



CARACTERIZAÇÃO DE TAMANHOS DE PARTÍCULAS SÓLIDAS UTILIZANDO EMISSÃO ACÚSTICA E INTELIGÊNCIA COMPUTACIONAL

Gilberto Magalhães Xavier

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Elétrica.

Orientador: José Manoel de Seixas

Rio de Janeiro
Março de 2019

CARACTERIZAÇÃO DE TAMANHOS DE PARTÍCULAS SÓLIDAS
UTILIZANDO EMISSÃO ACÚSTICA E INTELIGÊNCIA COMPUTACIONAL

Gilberto Magalhães Xavier

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE)
DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR
EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Examinada por:

Prof. José Manoel de Seixas, D.Sc.

Prof. Adrião Duarte Dória Neto, Dr.Ing.

Prof. Alexandre Rodrigues Tôrres, D.Sc.

Prof. Augusto Santiago Cerqueira, D.Sc.

Prof. Luiz Pereira Calôba, Dr.Ing.

Eng. Sergio Damasceno Soares, D.Sc.

RIO DE JANEIRO, RJ – BRASIL

MARÇO DE 2019

Xavier, Gilberto Magalhães

Caracterização de tamanhos de partículas sólidas utilizando emissão acústica e inteligência computacional/Gilberto Magalhães Xavier. – Rio de Janeiro: UFRJ/COPPE, 2019.

XIII, 131 p.: il.; 29, 7cm.

Orientador: José Manoel de Seixas

Tese (doutorado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2019.

Referências Bibliográficas: p. 108 – 125.

1. Tamanhos de partículas. 2. Emissão acústica.
3. Inteligência computacional. I. Seixas, José Manoel de. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

PARA MINHA FILHA CLARA.

Agradecimentos

A minha esposa, Aline, e a minha filha, Clara, pelo amor, pelo apoio e pela compreensão, sem os quais seria impossível a conclusão deste trabalho.

Aos meus pais, Regina e Reginaldo, pelo amor incondicional e por terem dedicado uma grande parte de suas vidas para que eu pudesse me tornar o que sou hoje.

A minha avó Djanira, por compartilhar sua sabedoria de 101 anos de vida, por seu amor e também por me orientar espiritualmente.

A todos os meus familiares, amigos e colegas, próximos e distantes, que sempre estiveram dispostos a me ajudar nos momentos em que mais precisei.

Aos meus superiores imediatos na Petrobras, pelo apoio e incentivo constantes ao longo de todos esses anos.

Ao Prof. Paul Wilcox da Universidade de Bristol, por ter respondido à minha mensagem desesperada.

Ao meu orientador José Manoel de Seixas, pela generosidade de me orientar e também por sua amizade, as quais foram fundamentais para a elaboração deste trabalho.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

