

## REFERÊNCIAS

AGARWAL; SANJAY. 2016. “Optimizing Machining Parameters to Combine High Productivity with High Surface Integrity in Grinding Silicon Carbide Ceramics.” *Ceramics International* 42(5): 6244–62.

AGUIAR, P. R. *et al*. 2009. “Monitoring the Dressing Operation in the Grinding Process.” *International Journal of Machining and Machinability of Materials* 5(1): 3–22.

AKBARI; MANSUR; BUHL; LEINENBACH, S.; WEGENER, K. 2016. “A New Value for Johnson Cook Damage Limit Criterion in Machining with Large Negative Rake Angle as Basis for Understanding of Grinding.” *Journal of Materials Processing Tech.* 234: 58–71.

BADGER; JEFFREY; MURPHY, S.; ODONNELL, G. 2011. “The Effect of Wheel Eccentricity and Run-out on Grinding Forces, Waviness, Wheel Wear and Chatter.” *International Journal of Machine Tools and Manufacture* 51(10–11): 766–74.

BARROS, B. G. *et al*. 2014. “Utilization of Teflon and Aluminum Oxide for Wheel Cleaning in Minimum Quantity Lubrication ( MQL ) Grinding 2 . Theoretical Background.” 17(1): 23–32.

BENMAHDJOUB; KHALIDA; AMEUR, Z.; BOULIFA, M. 2013. “Forecasting of Rainfall Using Time Delay Neural Network in Tizi-Ouzou ( Algeria ).” *Energy Procedia* 36: 1138–46.

BIANCHI, E. C. *et al*. 1996. “Análise Do Comportamento de Rebolos Convencionais Na Retificação de Aços Dúcteis.” In Recife - PE: IV CONGRESSO NORTE NORDESTE DE ENGENHARIA MECÂNICA, 387–92.

BRAGA, A. P.; LUDERMIR, T. B.; CARVALHO, A. C. P. F. L. 2000. *Redes Neurais Artificiais Teoria E Aplicações*. LTC.

D’ADDONA, D. M. *et al*. 2016. “Neural Networks Tool Condition Monitoring in Single-Point Dressing Operations.” *Procedia CIRP* 41: 431–36.

DINIZ, A. E.; MARCONDES, F. C.; COPPINI, N. L. 2010. *Tecnologia Da Usinagem Dos Materiais*. 4th ed. Campinas: Artiliber Editora Ltda.

DODONOV, E.; MELLO, R. F. 2008. “Predição Por Meio de Atrasos No Tempo: TDNN for Estudo Sobre Abordagens de Extração, Classificação E Predição de Comportamento de Processos.” ICMC/USP.

DROUILLET, C. *et al*. 2016. “Tool Life Predictions in Milling Using Spindle Power with the Neural Network Technique.” *Journal of Manufacturing Processes* 22: 161–68.

FERREIRA, A. A. 2004. “Comparação de Arquiteturas de Redes Neurais Para Sistemas de Reconhecimento de Padrões Em Narizes Artificiais.” Universidade Federal de Pernambuco, UFPE.

GRAF, W. 2004. *Cylindrical Grinding*. WST Winterthur Schleiftechnik AG, Suíça 87.

HARIMKAR, S. P. 2006. “Prediction of Solidification Microstructures During Laser Dressing of Alumina Based Grinding Wheel Material.” *Journal Physics* 39: 1642–49.

HARTMANN, F. R. 2002. *Redes Neurais, Conceitos Básicos E Análise*. Universidade do Vale do Rio dos Sinos - UNISINOS - RS.

HASSUI, A; DINIZ, A. E. 2003. “Correlating Surface Roughness and Vibration on Plunge Cylindrical Grinding of Steel.” *International Journal of Machine Tools & Manufacture* 43: 855–62.

HAYKIN, S. 1999. *Neural Networks: A Comprehensive Foundation*. 2ª ed. Pearson Prentice Hall.

HEINZEL, C.; RICKENS, K. 2009. “Engineered Wheels for Grinding of Optical Glass.” *CIRP Annals - Manufacturing Technology* 58: 315–18.

HUANG, S. 1994. “Artificial Neural Networks in Manufacturing: Concepts, Applications and Perspectives.” *Manufacturing Technology* 17: 212–28.

INASAKI, I.; OKAMURA, K. 1985. “Monitoring of Dressing and Grinding Processes with Acoustic Emission Signals.” *CIRP Annals - Manufacturing Technology1* 34: 277–80.

JACKSON, M. J. 2007. “Laser Cleaning and Dressing of Vitrified Grinding Wheels.” *Journal of Materials Processing Technology* 185: 17–23.

KARPUSCHEWSKI, B.; WEHMEIER, M.; INASAKI, I. 2000. “Grinding Monitoring System Based on Power and Acoustic Emission Sensors.” *CIRP Annals - Manufacturing Technology* 49(1): 235–40.

KING, R. I.; HAHN, R. S. 1992. *Handbook of Modern Grinding Technology*. 3rd ed. New York.

KOHONEN, T. 1988. *An Introduction to Neural Computing*. Neural Networks, Vol 1. pp. 3-16.

KONIG, W.; KLOCKE, F. 1996. Fertigungsverfahren Band 2. Schleifen, Honen, Läppen. 3. Auflage, VDI-Verlag GmbH, Düsseldorf.

KUMAR; ANUJ; KUMAR, A.; RAI, A. 2016. “Effects of Minimum Quantity Lubrication ( MQL ) in Machining Processes Using Conventional and Nano Fl Uid Based Cutting Fl Uids : A Comprehensive Review.” *Journal of Cleaner Production* 127: 1–18.

KWAK; SEOB, J.; HA, M. K. 2004. “Neural Network Approach for Diagnosis of Grinding Operation by Acoustic Emission and Power Signals.” *Journal of Materials Processing Technology* 147(1): 65–71.

LEE, D. E. 2006. “Precision Manufacturing Process Monitoring with Acoustic

Emission.” *International of Tools and Manufacture* 46: 175–88.

LIAO, T. W. 2007. “A Wavelet-Based Methodology for Grinding Wheel Condition Monitoring.” *International Journal of Machine Tools & Manufacture* 47: 580–92.

LIN, S. Y.; LIU, Y. C.; HUAN, C. W. 2008. “An Investigation of Surface Grinding Characteristics for Titanium Alloy with CBN Wheel.” *Key Engineering Materials* 364–366: 237–42.

LINKE, B. 2008. “Dressing Process Model for Vitrified Bonded Grinding Wheels.” *CIRP Annals - Manufacturing Technology* 57(1): 345–48.

MALKIN, S.; GUO, C. 2007. “Thermal Analysis of Grinding.” *CIRP Annals - Manufacturing Technology* 56(2): 760–82.

MALKIN, S.; GUO, C. 2008. *Grinding Technology: Theory and Applications of Machining with Abrasives*. 2ª ed. New York: Industrial Press Inc.

MARINESCU, I. D. 2004. *Tribology of Abrasive Machining Processes*. 1st ed. Norwich: William Andrew Inc.

MARINESCU, I. D.; HITCHINER M.; UHLMANN, E.; ROWE, W. B. 2007. *Handbook of Machining with Grinding Wheels*. 1st ed. New York: CRC Press.

MARTINS, C. H. R.; AGUIAR, P. R.; FRECH, A.; BIANCHI, E. C. 2014. “Tool Condition Monitoring of Single-Point Dresser Using Acoustic Emission and Neural Networks Models.” *IEEE Transactions on Instrumentation and Measurement* 63(3): 667–79.

MIRANDA, H. I. *et al*. 2015. “Monitoring Single-Point Dressers Using Fuzzy Models.” In *9th CIRP Conference on Intelligent Computation in Manufacturing Engineering*, Elsevier B.V., 281–86.

MOIA, D. F. G. *et al*. 2015. “Tool Condition Monitoring of Aluminum Oxide Grinding Wheel in Dressing Operation Using Acoustic Emission and Neural Networks.” *Journal of the Brazilian Society of Mechanical Sciences and Engineering* 63(3): 627–40.

MOLAIE, M. M.; AKBARI, J.; MOVAHHEDY, M. R. 2016. “Ultrasonic Assisted Grinding Process with Minimum Quantity Lubrication Using Oil-Based Nanofluids.” *Journal of Cleaner Production* 129: 212–22.

MORETTIN, L. G. 1999. *Estatistica Básica - Probabilidade E Inferencia*. MAKRON.

MUÑOZ, L. A. B. 2009. “Learning in Feed-Forward Artificial Neural Networks.” *Encyclopedia of Artificial Intelligence* II: 1004–11.

NEGNEVITSKY, M. 2005. *Artificial Intelligence: A Guide to Intelligent Systems*. 2nd ed. Harlow: Addison-Wesley.

NILSSON, J. W.; RIEDEL, S. A. 2016. *Circuitos Elétricos.* 10nd ed. São Paulo: Pearson Prentice Hall. 816p.

OLIVEIRA, J. F. G.; BIANCHI, E. C. 1992. “Grinding Process Dominance by Means of the Dressing Operation.” In *Twenty - Ninth International Matador Conference.*, , 547–50.

DURGUMAHANTI, U. S. P., SINGH, V.; RAO, P. V. 2010. “A New Model for Grinding Force Prediction and Analysis.” *International Journal of Machine Tools and Manufacture* 50(3): 231–40.

QUAN, Y.; ZHOU, M.; LUO, Z. 1998. “On-Line Robust Identi ® Cation of Tool-Wear via Multi-Sensor Neural- Network Fusion.” 11: 717–22.

REN, Y. H.; ZHANG, B.; ZHOU, Z. X. 2009. “Specific Energy in Grinding of Tungsten Carbides of Various Grain Sizes.” *CIRP Annals - Manufacturing Technology* 58: 299–302.

SALEH, T.; BISHWAS, I.; RAHMAN, M. 2009. “Efficient Dressing of the Wheel in ELID Grinding by Controllable Voltage with Force Feed Back.” *International Journal of Machine Tools & Manufacture*.

SALMON, S. C. 1992. *Modern Grinding Process Technology.* MacGraw-Hill.

SARIKAYA; MURAT; GULLU, A. 2014. “Taguchi Design and Response Surface Methodology Based Analysis of Machining Parameters in CNC Turning under MQL.” *Journal of Cleaner Production* 65: 604–16.

STEMMER, C. E. 1992. *Ferramentas de Corte II: Brocas, Alargadores, Ferramentas de Roscas, Fresas, Brochas, Rebolos E Abrasivos*. Florianópolis: Editora da UFSC.

TETI, R.; JEMIELNIAK, K.; O’DONNELL, G.; DORNFELD, D. 2010. “Advanced Monitoring of Machining Operations.” *CIRP Annals - Manufacturing Technology* 59: 717–39.

TUAN; ANH; LEE, D. 2008. “Correlation of Grinding Wheel Topography and Grinding Performance : A Study from a Viewpoint of Three-Dimensional Surface Characterisation.” *Journal of Materials Processing Technology* 8(1995): 14–23.

WAIBEL, A. *et al*. 1989. “Phonemic Recognition Using Time Delay Neural Networks.” *IEEE Trans, Acoust, Speech, Signal Processing* 37(3): 328–39.

WANG, J. Z. 2005. “Prediction of Surface Roughness Cylindrical Traverse Grinding Based on ALS Algoritm.” *Proceedings of the Fourth Internacional Conference on Machine Learning and Cybernetics.*: 549–54.

WANG, Y. *et al*. 2016. “Experimental Evaluation of the Lubrication Properties of the Wheel / Workpiece Interface in MQL Grinding with Different Nanofluids.” *Tribiology International* 99: 198–210.

WANG, Z.; WILLETT, P; AGUIAR, P. R.; WEBSTER, J. A. 2001. “Neural Network Detection of Grinding Burn from Acoustic Emission.” *International Journal of Machine Tools and Manufacture* 41(2): 283–309.

WEBSTER, J. A. 2007. “Coolant Calculus: Directing Coolant into the Right Place at the Right Speed, in the Right Quantity.” *Cutting Tool Technology* 60(2): 58–66.

WEGENER, K. *et al*. 2011. “Conditioning and Monitoring of Grinding Wheels.” *CIRP Annals - Manufacturing Technology* 60(2): 757–77.

WILLIAMS, J. C.; LEACH, M. F.; RUBIN, G. A. 1978. "Particle Size Distribution Characterization from Acoustic Emissions". *Powder Technology* 19: 157-167.

XUE, L.; NAGHDY, F.; COOK, C. 2002. “Monitoring of Wheel Dressing Operation for Precision Grinding.” In *FIEEE International Conference on Industrial Technology*, , 1296–99.

YANG, J. F.; CHEN, F. K. 2002. “Recursive Discrete Fourier Transform with Inified IIR Filter Structures.” *Signal Processing* 82: 31–41.

ZHOU; HONG, J.; PANG, C. K.; ZHONG, Z. W.; LEWIS, F. L. 2011. “Tool Wear Monitoring Using Acoustic Emissions by Dominant-Feature Identification.” *IEEE Transactions on Instrumentation and Measurement* 60(2): 547–59.

# APÊNDICES

# APÊNDICE A – Médias das Estatísticas

Várias estatísticas foram calculadas para o sinal de emissão acústica: RMS, ROP, MVD, CFAR e *power law*. Cada uma das estatísticas foi calculada utilizando as bandas que foram selecionadas, as quais foram apresentadas na Tabela 4-7. No entanto, nem todas as estatísticas foram calculadas para todas as bandas.

Este apêndice apresenta os gráficos das médias das estatísticas para as diversas bandas que não foram utilizadas nas redes neurais. Muitas delas apresentaram um resultado interessante, podendo ser testadas em trabalhos futuros. Já outras não apresentaram uma tendência clara, resultando em valores caóticos que não são de interesse.

As bandas selecionadas que apresentaram um bom resultado para estudo foram:

- RMS: bandas de 4 a 7 e sem banda;
- ROP: bandas de 5 a 6 e sem banda;
- MVD: se apresentou interessante apenas sem seleção de banda;
- CFAR: se apresentou interessante apenas sem seleção de banda;
- *Power law*: bandas de 4 a 6 e sem banda.

Figura A-1 – Média das passadas RMS para a banda 1 (21 kHz a 25 kHz).

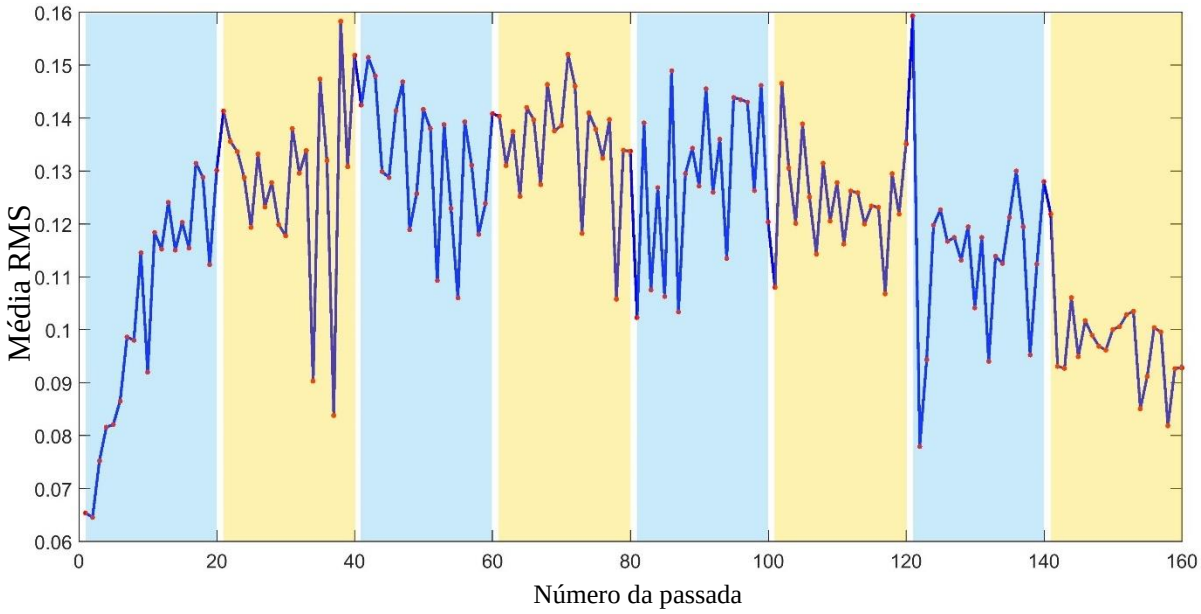


Figura A-2 – Média das passadas RMS para a banda 2 (24 kHz a 29 kHz).