CARACTERIZAÇÃO DE TAMANHOS DE PARTÍCULAS SÓLIDAS UTILIZANDO EMISSÃO ACÚSTICA E INTELIGÊNCIA COMPUTACIONAL

Gilberto Magalhães Xavier

Março/2019

Orientador: José Manoel de Seixas

Programa: Engenharia Elétrica

A caracterização de tamanhos de partículas sólidas desempenha um papel fundamental na qualidade de diversos produtos e no desempenho de vários processos de produção. A utilização da emissão acústica para esta tarefa é uma abordagem que oferece vantagens significativas como: não-invasividade, baixo custo e resposta rápida, resultando em melhorias relevantes no controle dos processos e na qualidade dos produtos. Por outro lado, os sinais de emissão acústica são reconhecidamente difíceis de interpretar e analisar, sendo que uma opção interessante para superar estas dificuldades é utilizar a inteligência computacional para viabilizar a extração de informação útil e relevante dos sinais de emissão acústica. Entretanto, desenvolver métodos para a caracterização de tamanhos de partículas sólidas usando emissão acústica e inteligência computacional não é uma tarefa fácil devido a vários desafios como: elevada dimensionalidade dos sinais de emissão acústica, indisponibilidade de ferramentas de simulação de fácil uso e acesso, bem como a ausência de bases de dados bem caracterizadas e reprodutíveis. Neste estudo uma modelagem para a simulação da cadeia de medição de emissão acústica foi desenvolvida, implementada e validada; uma base de dados reprodutível e bem caracterizada de sinais de emissão acústica foi produzida; sete novas abordagens que combinam técnicas de inteligência computacional e dois novos métodos de pré-processamento foram desenvolvidas, implementadas e avaliadas. Os resultados obtidos permitiram propor uma nova abordagem híbrida que combina, de uma forma inédita neste contexto, a inteligência computacional com o conhecimento especialista e os métodos tradicionais de emissão acústica. A abordagem proposta apresentou um desvio absoluto médio inferior a 1% na previsão do teor de partículas inferiores a 750 μm e possui uma vantagem adicional e inovadora de não necessitar de re-treinamento.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

SOLID PARTICLES SIZING USING ACOUSTIC EMISSION AND COMPUTATIONAL INTELLIGENCE

Gilberto Magalhães Xavier

March/2019

Advisor: José Manoel de Seixas

Department: Electrical Engineering

Solid particles sizing plays a significant role in the quality of different products and in the performance of several manufacturing processes. The use of acoustic emission for this task is an approach that offers significant advantages such as: non-invasiveness, low cost and rapid response, resulting in relevant improvements in process control and product quality. On the other hand, the acoustic emission signals are admittedly difficult to interpret and analyze, and an interesting option to overcome these difficulties is to use computational intelligence to enable the extraction of useful and relevant information from the acoustic emission signals. However, developing methods for the characterization of solid particle sizes using acoustic emission and computational intelligence is not an easy task due to several challenges such as high dimensionality of acoustic emission signals, unavailability of simulation tools that are accessible and easy to use, as well as the lack of well-characterized and reproducible databases. In this study a model for the simulation of the acoustic emission measurement chain was developed, implemented and validated; a reproducible and well-characterized database of acoustic emission signals has been produced; seven new approaches combining computational intelligence techniques and two new preprocessing methods were developed, implemented, and evaluated. The results obtained allowed to propose a new hybrid approach that combines the computational intelligence with the expert knowledge and traditional methods of acoustic emission in an unprecedented way in this context. The proposed approach has shown an average absolute deviation below 1% for the prediction of the content of particles less than 750 μm and, as an additional and innovative advantage, it does not require re-training.

Sumário

Lista de Figuras	x
Lista de Tabelas	xiii
1 Introdução	1
1.1 Motivação	2
1.2 Objetivos	3
1.3 Contribuições	4
1.4 Organização	4
2 Fundamentos Teóricos	6
2.1 Caracterização de tamanhos de partículas sólidas	6
2.1.1 Instrumentação	8
2.1.2 Extração e condicionamento da amostra	9
2.2 Emissão acústica	11
2.2.1 Cadeia de medição	12
2.2.2 Modelagem da cadeia de medição	15
2.2.3 Análise dos sinais	16
2.3 Técnicas de inteligência computacional	20
2.3.1 Projeção em estruturas latentes (PLS)	21
2.3.2 Máquina de vetor de suporte (SVM)	24
2.3.3 Máquina de melhoramento gradiente (GBM)	26
2.3.4 Perceptron de múltiplas camadas (MLP)	28
2.4 Emissão acústica aplicada à caracterização de tamanhos de partículas	30
2.4.1 Lacunas identificadas e direcionamento	41
3 Modelagem da Cadeia de Medição	42
3.1 Fonte de excitação $F_0(\omega)$	43
3.2 Propagação $G_M(r, \omega)$	45
3.2.1 Equações do movimento	46
3.2.2 Decomposição do campo de deslocamento	49
3.2.3 Excitação harmônica pontual	50