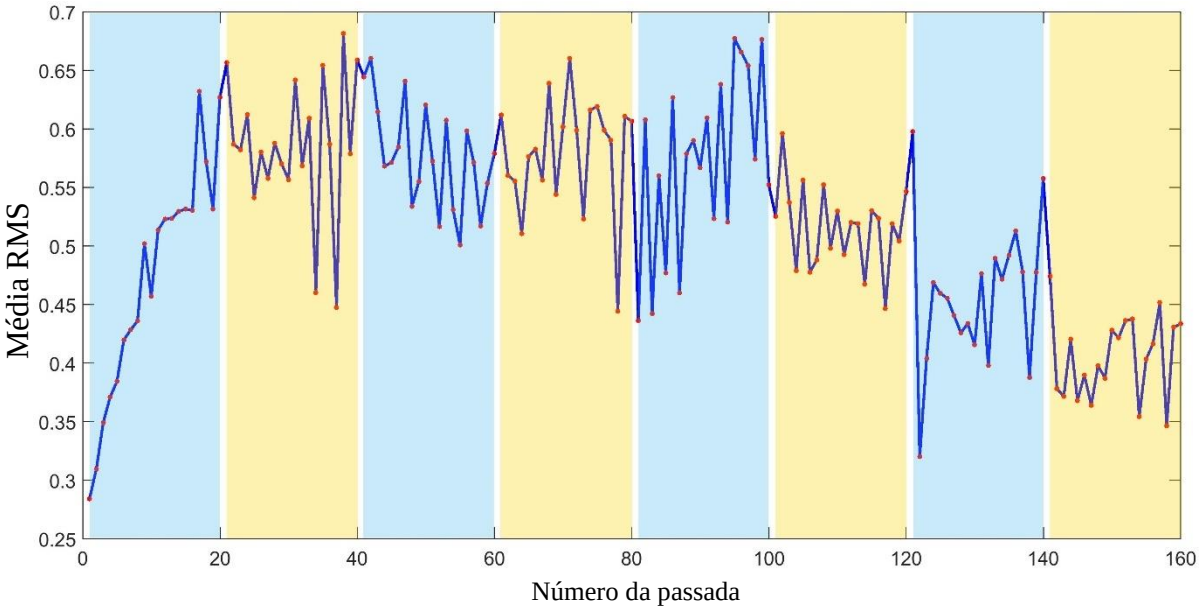



Figura A-3 – Média das passadas RMS para a banda 3 (25 kHz a 30 kHz).

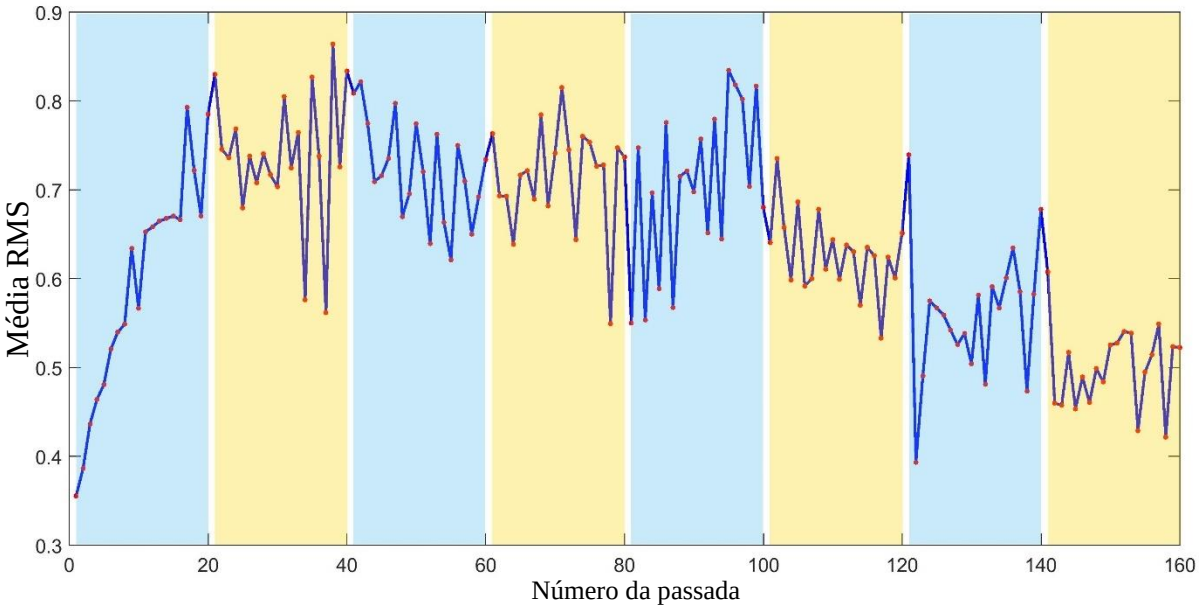


Figura A-4 – Média das passadas RMS para a banda 4 (29 kHz a 32 kHz).

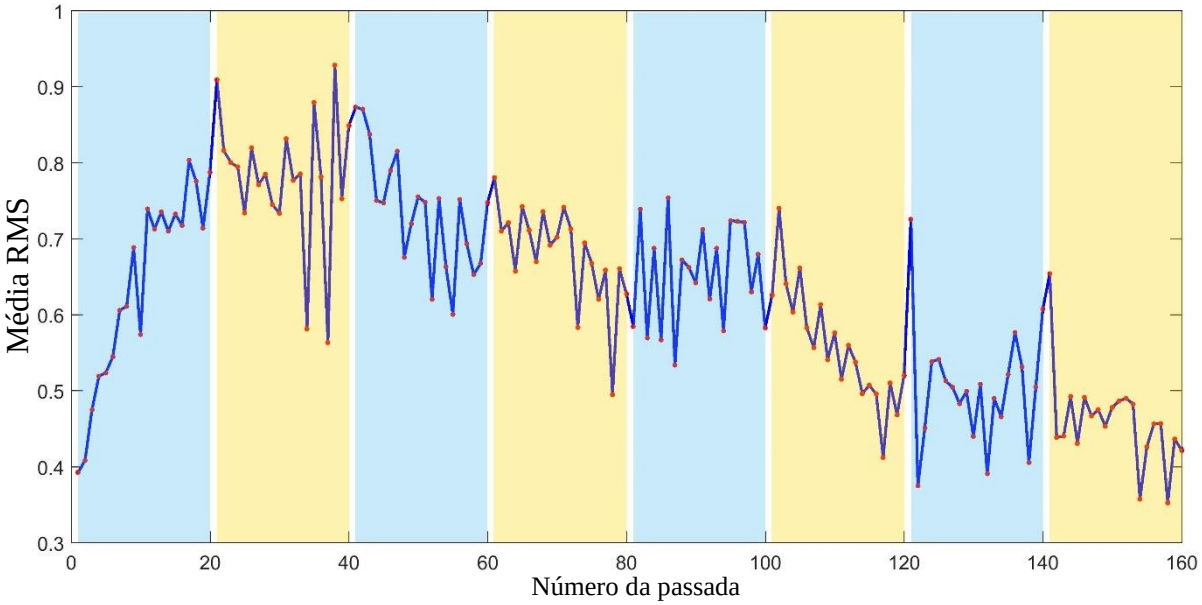



Figura A-5 – Média das passadas RMS para a banda 5 (30 kHz a 34 kHz).

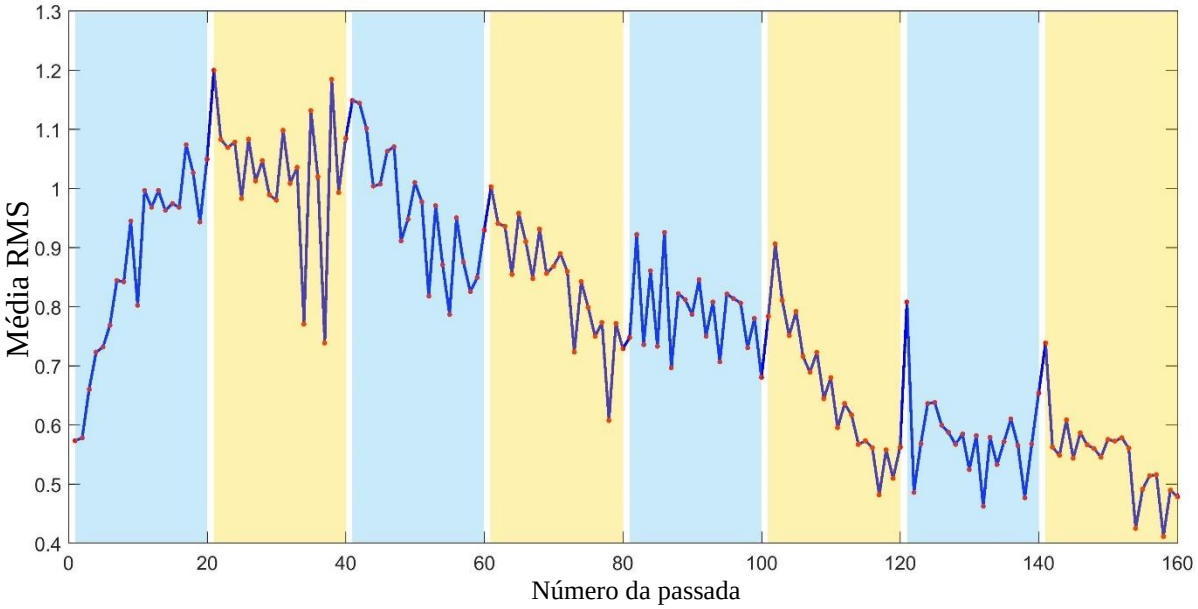


Figura A-6 – Média das passadas RMS para a banda 7 (41 kHz a 44 kHz).

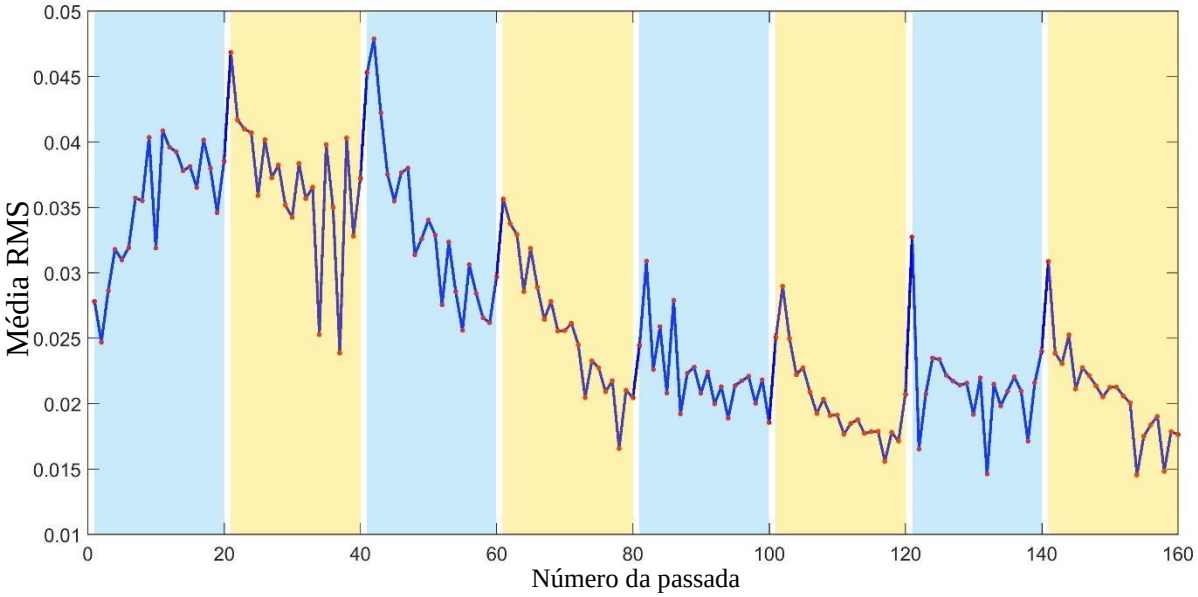



Figura A-7 – Média das passadas RMS para a banda 8 (50 kHz a 55 kHz).

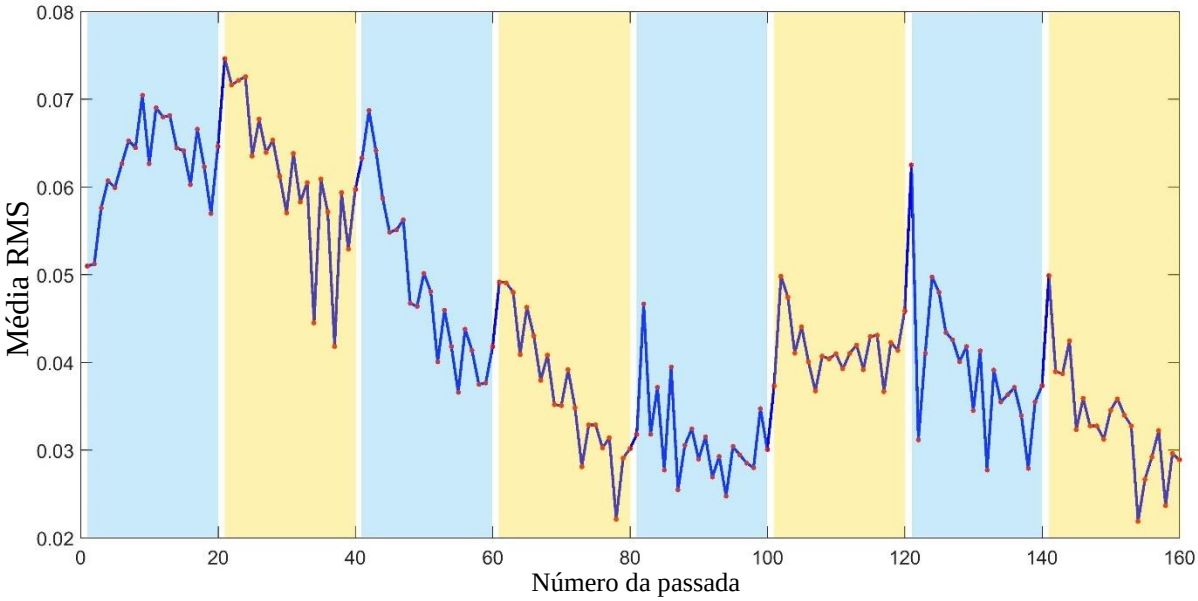


Figura A-8 – Média das passadas RMS para a banda 9 (63 kHz a 68 kHz).

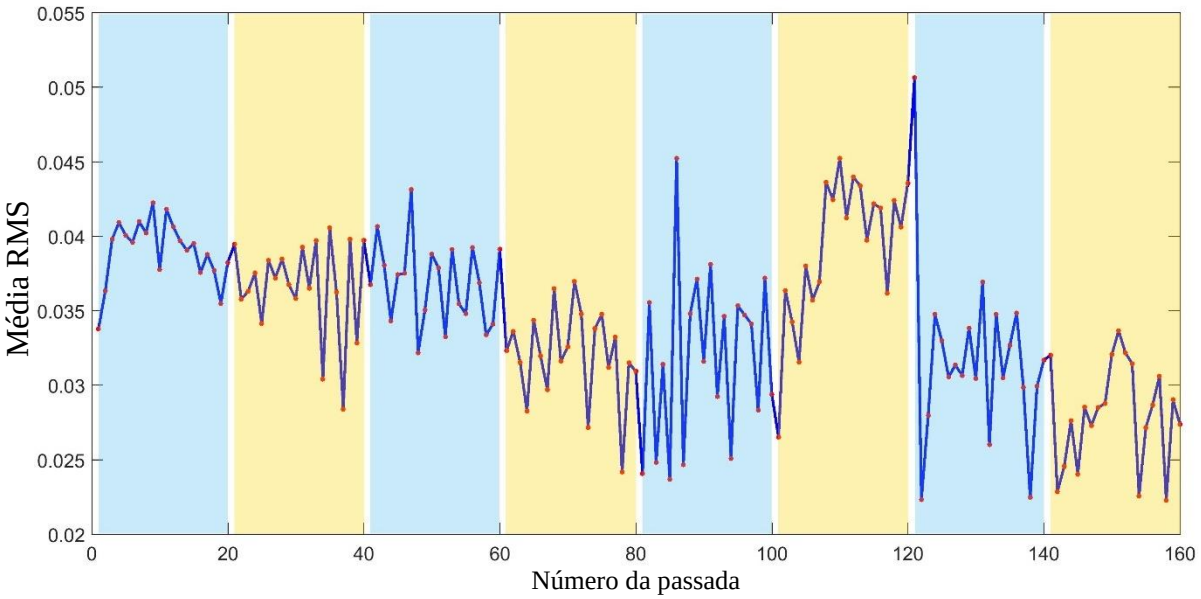



Figura A-9 – Média das passadas RMS para a banda 10 (72 kHz a 75 kHz).