3.2.4	Generalização para uma excitação transiente	56
3.2.5	Abordagens analíticas simplificadas	57
3.3	Detector $G_D(\omega)$	60
4	Método	62
4.1	Implementação do simulador	62
4.2	Validação do simulador	63
4.3	Base de dados	64
4.4	Pré-processamentos	64
4.4.1	Especialista	65
4.4.2	Estatístico	66
4.5	Figuras de mérito, sintonia, estimação e comparação de desempenho .	67
4.6	Implementação das técnicas de IC	69
4.7	Abordagens desenvolvidas	70
4.8	Abordagem de referência	72
5	Resultados e Discussão	74
5.1	Validação do simulador	74
5.2	Base de dados	77
5.3	Abordagem baseada em parâmetros	79
5.4	Abordagem baseada em formas de onda	93
5.5	Abordagem proposta	99
5.6	Abordagem de referência	101
6	Conclusões	104
6.1	Perspectivas e trabalhos futuros	107
	Referências Bibliográficas	108
A	Caso de uso do pacote pongaR	126
B	Informação complementar	131

Lista de Figuras

2.1	Exemplos de diâmetros característicos equivalentes (adaptado de TROTTIER [22]).	7
2.2	Histogramas dos dados da Tabela 2.1 em escala linear (esquerda) e logarítmica (direita) (adaptado de TROTTIER [22]).	8
2.3	Principais fontes de erro na medição do tamanho de partícula (adaptado de MERKUS [2, p. 119]).	11
2.4	Cadeia de medição da técnica de EA (adaptado de KOCUR [39, p. 8]).	13
2.5	Esquema de um típico sensor piezoelétrico ressonante (adaptado de UNNPORSSON [46, p. 2]).	14
2.6	Diagrama de blocos de um canal do sistema AMSY-6 (adaptado de VALLEN [47, p. 12]).	14
2.7	Diagrama de blocos da cadeia de medição de EA.	15
2.8	Exemplos de espectros de frequência da fonte, do material, do sensor, do sistema de aquisição e do sinal registrado (adaptado de ONO [48, p. 1211]).	16
2.9	Exemplo de um típico sinal registrado no domínio do tempo e no domínio de frequência (adaptado de SAUSE [49, p. 49]).	17
2.10	Modelo de uma rede neural artificial direta (ou MLP) e de um neurônio artificial.	28
3.1	Coordenadas retangulares e cilíndricas polares definidas para uma placa plana, homogênea e isotrópica de espessura d	50
3.2	Excitação pontual, harmônica e axialmente simétrica aplicada na região $r \equiv \sqrt{x^2 + y^2} \leq a$ da superfície da placa.	54
3.3	Comportamento dispersivo do modo anti-simétrico de ordem zero obtido através de diferentes teorias (adaptado de MINDLIN [171][Fig. 1]).	58
3.4	Exemplo de curvas de dispersão de uma placa plana, homogênea, isotrópica ($\nu = 0,286$).	59
3.5	Curva de calibração de um sensor de EA típico (adaptado de PAC [179]).	61