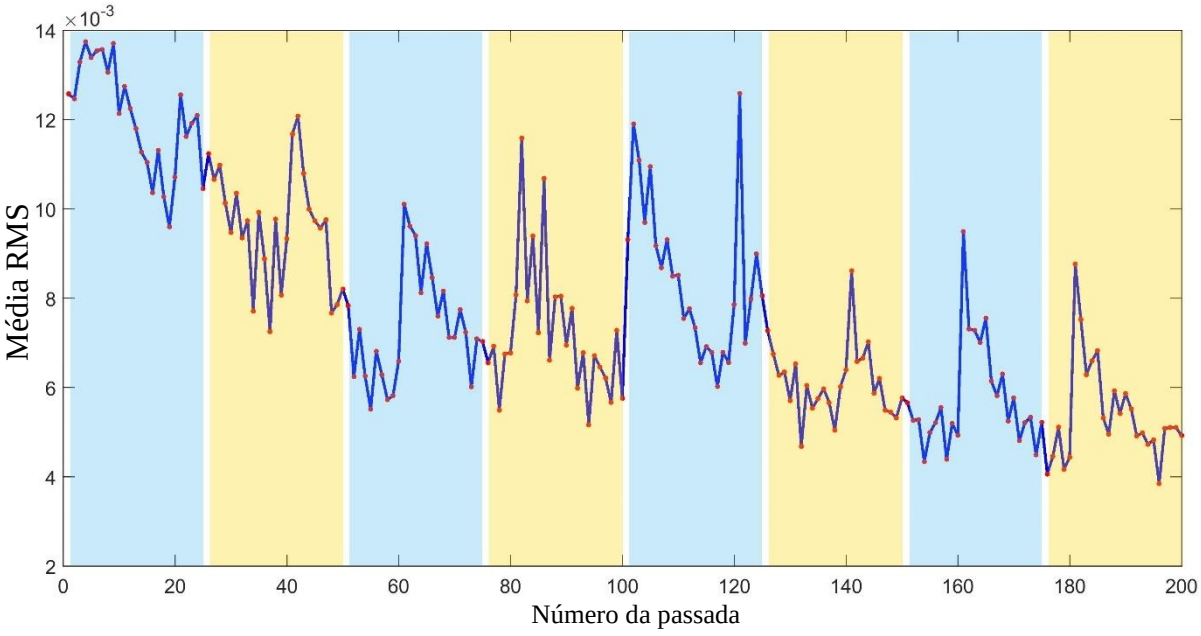


Figura A-10 – Média das passadas RMS para a banda 11 (95 kHz a 99 kHz).

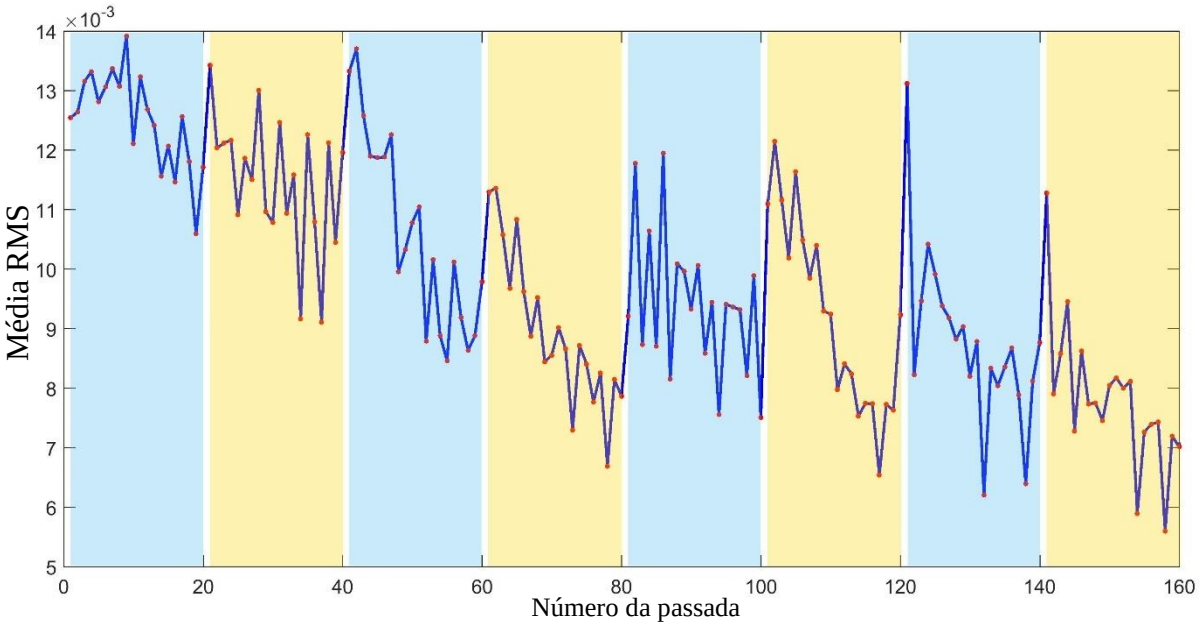



Figura A-11 – Média das passadas RMS para a banda 12 (105 kHz a 107 kHz).

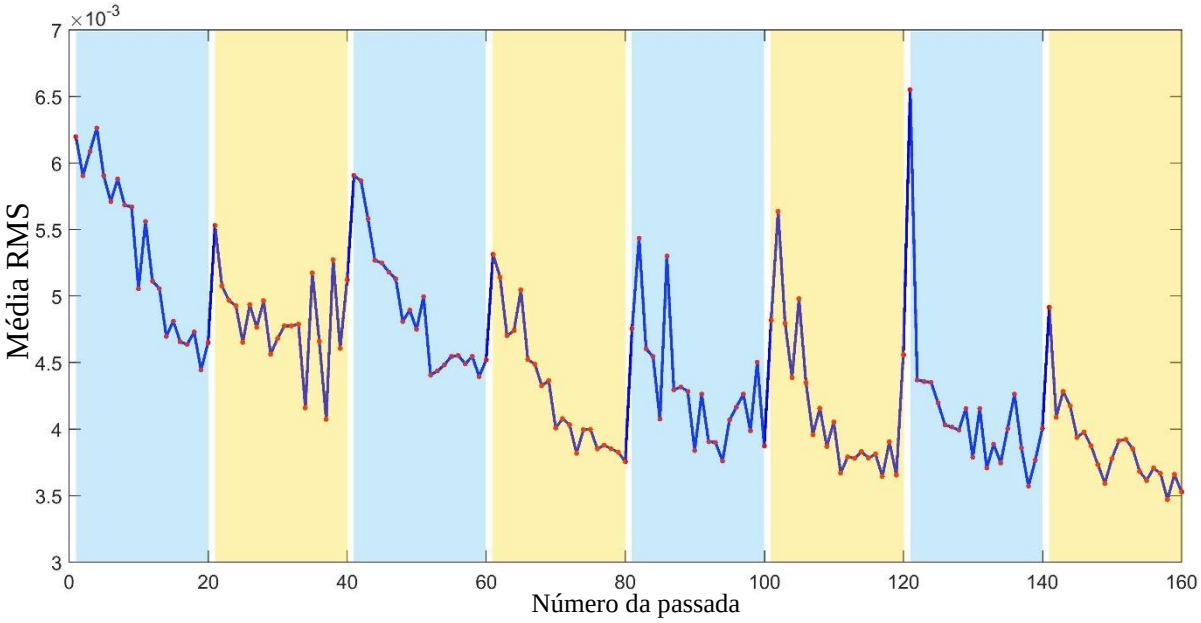


Figura A-12 – Média das passadas RMS para a banda 13 (111 kHz a 114 kHz).

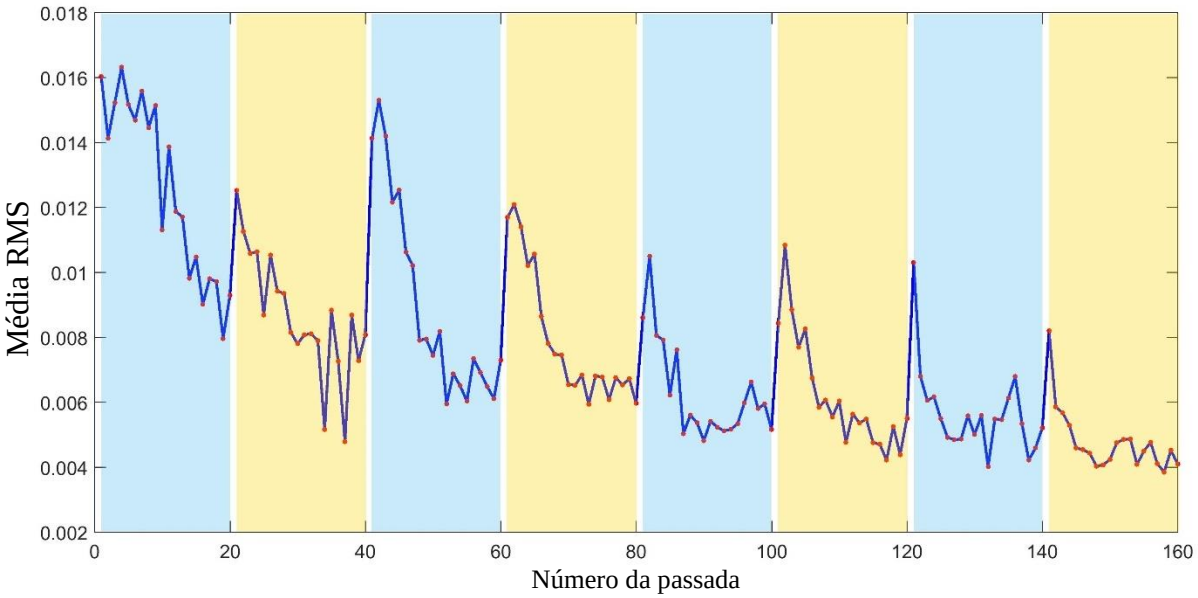



Figura A-13 – Média das passadas RMS para a banda 14 (120 kHz a 124 kHz).

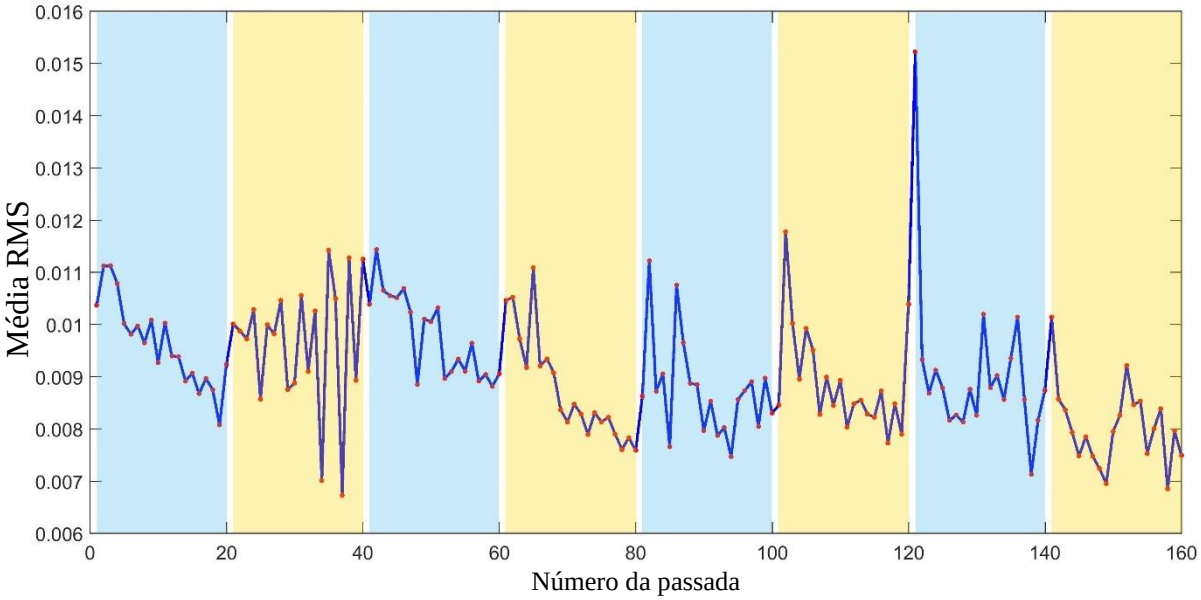


Figura A-14 – Média das passadas RMS para a banda 15 (131 kHz a 134 kHz).

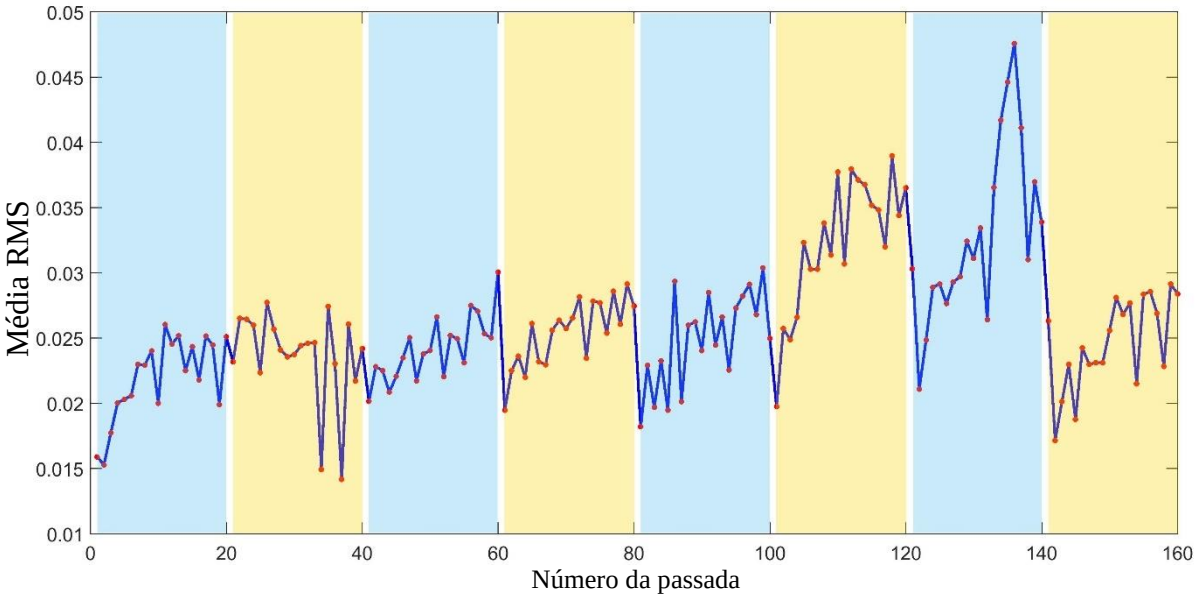



Figura A-15 – Média das passadas RMS para a banda 16 (199 kHz a 204 kHz).

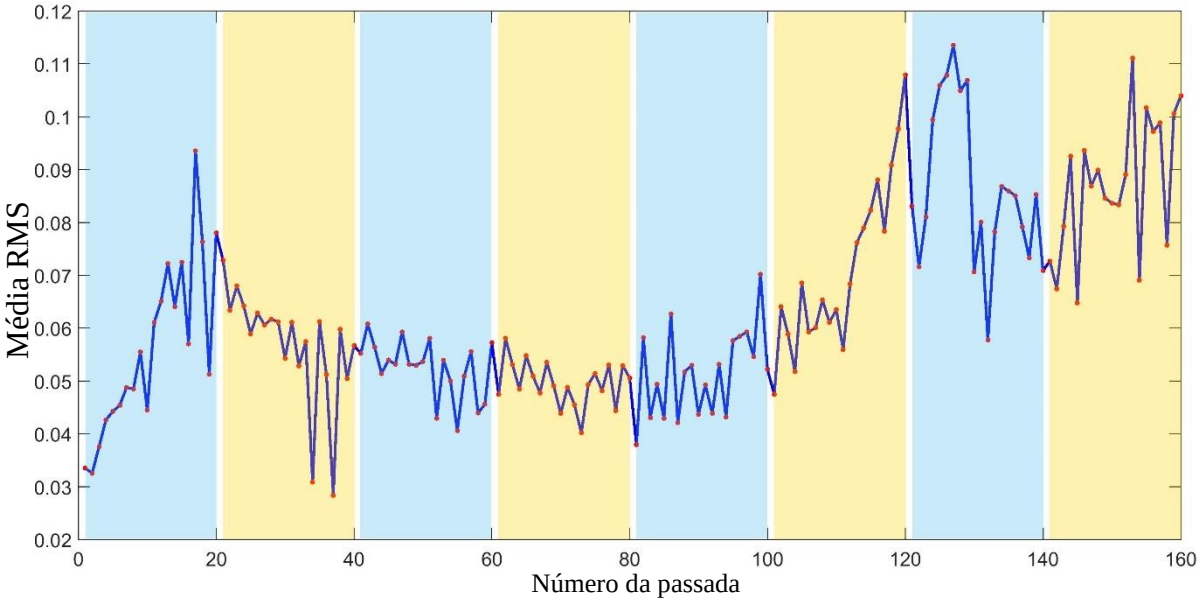


Figura A-16 – Média das passadas RMS para a banda 17 (216 kHz a 219 kHz).