3.6	Função de transferência de um sensor de EA típico.	61
4.1	Diagramas de blocos das abordagens desenvolvidas.	71
5.1	Imagem da matriz tempo-distância dos sinais de EA simulados através da abordagem analítica proposta (placa de titânio, $d = 5$ mm, fonte de excitação impulso pontual).	75
5.2	Gráfico de contorno das curvas de dispersão simuladas usando a abordagem proposta e os valores exatos da teoria analítica (linhas pontilhadas azuis).	75
5.3	Valores exatos da teoria analítica (linhas pontilhadas azuis) e máximos locais extraídos das curvas de dispersão simuladas usando a abordagem proposta (círculos pretos), a teoria de Kirchhoff-Love (quadrados vermelhos) e a teoria de Mindlin (triângulos verdes).	76
5.4	Exemplo de sinal de EA simulado.	79
5.5	Variação do índice SP com o número de estruturas latentes (técnica PLS-DA / pré-processamento especialista).	81
5.6	Relevância das variáveis (técnica PLS-DA / pré-processamento especialista).	81
5.7	Variação do índice SP com o parâmetro de regularização C (técnica C -SVC linear / pré-processamento especialista).	82
5.8	Relevância das variáveis (técnica C -SVC linear / pré-processamento especialista).	82
5.9	Variação do índice SP com o parâmetro de regularização C e com o hiperparâmetro γ (técnica C -SVC radial / pré-processamento especialista).	83
5.10	Relevância das variáveis (técnica C -SVC radial / pré-processamento especialista).	84
5.11	Variação do índice SP com o número de iterações de melhoramento e com a profundidade máxima (técnica GBM / pré-processamento especialista).	85
5.12	Relevância das variáveis (técnica GBM / pré-processamento especialista).	86
5.13	Variação do índice SP com o número de neurônios na camada escondida e com o decaimento (técnica MLP / pré-processamento especialista).	87
5.14	Relevância das variáveis (técnica MLP / pré-processamento especialista).	88
5.15	Relevância agregada das variáveis (todas as técnicas / pré-processamento especialista).	89

5.16	Desempenho dos modelos selecionados (todas as técnicas / pré-processamento especialista).	90
5.17	Diferenças de desempenho entre os modelos selecionados (todas as técnicas / pré-processamento especialista).	91
5.18	Distribuição do índice SP (técnicas selecionadas / pré-processamento especialista).	92
5.19	Desempenhos de diferentes conjuntos de parâmetros de EA (técnica MLP / pré-processamento especialista).	93
5.20	Comportamento típico do erro de reconstrução e da energia com os componentes principais (pré-processamento estatístico).	94
5.21	Variação do índice SP com o parâmetro de regularização C e com o hiperparâmetro γ (técnica C -SVC radial / pré-processamento estatístico).	95
5.22	Variação do índice SP com o número de neurônios na camada escondida e com o decaimento (técnica MLP / pré-processamento estatístico).	96
5.23	Variação do índice SP (técnicas MLP e C -SVC radial / pré-processamento estatístico).	97
5.24	Desempenho dos modelos selecionados (técnicas MLP e C -SVC radial / pré-processamento estatístico).	98
5.25	Distribuição do índice SP (técnicas MLP e C -SVC radial / pré-processamento estatístico).	99
5.26	Desempenhos das variantes selecionadas (abordagens estudadas).	99
5.27	Desempenho na previsão de finos (abordagem proposta).	100
5.28	Variação do $RMSE$ com o número de neurônios na camada escondida e com o decaimento (abordagem de referência).	102
5.29	Desempenho na previsão do teor de finos (abordagem de referência).	102
A.1	Curvas de dispersão analíticas dos primeiros três modos simétricos (S) e anti-simétricos (A) (placa de titânio, $d = 1$ mm).	128
A.2	Funções de excitabilidade adimensionais dos primeiros três modos simétricos (S) e anti-simétricos (A) (placa de titânio, $d = 1$ mm, fonte de excitação pontual).	128
A.3	Exemplo de um sinal de EA simulado (a) e seu espectro de frequência (b).	130

Lista de Tabelas

2.1	Distribuição dos tamanhos de partículas (adaptado de TROTTIER [22]).	8
2.2	Principais técnicas de caracterização (adaptado de JILLAVENKA- TESA <i>et al.</i> [23, p. 2]).	10
2.3	Parâmetros de EA básicos (adaptado de SAUSE [49, p. 49]).	18
2.4	Parâmetros de EA derivados (adaptado de SAUSE [49, p. 49]).	18
3.1	Relações entre as constantes elásticas isotrópicas.	48
5.1	Medida de concordância $sMSE$ das abordagens analíticas para cada modo de onda de Lamb.	76
5.2	Teores de finos e DTPs em número.	77
5.3	Definições utilizadas para simulação dos sinais de EA.	78
5.4	Parametrização do detector de eventos.	79
5.5	Especificação das grelhas (abordagem baseada em parâmetros).	80
5.6	Valores de sintonia dos parâmetros ajustáveis (modelos selecionados / abordagem baseada em parâmetros).	90
5.7	Estatísticas da distribuição do índice SP (todas as técnicas / pré- processamento especialista).	92
5.8	Especificação das grelhas (abordagem baseada em formas de onda).	94
5.9	Valores de sintonia dos parâmetros ajustáveis (modelos selecionados / abordagem baseada em formas de onda).	97
5.10	Estatísticas das distribuições dos desvios (abordagem proposta).	101
5.11	Especificação da grelha (abordagem de referência).	101
5.12	Estatísticas das distribuições dos desvios (abordagem de referência).	103
B.1	Codificação dos parâmetros derivados de EA.	131

Capítulo 1

Introdução

O tamanho das partículas sólidas afeta diretamente a qualidade de vários produtos, bem como o desempenho de muitos processos de produção. Por exemplo, na indústria de refino de petróleo, o monitoramento inadequado do tamanho das partículas sólidas em reatores de craqueamento catalítico fluidizado pode causar perdas financeiras da ordem de milhões de dólares por ano (COCCO *et al.* [1]).

Além disso, segundo MERKUS [2][p. 1], mais de 75% de todo o material processado na indústria é composto de material particulado sólido. Sendo assim, é fácil entender porque a caracterização de tamanhos de partículas sólidas representa um campo relevante de pesquisa.

O problema da caracterização de tamanhos de partículas sólidas é agravado pelo fato dela ser tradicionalmente realizada de modo *offline*¹, o que leva a erros na extração e preparação das amostras, além de medições com baixa frequência (ROSSETTI *et al.* [3]), longe do ideal em muitos casos.

Embora existam analisadores de tamanho de partículas sólidas que operam no modo *inline*², os elevados custos iniciais de investimento e manutenção, bem como as características do equipamento de processo, criam enormes dificuldades para usá-los e mantê-los em muitas situações (REDMAN e O'GRADY [4], MERKUS [2][p. 349]).

Em resumo, a indústria carece de técnicas para caracterização de tamanhos de partículas sólidas que não sejam intrusivas, isto é, que não requeiram amostragem ou preparação de amostras, tenham baixo custo, sejam fáceis de manter e proporcionem medições próximas do tempo real.

Uma técnica de medição que oferece estes tão desejados requisitos é a caracterização de tamanhos de partículas sólidas através de emissões acústicas, uma vez

¹No modo *offline*, o material é amostrado manualmente e a amostra é enviada a um laboratório de controle de qualidade para análise.

²No modo *inline*, o analisador encontra-se em contato direto com o processo (*in-situ*), interagindo diretamente com o material, o que elimina a etapa de amostragem.

que as colisões entre as partículas e uma placa, por exemplo, produzem sinais de emissão acústica que podem ser captados e cujas características estão relacionadas aos tamanhos das partículas que os produziram (LEACH *et al.* [5]).

Neste ponto é interessante observar que aquilo que neste trabalho é informação, em outros contextos de uso da emissão acústica, como por exemplo no caso dos ensaios não-destrutivos (emissão acústica material), é apenas ruído indesejado e perturbador que precisa ser eliminado. Ou seja, o que é ruído para uns pode ser informação para outros.

Por outro lado, devido a sua elevada dimensionalidade, baixa relação sinal-ruído e difícil interpretação, a extração de informações úteis e relevantes dos sinais de emissão acústica que permitam a determinação de tamanhos de partículas ainda é um tópico de pesquisa aberto (ROSSETTI *et al.* [3]), embora muito trabalho tenha sido feito nas últimas quatro décadas³.

Uma opção interessante para superar as desafiantes características dos sinais de emissão acústica é a utilização de técnicas de inteligência computacional, as quais possuem uma capacidade extraordinária de tratar problemas caracterizados por elevada dimensionalidade, baixa relação sinal-ruído e difícil interpretação.