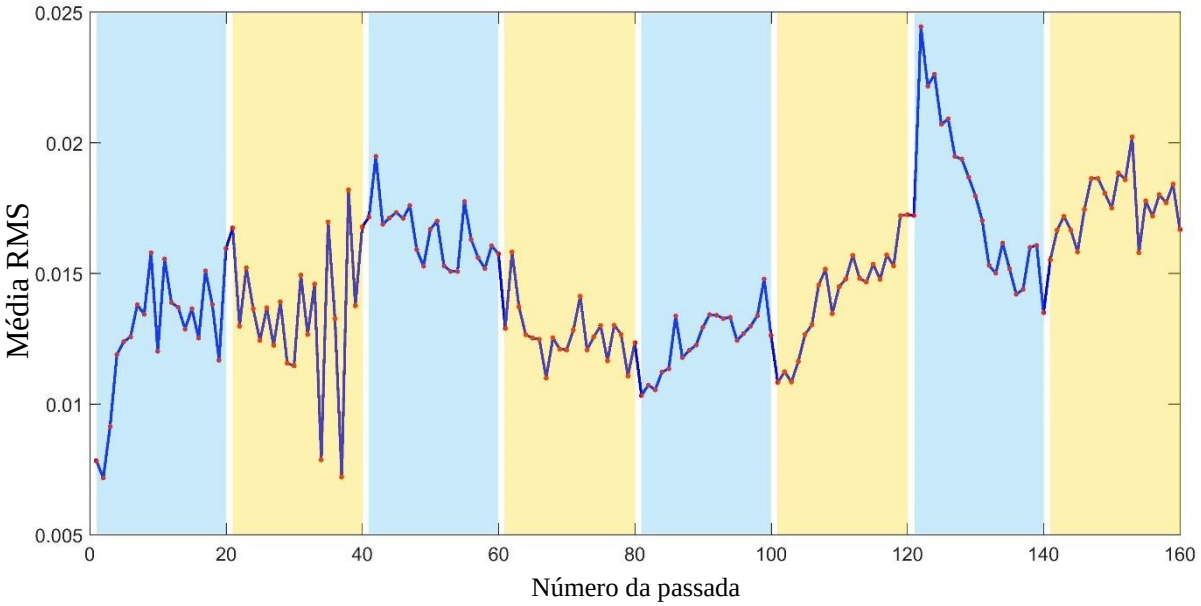



Figura A-17 – Média das passadas ROP sem seleção de banda.

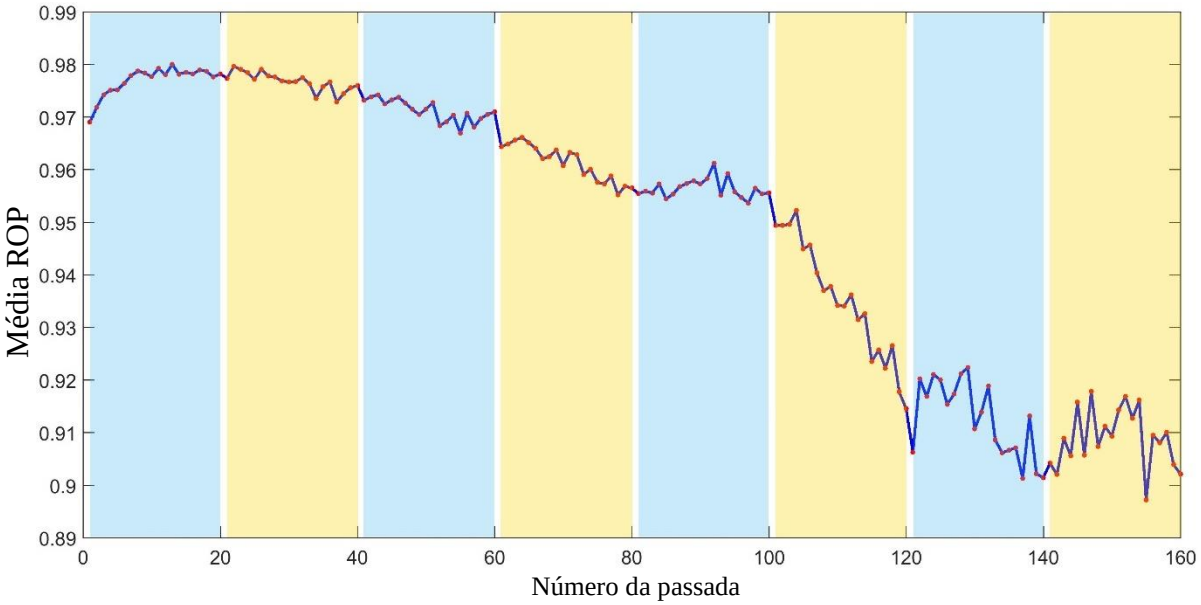


Figura A-18 – Média das passadas ROP para a banda 1 (21 kHz a 25 kHz).

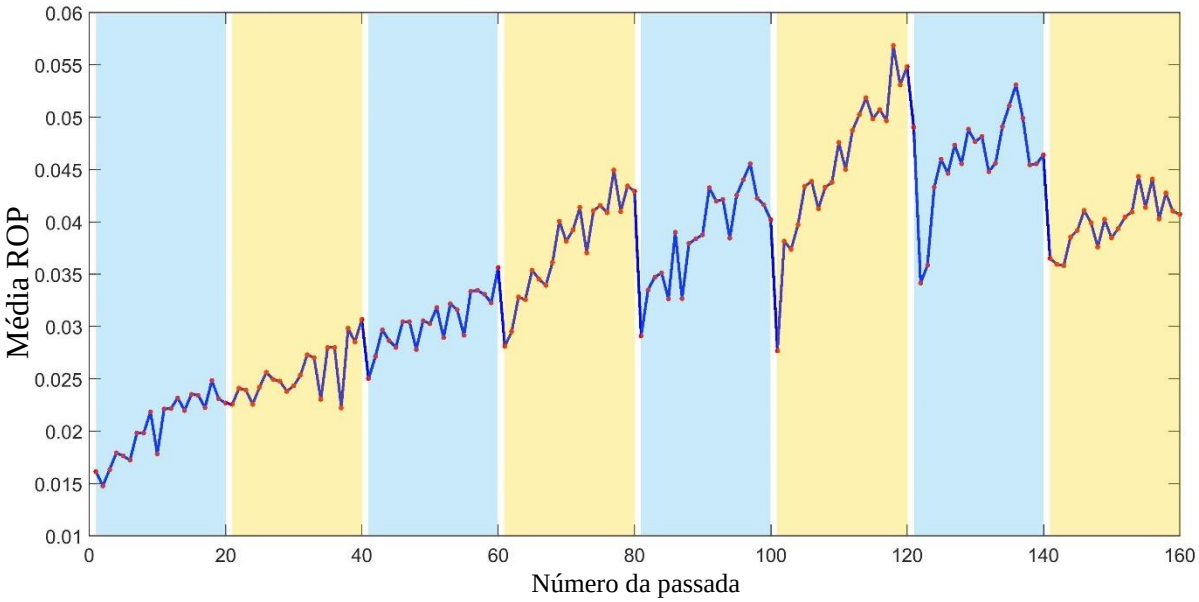



Figura A-19 – Média das passadas ROP para a banda 2 (24 kHz a 29 kHz).

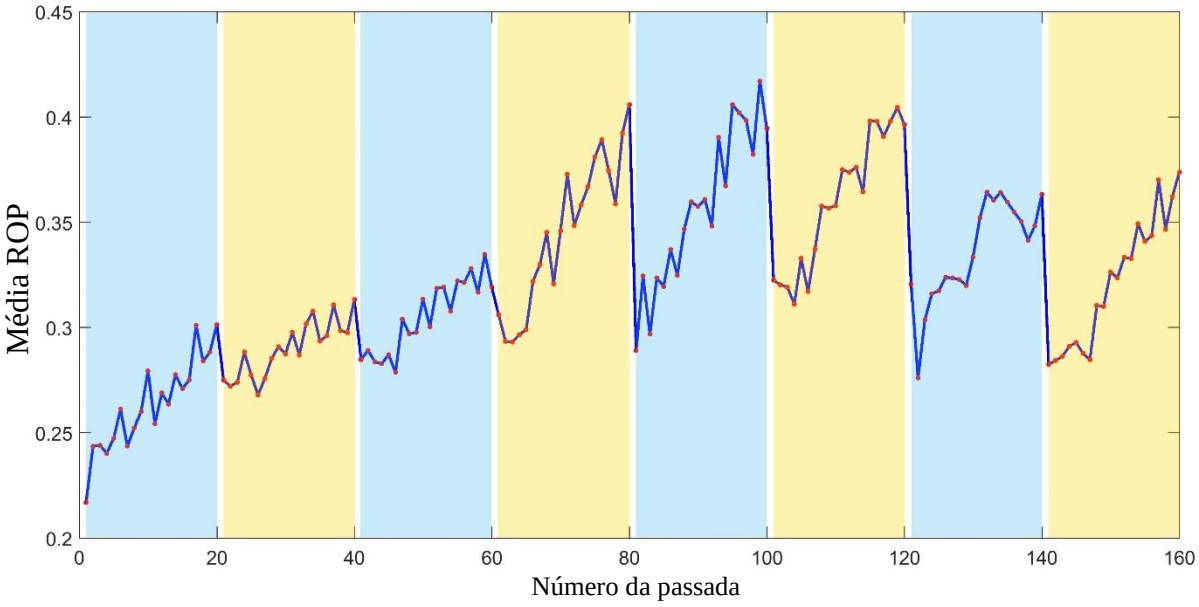


Figura A-20 – Média das passadas ROP para a banda 3 (25 kHz a 30 kHz).

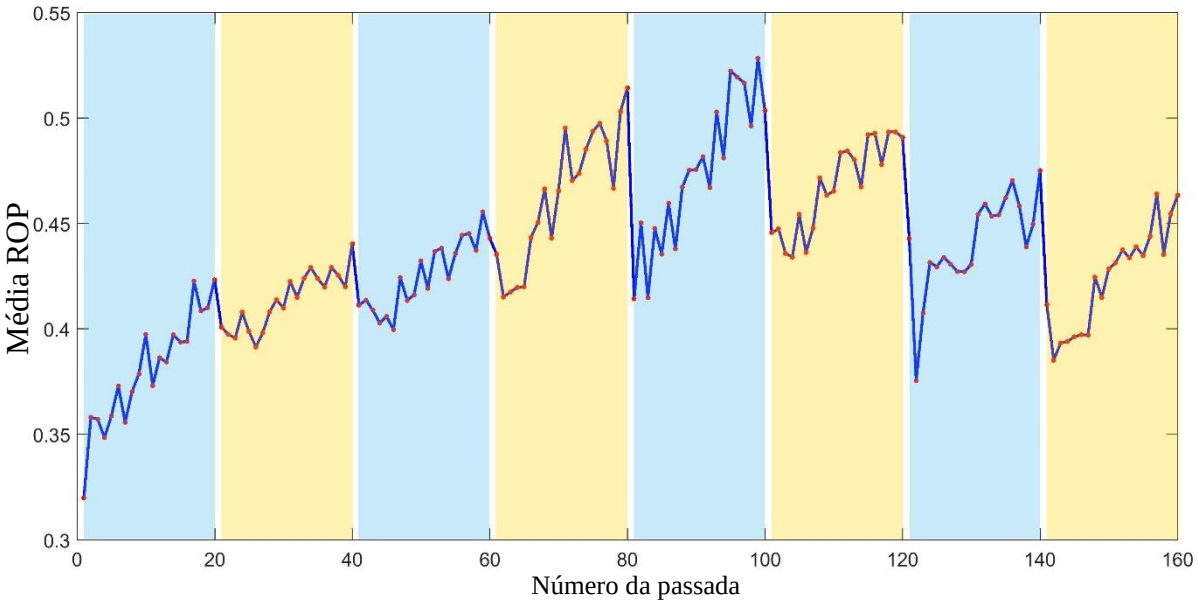



Figura A-21 – Média das passadas ROP para a banda 4 (29 kHz a 32 kHz).

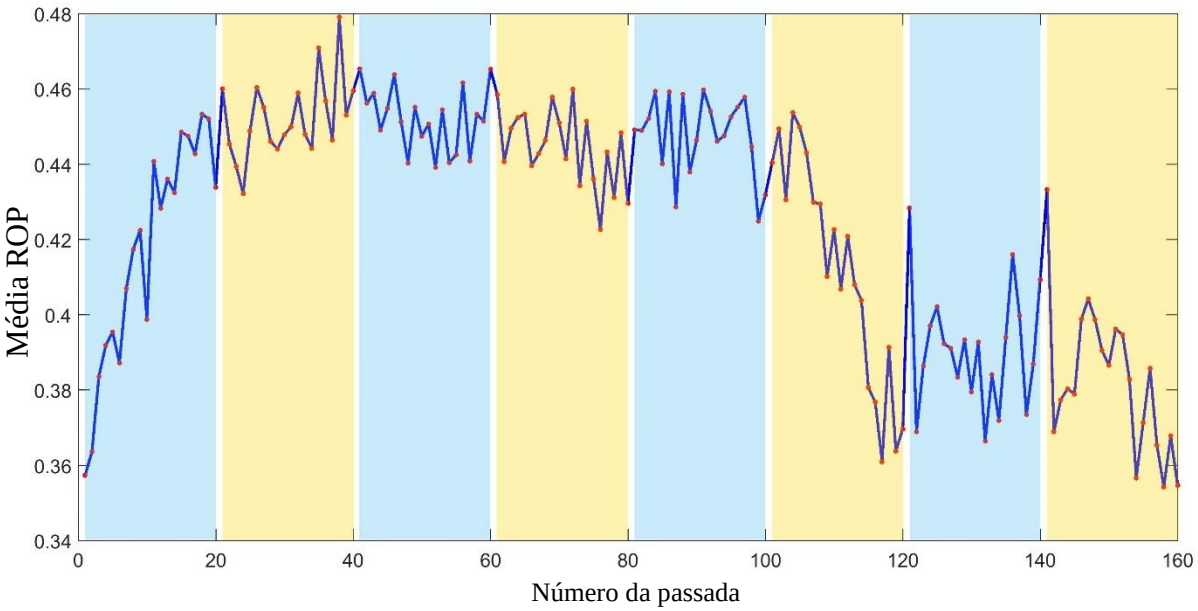


Figura A-22 – Média das passadas ROP para a banda 5 (30 kHz a 34 kHz).

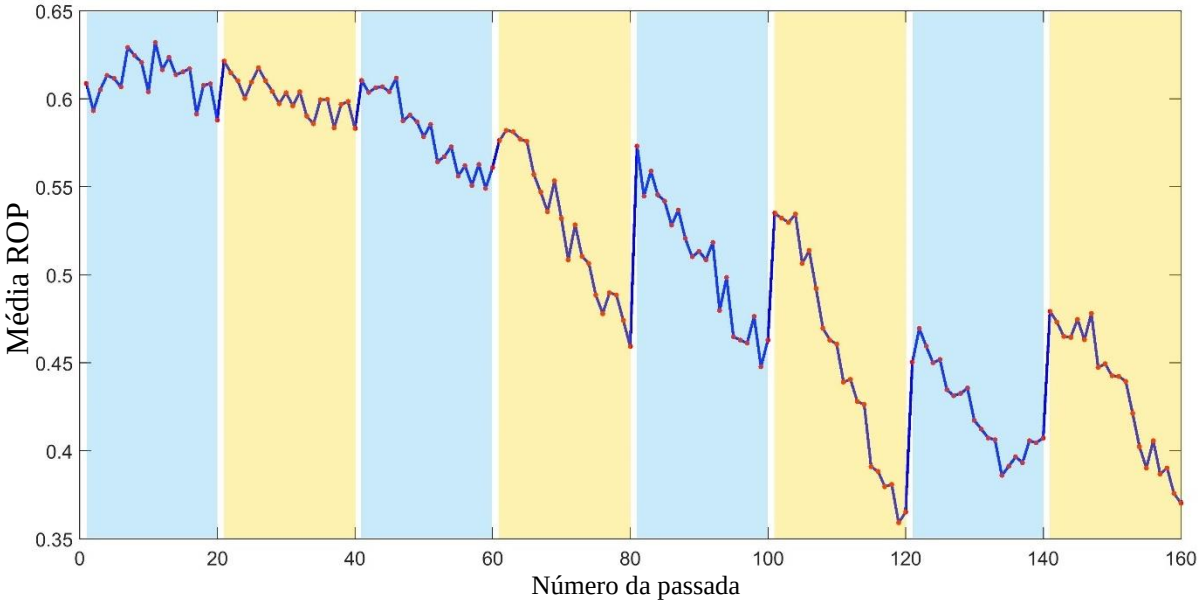



Figura A-23 – Média das passadas ROP para a banda 7 (41 kHz a 44 kHz).