De fato, a partir dos anos 90, BOUCHARD *et al.* [6] introduzem a utilização de técnicas de inteligência computacional e diversos métodos de pré-processamento para a extração de características com o objetivo de prever tamanhos de partículas sólidas a partir dos sinais de emissão acústica produzidos pelos seus impactos com um meio de propagação.

Entretanto, alguns desafios e lacunas persistem e contribuem para que a caracterização de tamanhos de partículas sólidas usando emissão acústica e inteligência computacional ainda seja considerada imatura.

1.1 Motivação

Os estudos recentes sobre o uso combinado de emissão acústica e inteligência computacional para a caracterização de tamanhos de partículas sólidas sofrem de reprodutibilidade e generalização, pois são baseados em dados de experimentos muito específicos (ROSSETTI *et al.* [3], CHEN e CHEN [7], PAPP *et al.* [8], CAO *et al.* [9], HE *et al.* [10], REN *et al.* [11], MATERO *et al.* [12, 13], BASTARI *et al.* [14], HANSULD *et al.* [15], HU *et al.* [16], ROSSETTI *et al.* [17], AN *et al.* [18]) ou simulados a partir de modelagens computacionalmente intensivas (WATSON *et al.* [19], TRAMONTANA *et al.* [20]) ou que empregam abordagens inadequadas ao contexto.

³Conforme detalhado na Seção 2.4

A ausência de dados reprodutíveis e bem caracterizados aliada a indisponibilidade de ferramentas de simulação adequadas, de fácil uso e acesso tornam bastante difícil a tarefa de desenvolver e comparar abordagens para a caracterização de tamanhos de partículas sólidas usando emissão acústica e inteligência computacional. Sendo assim, a superação destas lacunas contribui para desenvolvimento destas abordagens e é exatamente isso o que motivou a primeira etapa desta investigação.

Além disso, uma outra lacuna revelada por intermédio da revisão dos principais trabalhos publicados na área é a não incorporação do conhecimento especialista de emissão acústica associado a outros contextos como, por exemplo, o dos ensaios não-destrutivos. Esta lacuna, aliada a reconhecida dificuldade de interpretação e análise dos sinais de emissão acústica devido, principalmente, a sua elevada dimensionalidade, é o que motivou a segunda etapa desta investigação.

1.2 Objetivos

Sendo assim, este estudo almeja atacar os principais desafios do desenvolvimento de metodologias que associem a inteligência computacional e a emissão acústica para a caracterização de tamanhos de partículas sólidas, e contribuir com o esforço para o amadurecimento desta abordagem tão promissora.

Em um contexto mais amplo, este estudo possui o seguinte objetivo primário:

- propor uma nova abordagem para caracterização de tamanhos de partículas sólidas usando emissão acústica e inteligência computacional.

Desta forma, com a intenção de viabilizar o alcance deste objetivo, os seguintes objetivos secundários foram estabelecidos:

- investigar, desenvolver, implementar e validar modelagens pouco intensivas computacionalmente e de fácil utilização que permitam simular sinais de emissão acústica que sejam reprodutíveis, bem caracterizados e possuam uma exatidão adequada;
- propor e avaliar métodos de pré-processamento que permitam a extração de características dos sinais de emissão acústica, e;
- avaliar o desempenho de técnicas de inteligência computacional na caracterização de tamanhos de partículas através de diferentes abordagens de análise de sinais de emissão acústica.

Os dois últimos objetivos secundários são praticamente auto-justificados pelo objetivo primário. Entretanto, o primeiro merece uma justificativa mais detalhada a qual é fornecida a seguir.

A utilização de dados pseudo-experimentais obtidos por meio de simulação dos sinais de emissão acústica é uma opção interessante ao uso de dados experimentais, pois apresenta a vantagem de ser capaz de produzir dados reproduzíveis, bem caracterizados e com exatidão adequada, os quais são extremamente úteis tanto no desenvolvimento como também na comparação do desempenho das diferentes abordagens.