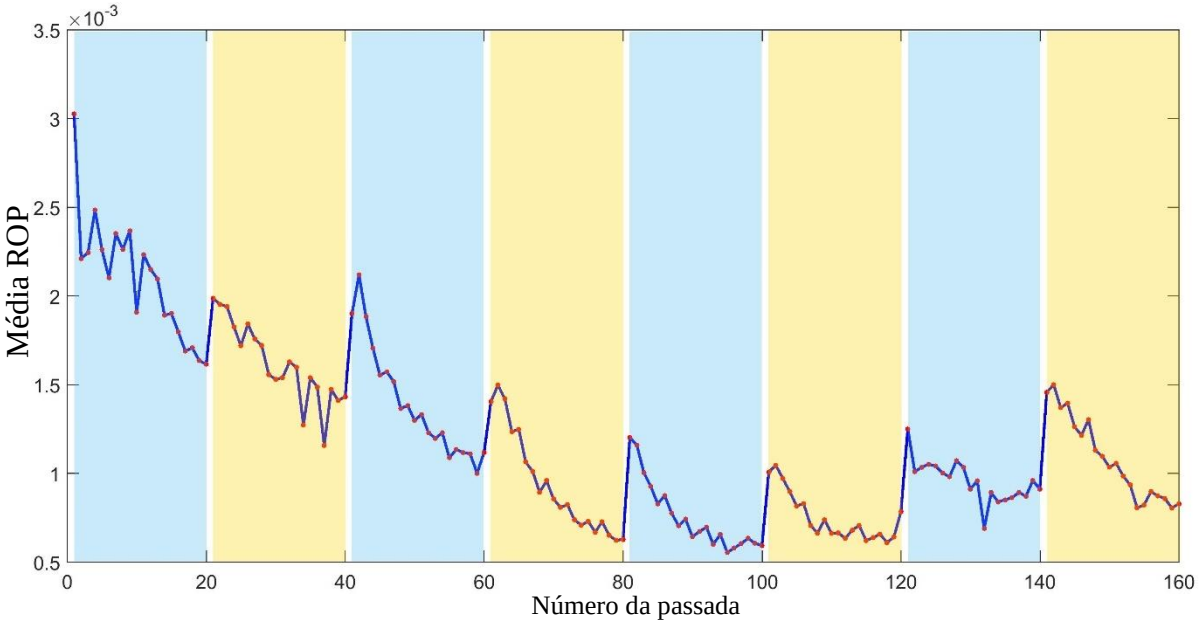


Figura A-24 – Média das passadas ROP para a banda 8 (50 kHz a 55 kHz).

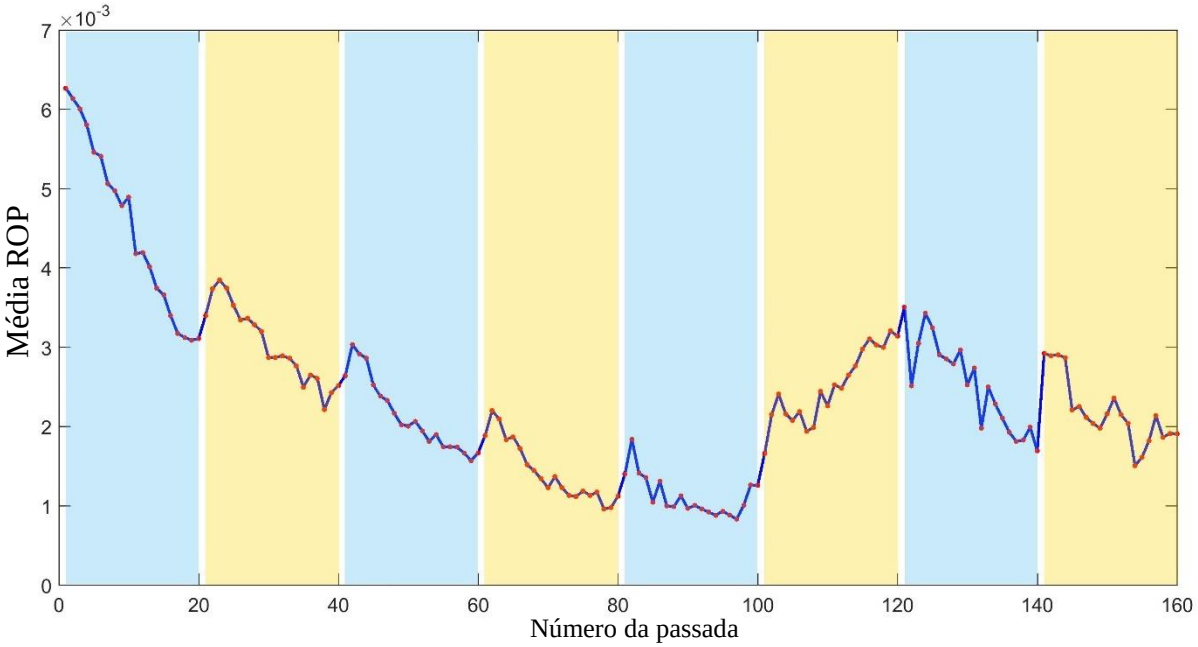



Figura A-25 – Média das passadas ROP para a banda 9 (63 kHz a 68 kHz).

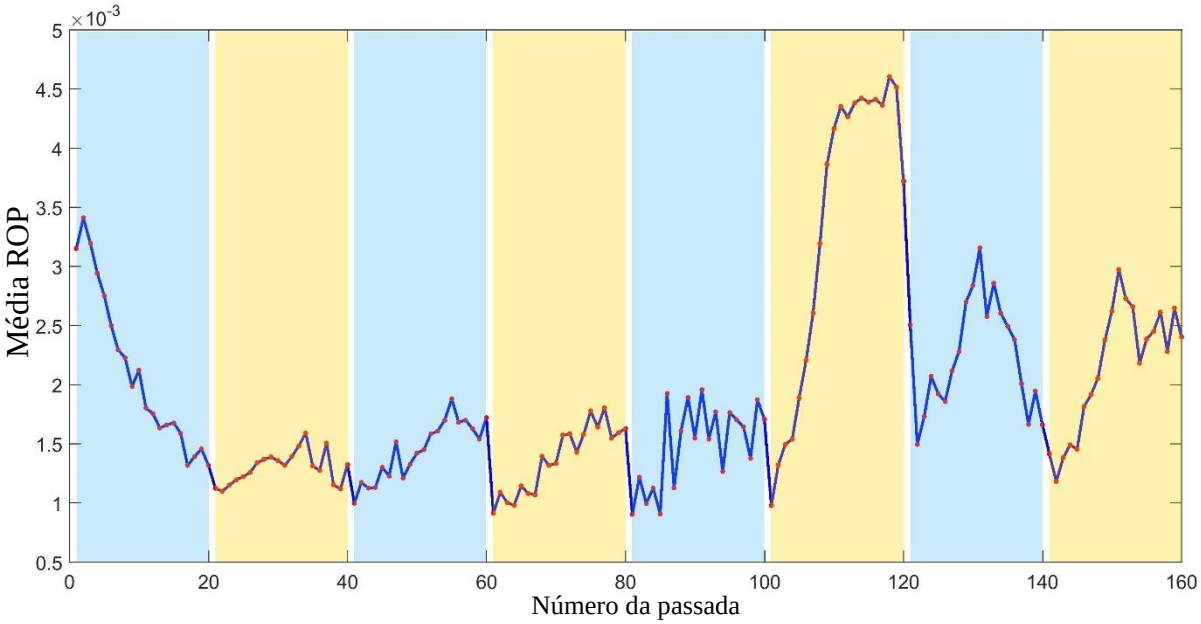


Figura A-26 – Média das passadas ROP para a banda 10 (72 kHz a 75 kHz).

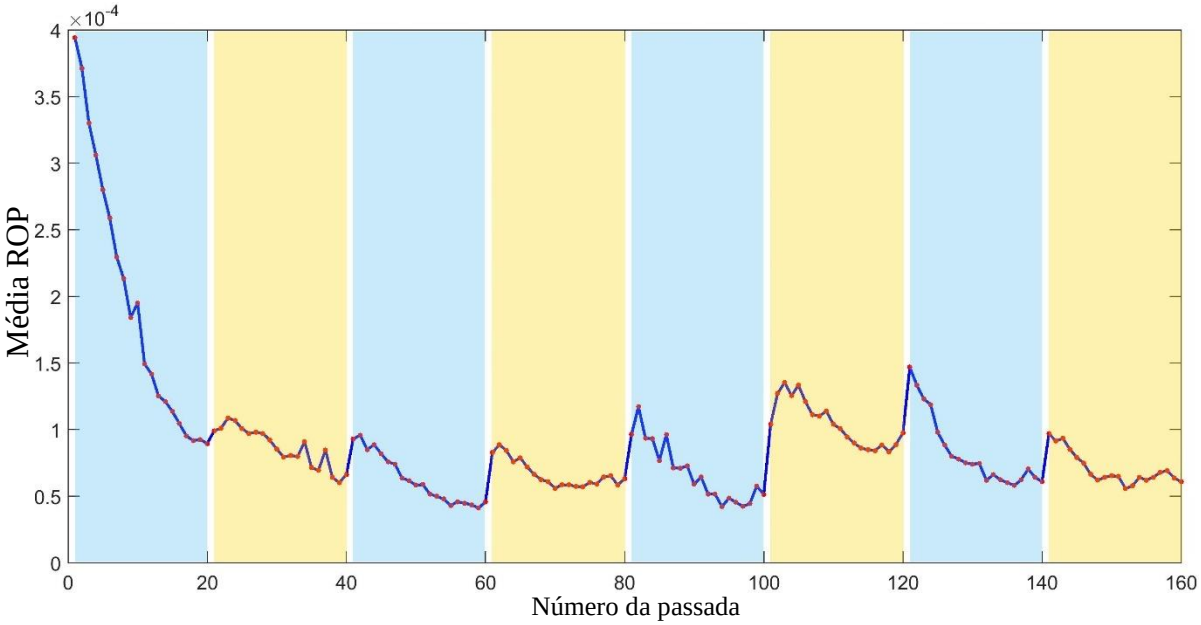



Figura A-27 – Média das passadas ROP para a banda 11 (95 kHz a 99 kHz).

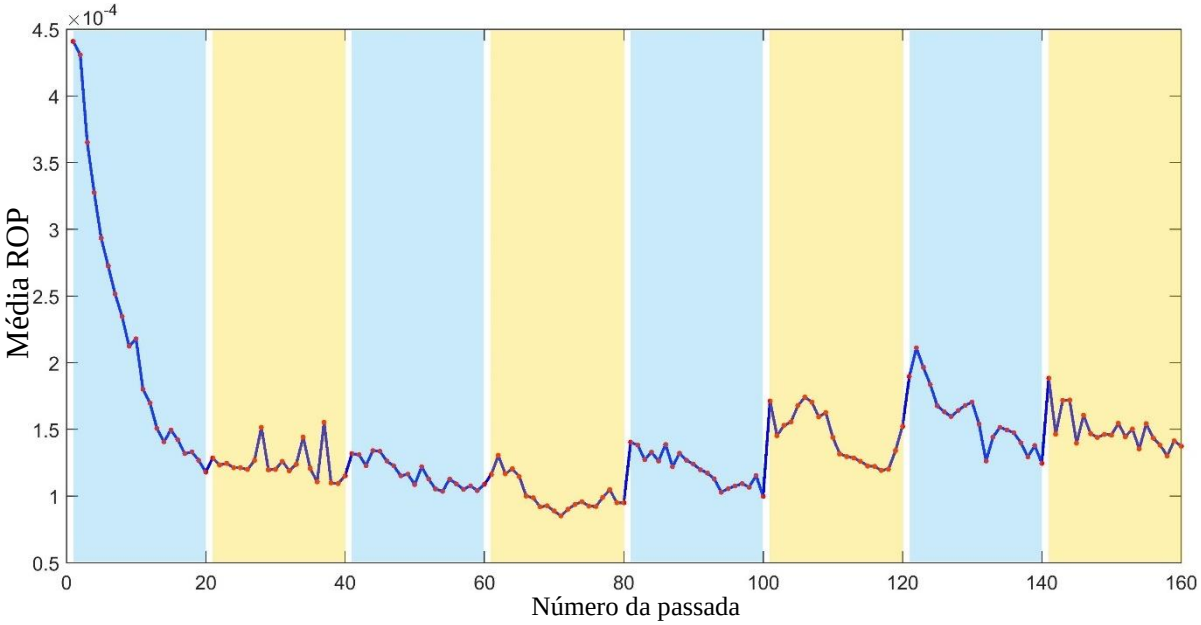


Figura A-28 – Média das passadas ROP para a banda 12 (105 kHz a 107 kHz).

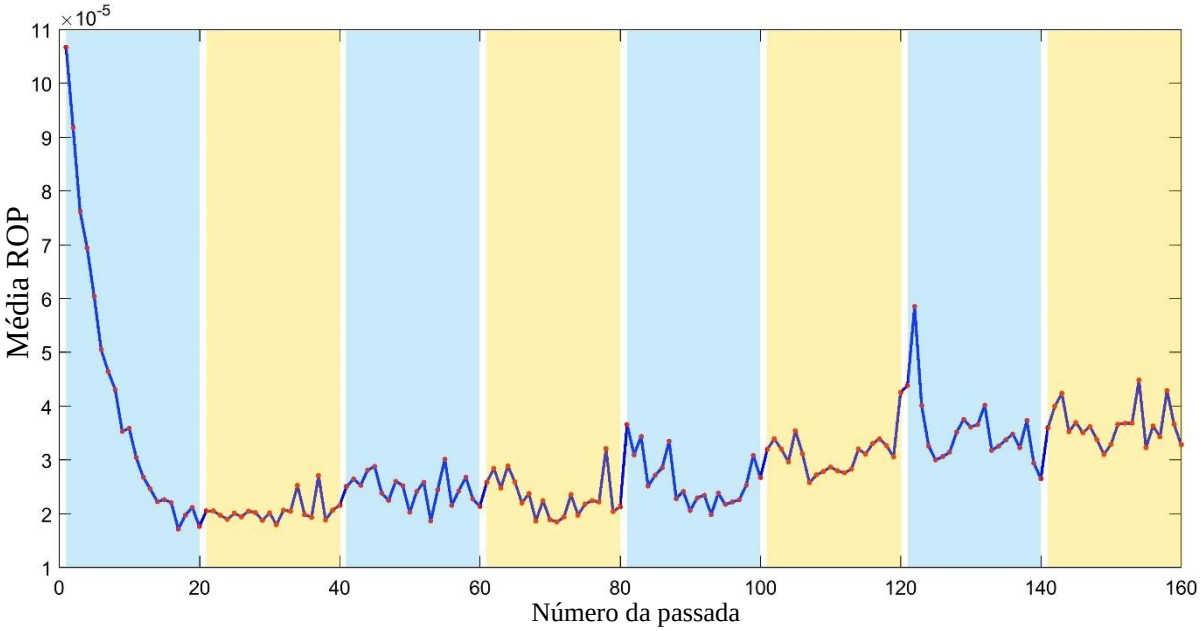



Figura A-29 – Média das passadas ROP para a banda 13 (111 kHz a 114 kHz).

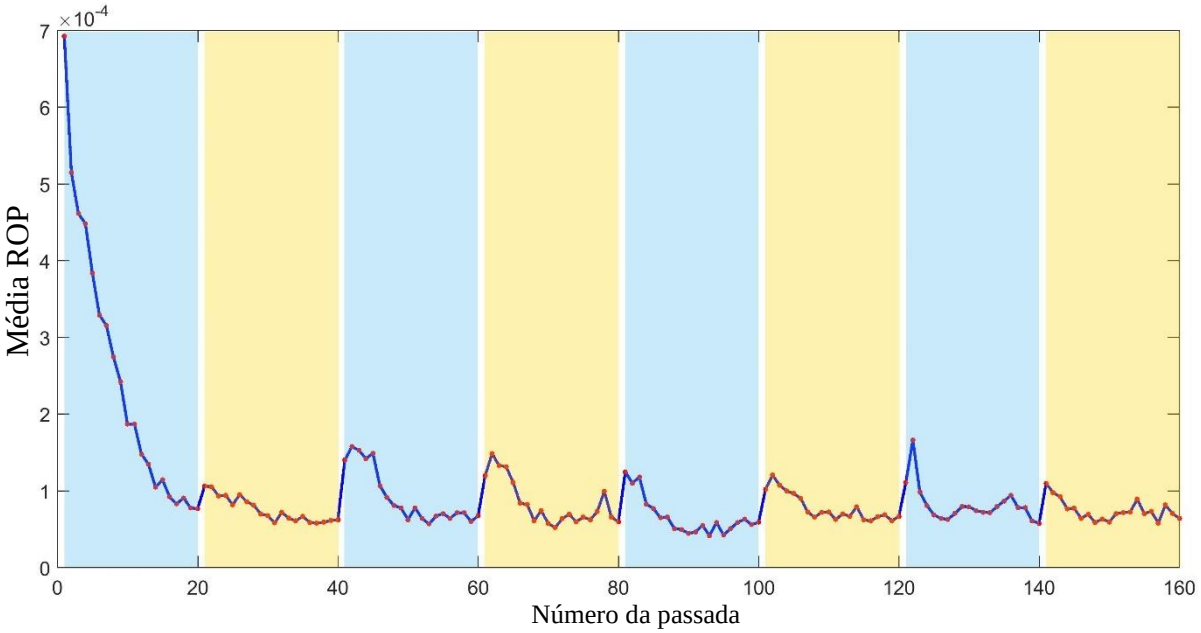


Figura A-30 – Média das passadas ROP para a banda 14 (120 kHz a 124 kHz).

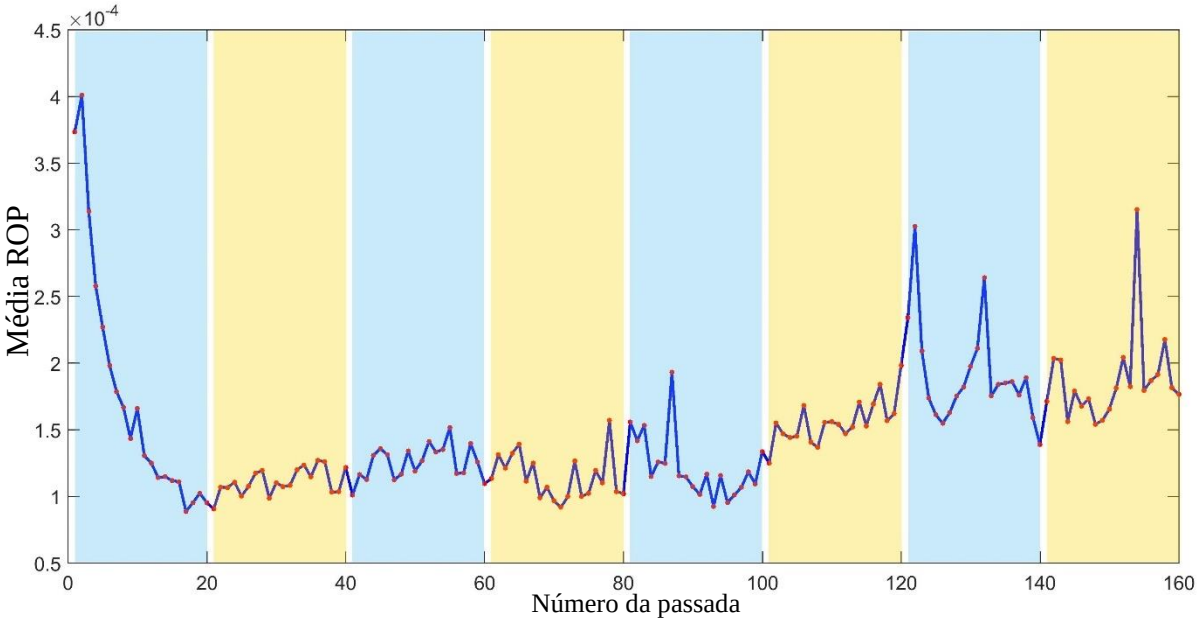



Figura A-31 – Média das passadas ROP para a banda 15 (131 kHz a 134 kHz).

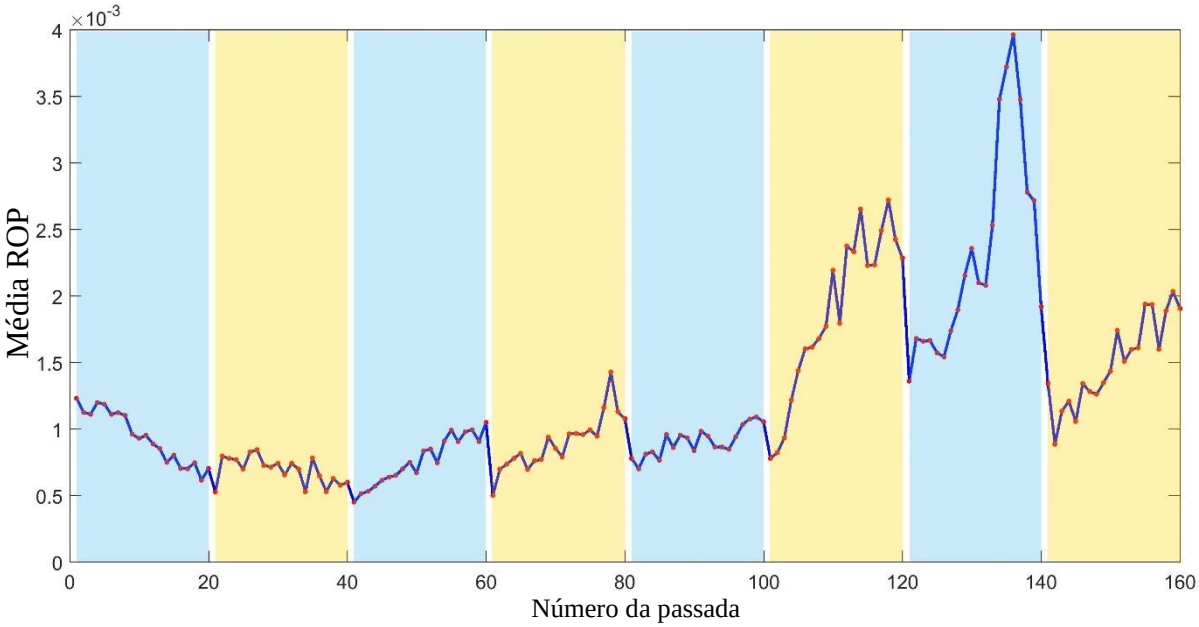


Figura A-32 – Média das passadas ROP para a banda 16 (199 kHz a 204 kHz).

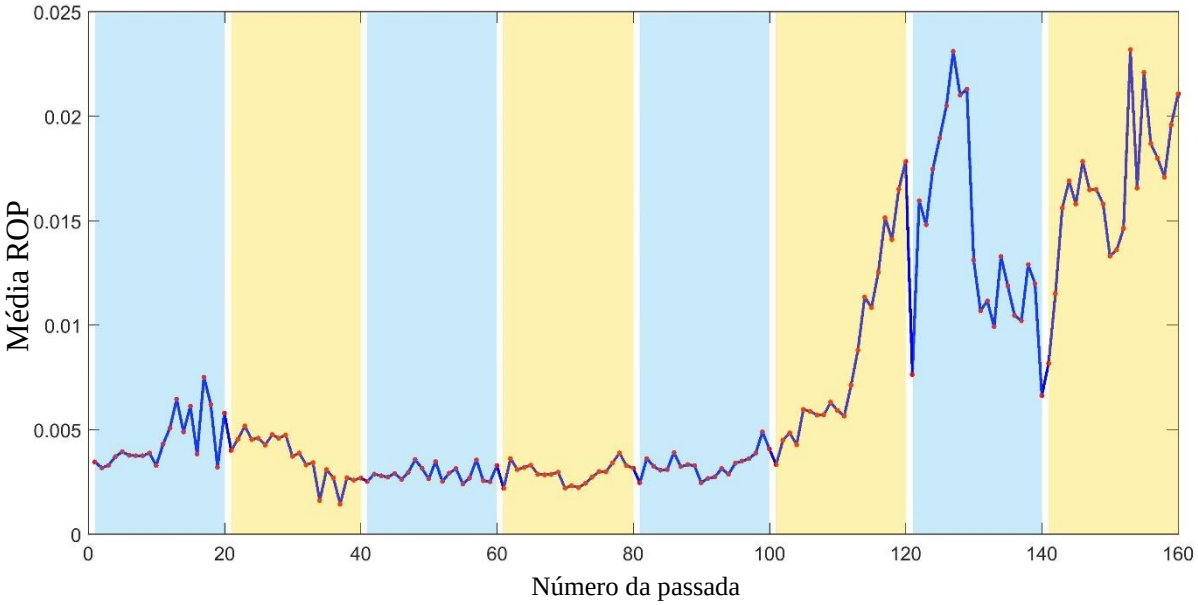



Figura A-33 – Média das passadas ROP para a banda 17 (216 kHz a 219 kHz).

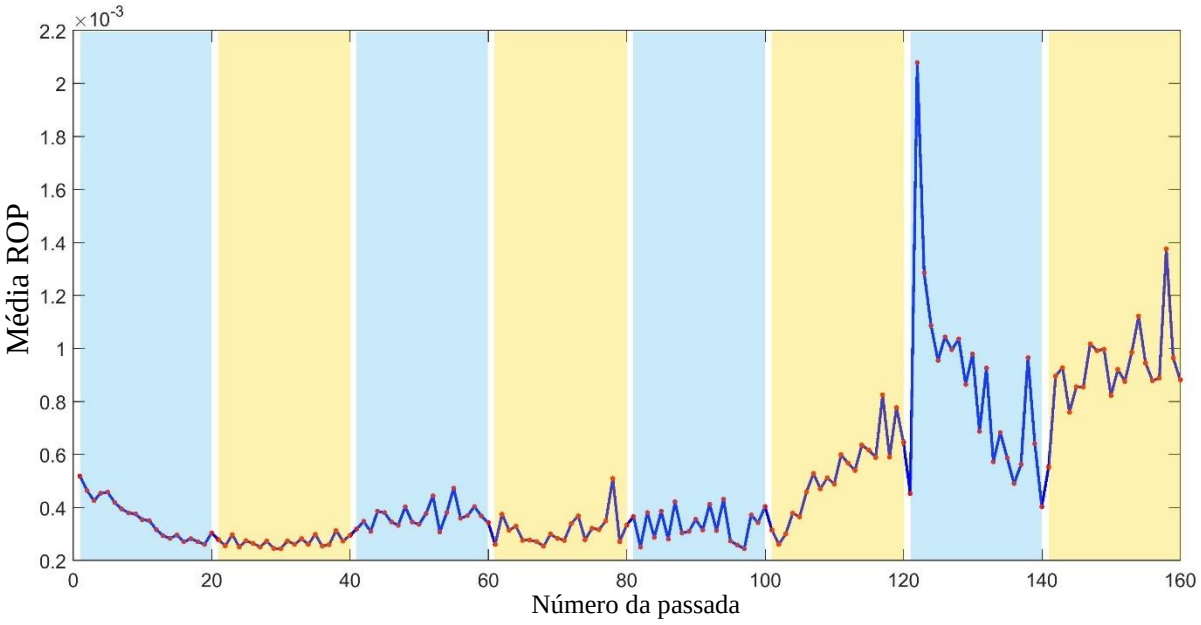


Figura A-34 – Média das passadas MVD para a banda 6 (32 kHz a 34 kHz).

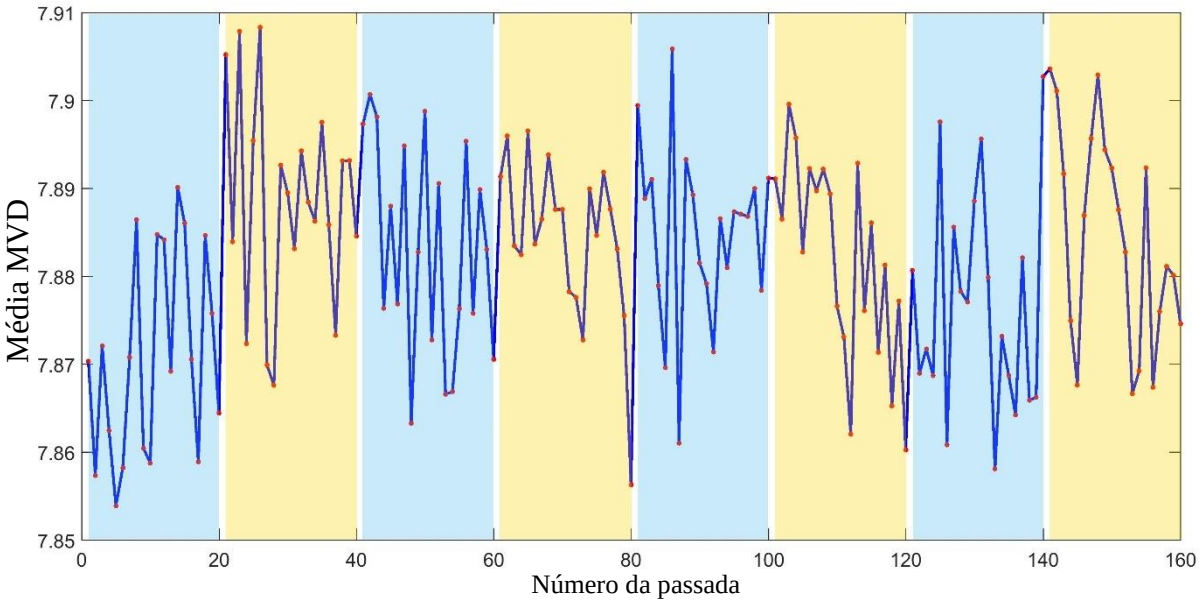



Figura A-35 – Média das passadas CFAR para a banda 2 (24 kHz a 29 kHz).

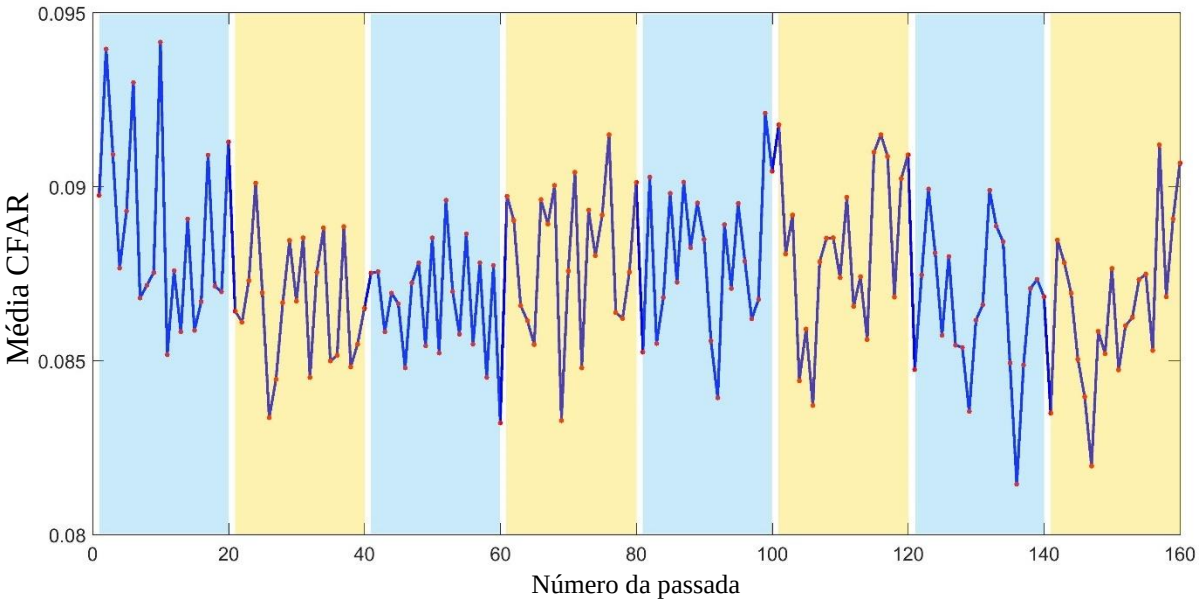


Figura A-36 – Média das passadas CFAR para a banda 3 (25 kHz a 30 kHz).

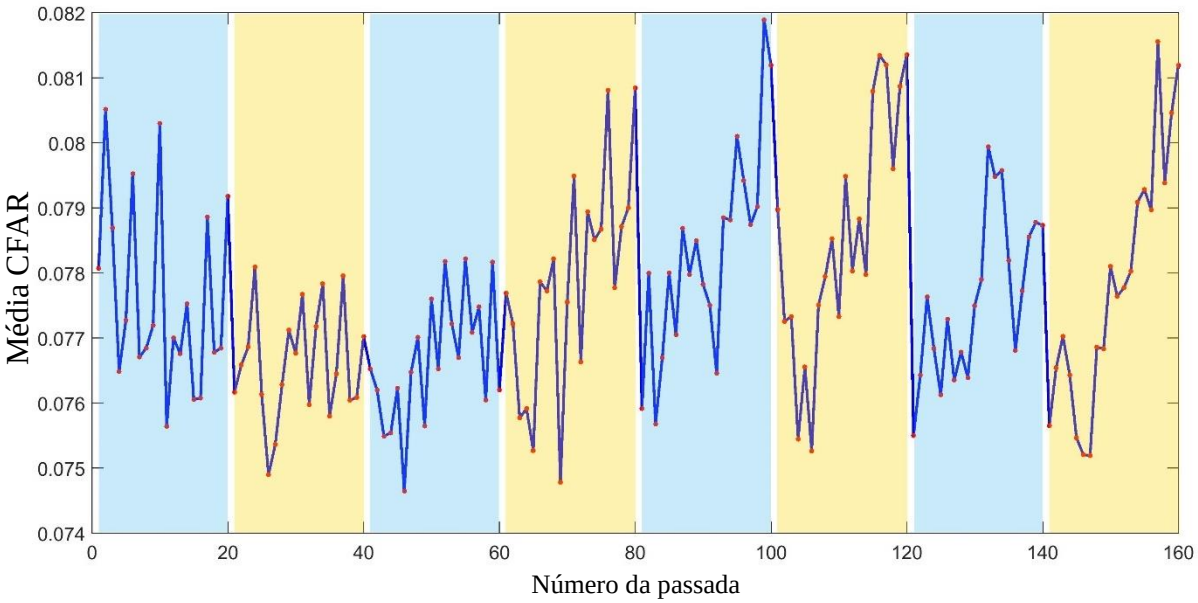



Figura A-37 – Média das passadas CFAR para a banda 4 (29 kHz a 32 kHz).

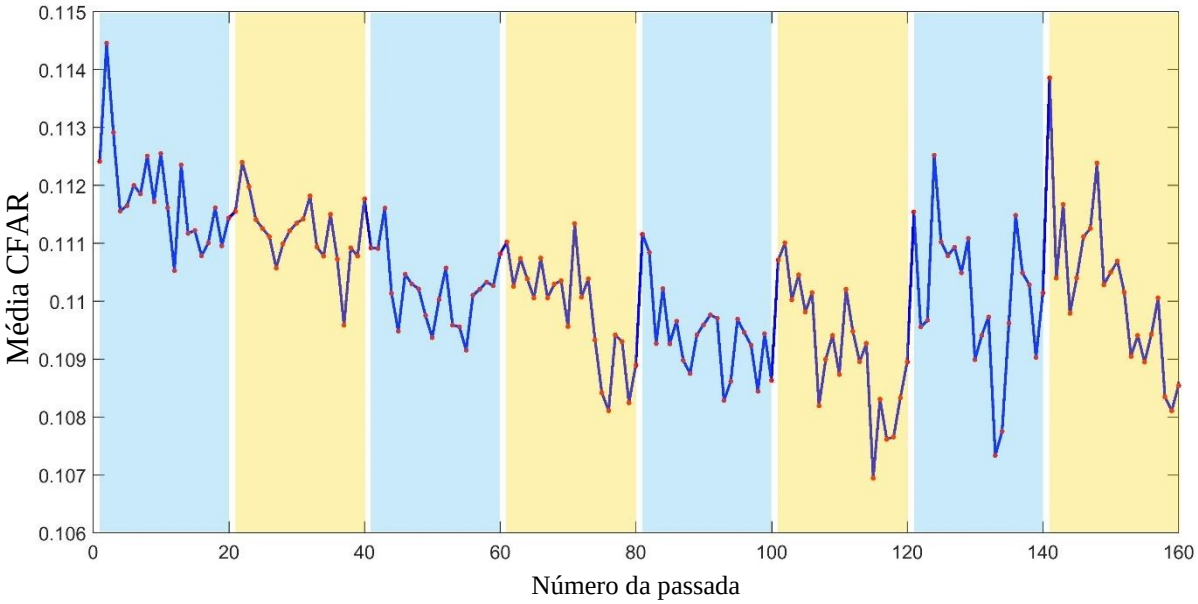


Figura A-38 – Média das passadas CFAR para a banda 5 (30 kHz a 34 kHz).

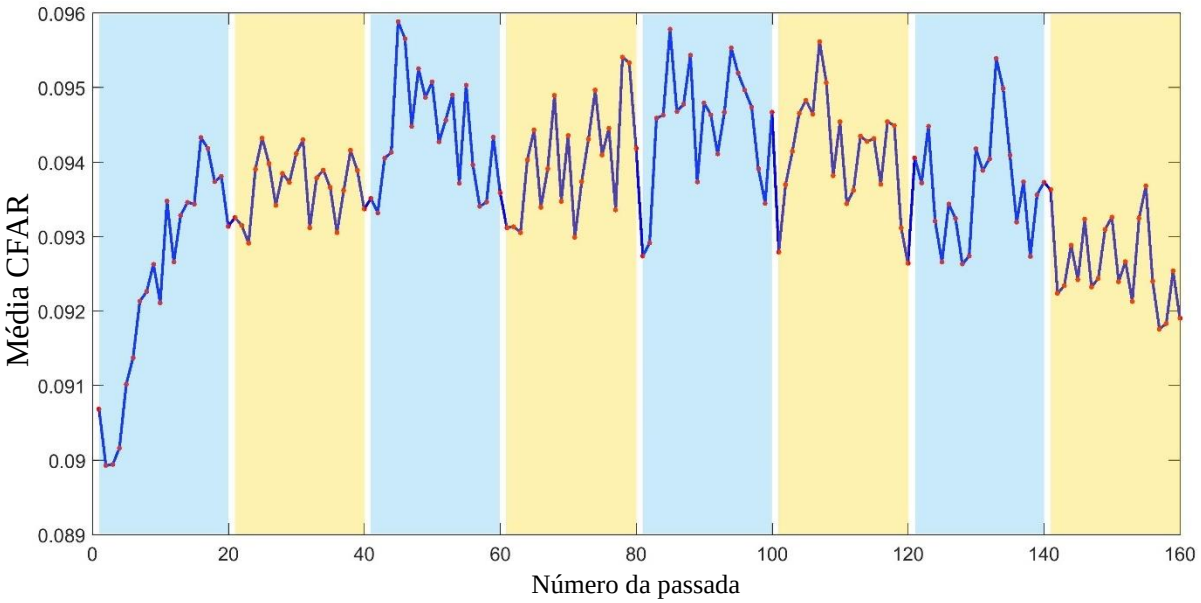



Figura A-39 – Média das passadas CFAR para a banda 6 (32 kHz a 34 kHz).

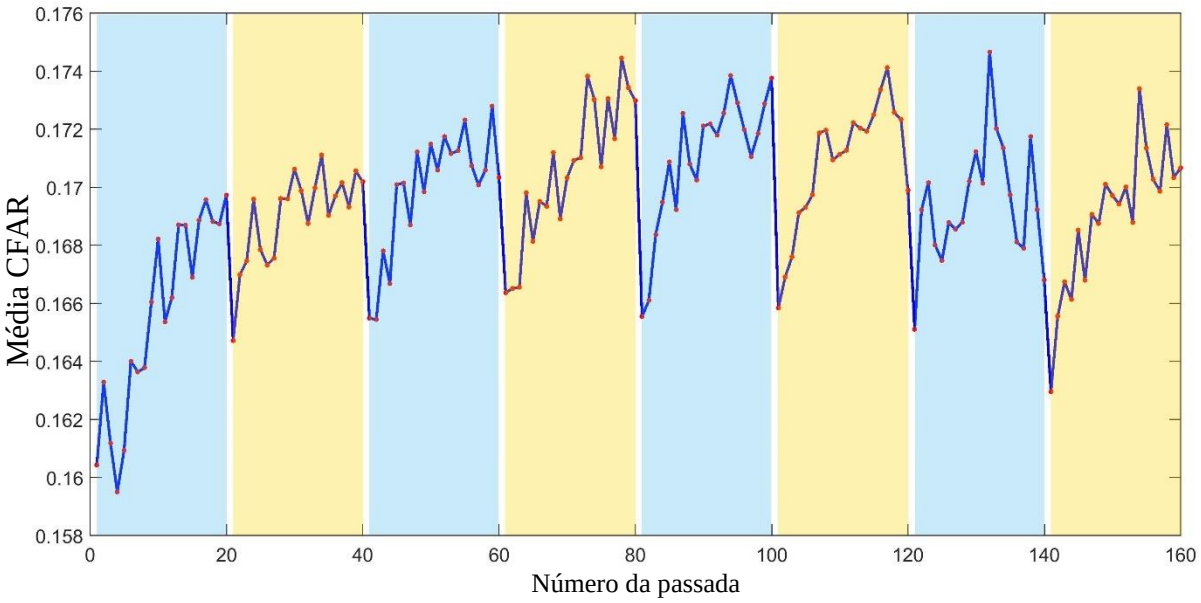


Figura A-40 – Média das passadas CFAR para a banda 8 (50 kHz a 55 kHz).

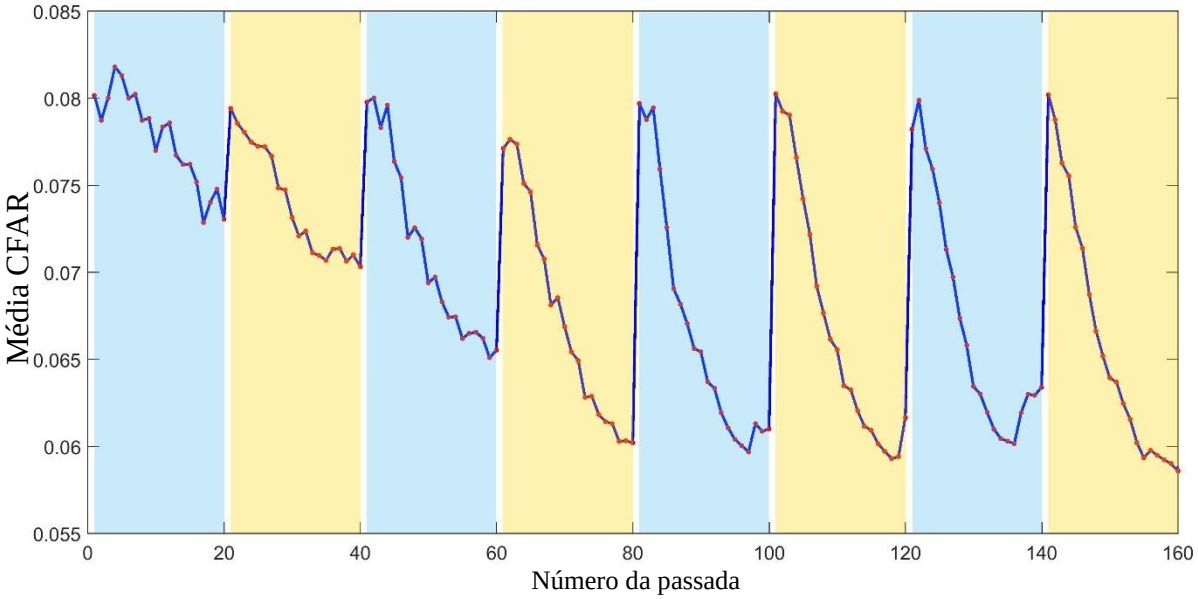



Figura A-41 – Média das passadas *power law* para a banda 1 (21 kHz a 25 kHz).

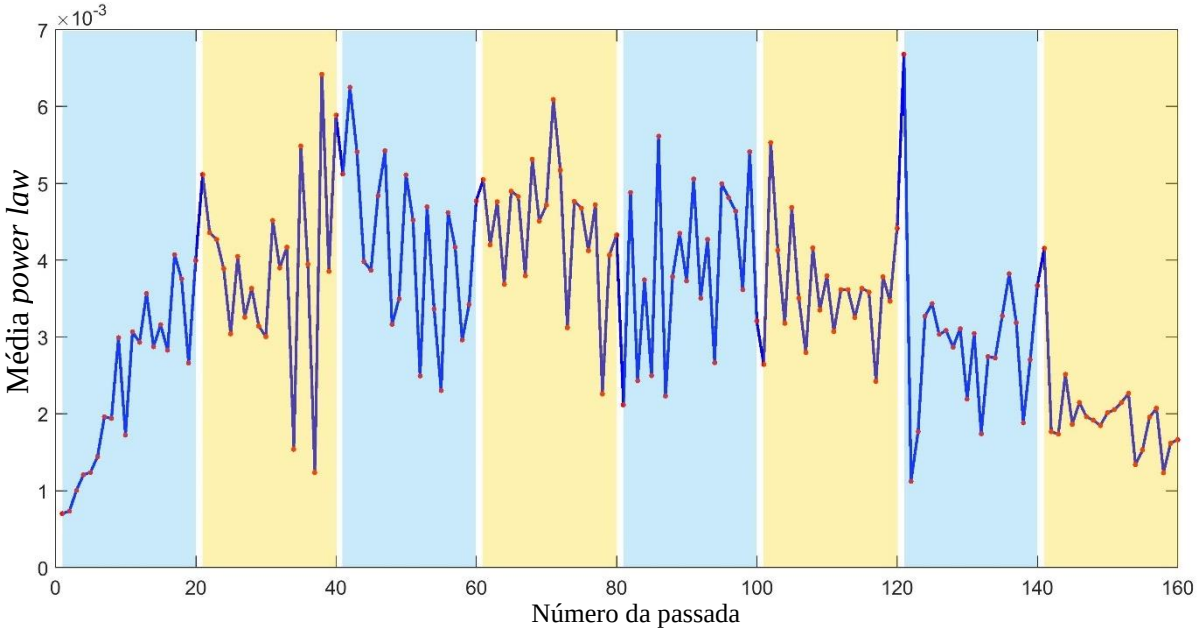


Figura A-42 – Média das passadas *power law* para a banda 2 (24 kHz a 29 kHz).

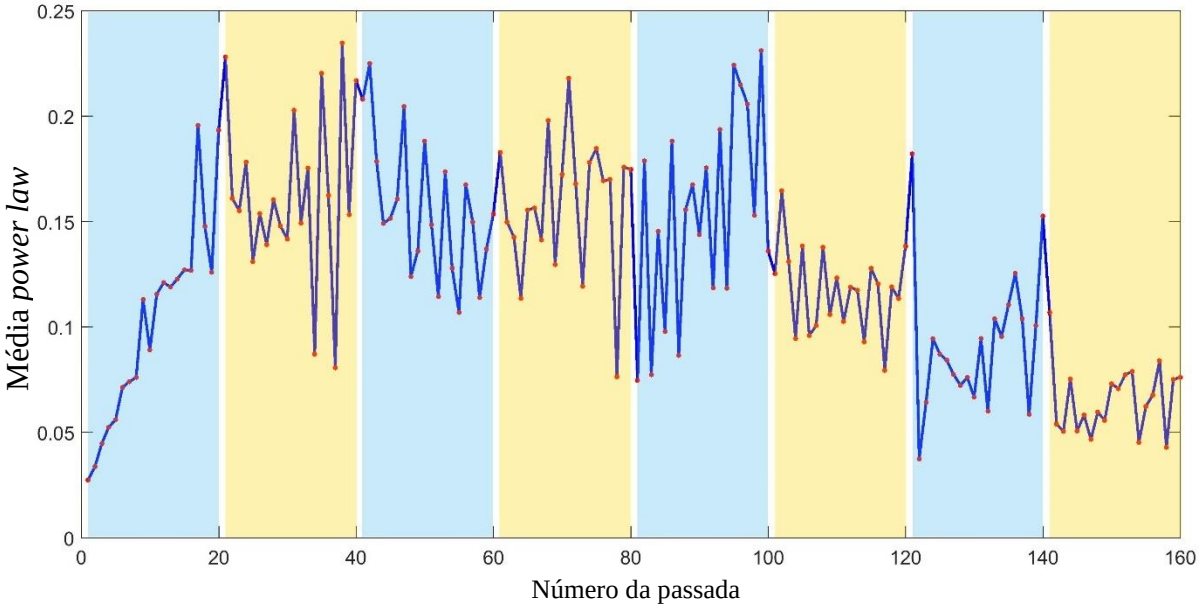



Figura A-43 – Média das passadas *power law* para a banda 3 (25 kHz a 30 kHz).

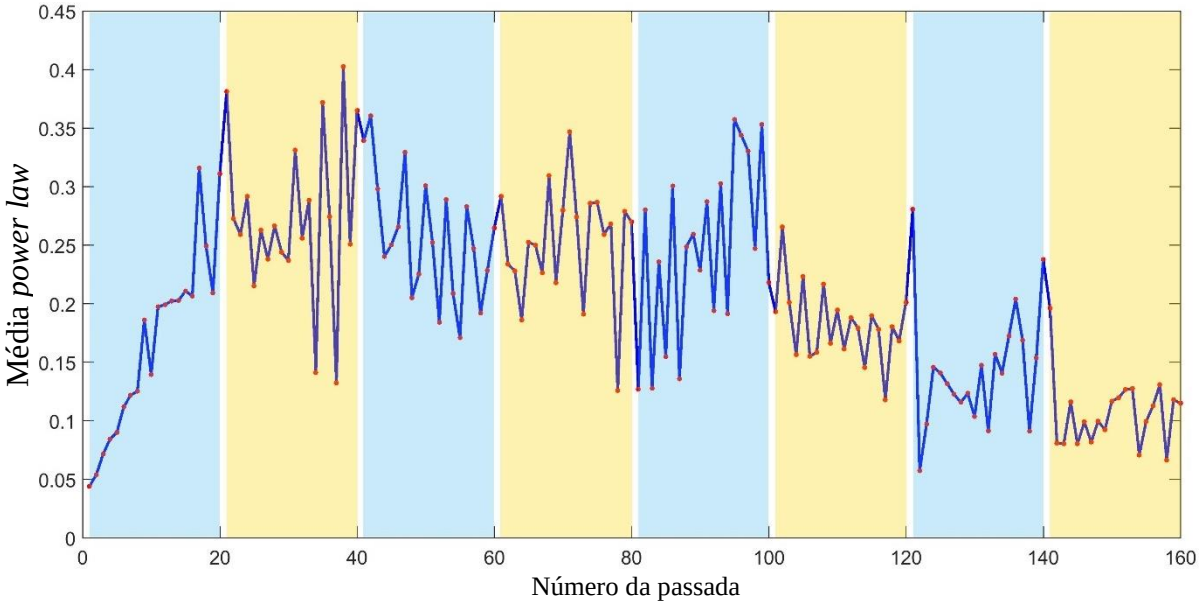


Figura A-44 – Média das passadas *power law* para a banda 4 (29 kHz a 32 kHz).

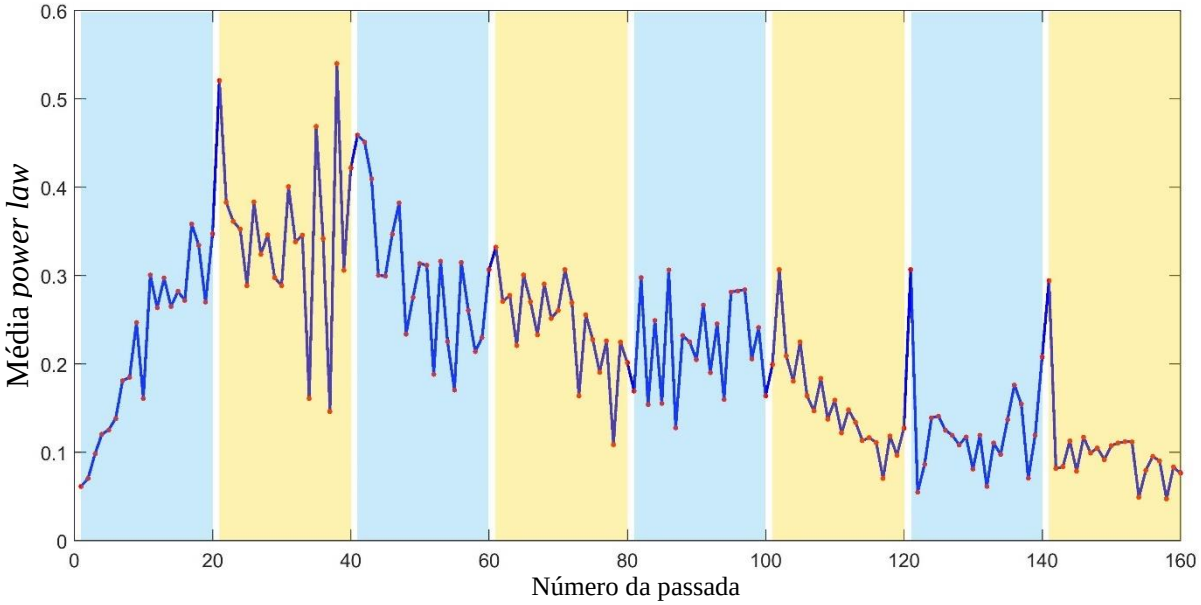



Figura A-45 – Média das passadas *power law* para a banda 5 (30 kHz a 34 kHz).

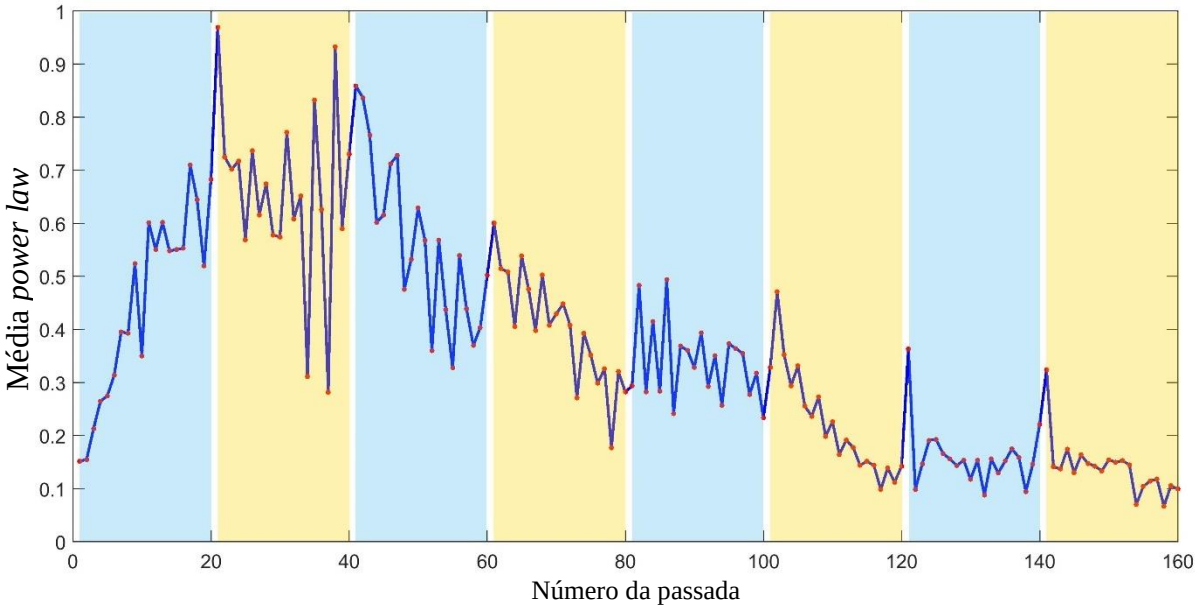


Figura A-46 – Média das passadas *power law* para a banda 6 (32 kHz a 34 kHz).

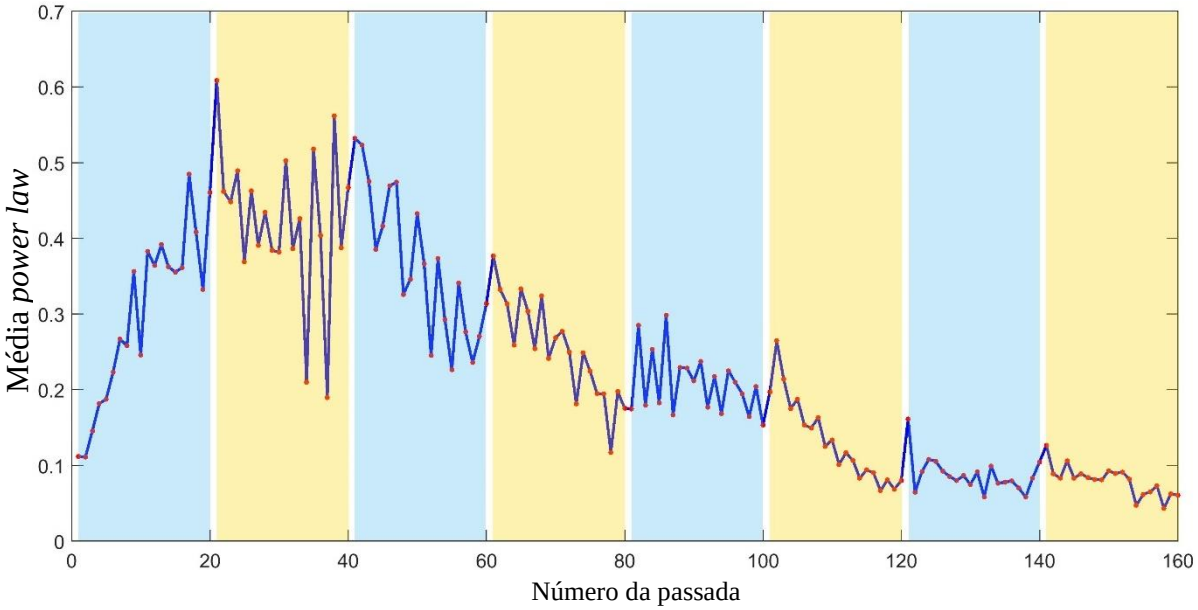



Figura A-47 – Média das passadas *power law* para a banda 7 (41 kHz a 44 kHz).

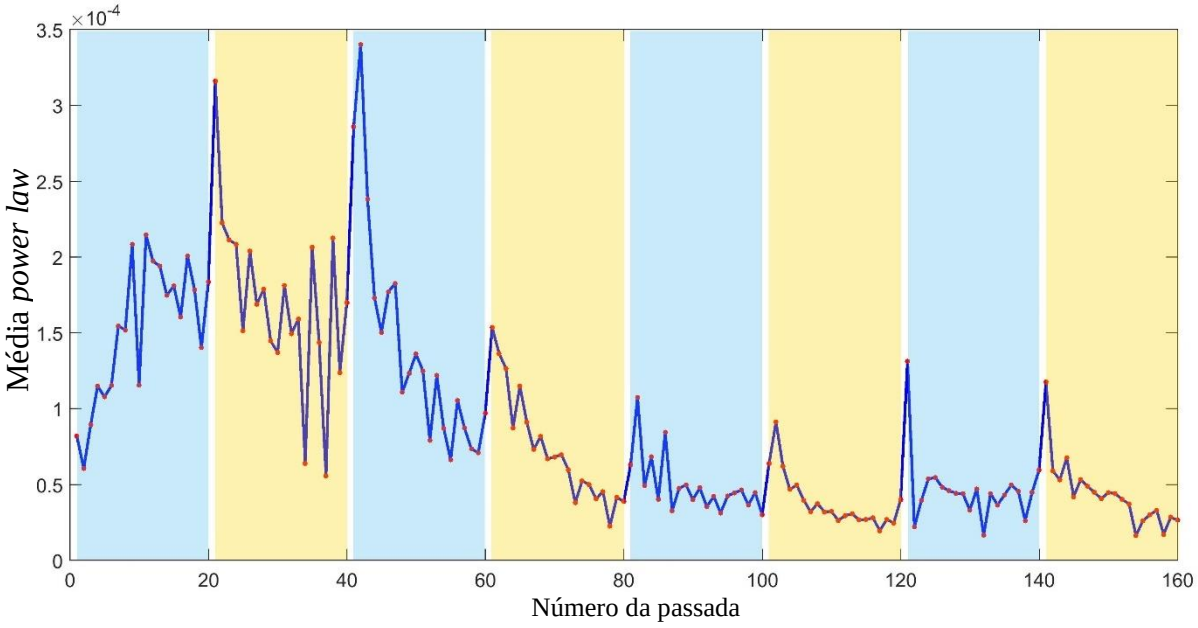
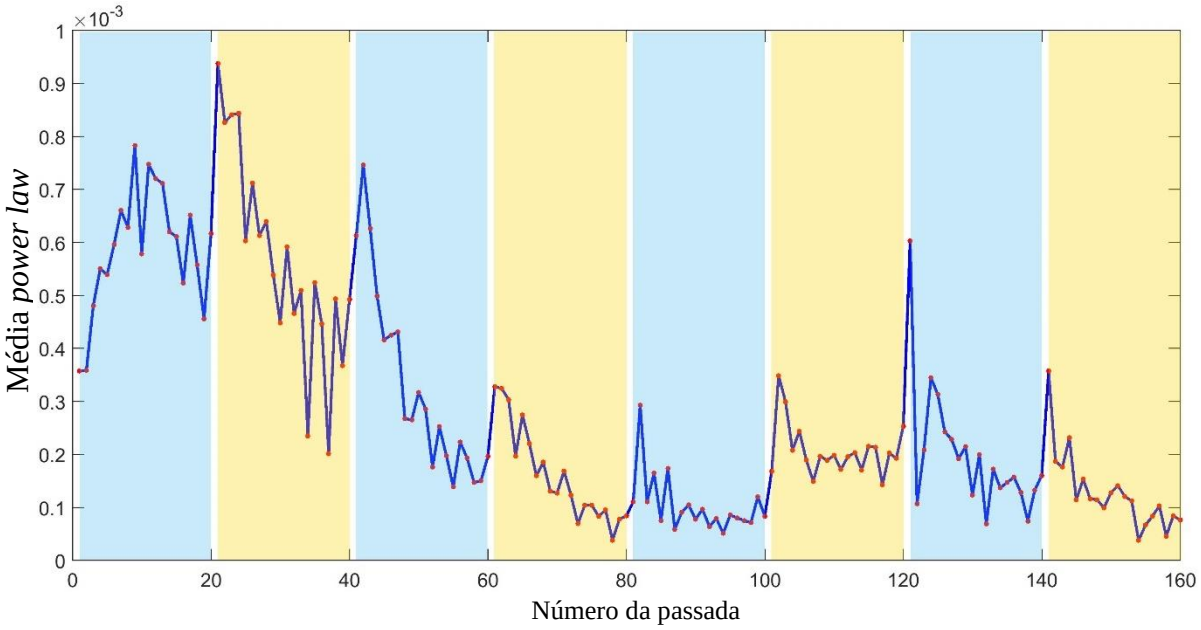


Figura A-48 – Média das passadas *power law* para a banda 8 (50 kHz a 55 kHz).



## APÊNDICE B – Instruções para Estimação do $b_d$

```
% DEPARTAMENTO DE ENGENHARIA ELÉTRICA – FEB – UNESP BAURU
% Pós-Graduação em Engenharia Elétrica
% Fábio Isaac Ferreira
% Rede Neural Estimação do bd do diamante durante a dressagem

clear all
close all
clc

% Abrindo os arquivos de treinamento
load e_treino % Dados dos sinais de emissão acústica
load s_treino % Dados do bd real

% Treinar modelo neural com a melhor topologia de rede obtida
net = feedforwardnet([10 15 10], 'trainlm');

net.divideParam.trainRatio = .7;
net.divideParam.valRatio = .15;
net.divideParam.testRatio = .15;

net.trainParam.showwindow = 0;
net.trainParam.max_fail = 15;
net.trainParam.epochs = 2000;

[net, TR] = train(net, e_treino, s_treino);

bd_estimado = net(e_treino);

figure
plot(s_treino,'b')
title('Bd real')
hold on
plot(bd_estimado,'r')
title('Bd estimado')

erros = s_treino – bd_estimado;
erros_porcentagem = erros./s_treino;

mean(erros)
std(erros)

mean(erros_porcentagem)
std(erros_porcentagem)
```

## APÊNDICE C – Instruções para Predição do $b_d$

```
% DEPARTAMENTO DE ENGENHARIA ELÉTRICA – FEB – UNESP BAURU
% Pós-Graduação em Engenharia Elétrica
% Fábio Isaac Ferreira
% Rede Neural Predição do bd do diamante durante a dressagem

clear all
close all
clc

% Abrindo arquivos de treinamento
load e_treino % Dados do bd estimado
load s_treino % Dados do bd real

p_predicao = con2seq(e_treino);
t_predicao = con2seq(s_treino);

e=p_predicao(5:end);
s=t_predicao(5:end);
Pi=p_predicao(1:4);

estrutura=[15 15 10]; % Melhor topologia de rede neural obtida

ftdnn_net = timedelaynet([1:4],estrutura);  % Janela de 4 elementos

ftdnn_net.trainParam.goal = 0.00001;
ftdnn_net.trainParam.show = 30;
ftdnn_net.trainParam.max_fail=400;
ftdnn_net.trainParam.min_grad=1e-10;
ftdnn_net.trainParam.epochs=1000;
ftdnn_net.trainParam.mc=0.5;
ftdnn_net.trainParam.lr = 0.2;

ftdnn_net=train(ftdnn_net,e,s,Pi);

yp=ftdnn_net(p_predicao,Pi);
a=seq2con(yp);
output=a{1};
rmse=sqrt(mse(ftdnn_net,s_treino,output));
```