1.3 Contribuições

Investigou-se, desenvolveu-se e validou-se uma modelagem da cadeia de medição de emissão acústica adequada ao contexto da caracterização de tamanhos de partículas sólidas. A modelagem desenvolvida subsidiou a implementação de um simulador que é muito mais simples e prático do que a alternativa apresentada por WATSON *et al.* [19] e TRAMONTANA *et al.* [20], pois é computacionalmente menos intensivo, intuitivo e foi tornado público (<https://github.com/gmxavier/pongaR>).

Foram propostos e avaliados dois métodos de pré-processamento para a extração de características de sinais de emissão acústica que incluem ideias inéditas neste contexto e fazem uso do conhecimento especialista e de métodos clássicos de emissão acústica já estabelecidos em um outro contexto distinto, o dos ensaios não-destrutivos.

Avaliou-se o desempenho de quatro técnicas de inteligência computacional combinadas com os dois métodos de pré-processamento desenvolvidos, totalizando sete variantes das duas diferentes abordagens de análise de sinais de emissão acústica, ou seja, a abordagem baseada em parâmetros e a abordagem baseada em formas de onda. Os resultados obtidos nas avaliações subsidiaram a proposta de uma nova abordagem híbrida para caracterização de tamanhos de partículas sólidas que utiliza inteligência computacional e incorpora o conhecimento especialista de emissão acústica.

1.4 Organização

O Capítulo 2 fornece um resumo dos fundamentos teóricos associados à caracterização de tamanhos de partículas sólidas (Seção 2.1), à técnica de emissão acústica (Seção 2.2) e ao conjunto selecionado de técnicas de inteligência computacionais utilizadas (Seção 2.3). Ao final do Capítulo 2 o leitor irá encontrar uma visão geral dos trabalhos publicados nas últimas quatro décadas sobre o uso da emissão acústica na caracterização de tamanhos de partículas sólidas (Seção 2.4).

O Capítulo 3 detalha a proposta de modelagem da cadeia de medição de emissão acústica, incluindo o detalhamento da modelagem da fonte de excitação (Seção 3.1),

a abordagem analítica para modelagem da propagação dos sinais de emissão acústica (Seção 3.2), inédita neste contexto, como também a modelagem empírica proposta para o detector, a qual é baseada em dados disponíveis e facilmente recuperáveis (Seção 3.3).

O Capítulo 4 reúne as descrições dos métodos, a saber: os métodos para implementação e validação do simulador (Seções 4.1 e 4.2, respectivamente), os métodos relacionados à geração da base de dados (Seção 4.3), os métodos que descrevem os pré-processamentos dos sinais de EA (Seção 4.4), os métodos para obtenção das figuras de mérito, estimação e comparação do desempenho (Seção 4.5), os métodos utilizados para implementação das técnicas de IC (Seção 4.6), os métodos das abordagens desenvolvidas (Seção 4.7) e, finalmente, o método da abordagem de referência (Seção 4.8).

O Capítulo 5 resume os resultados obtidos, os quais incluem a validação do simulador (Seção 5.1), a base de dados produzida (Seção 5.2), a avaliação da abordagem baseada em parâmetros (Seção 5.3) e da abordagem baseada em formas de onda (Seção 5.4), a avaliação da abordagem proposta (Seção 5.5) e da abordagem de referência (Seção 5.6).

Por fim, o Capítulo 6 reúne as conclusões, perspectivas e trabalhos futuros.

Capítulo 2

Fundamentos Teóricos

A seguir são apresentados os fundamentos básicos necessários à compreensão da teoria envolvida na caracterização dos tamanhos de partículas sólidas, na técnica de emissão acústica e nas técnicas de inteligência computacional aqui utilizadas. Além disso, também é fornecida uma visão geral dos principais trabalhos publicados nas últimas quatro décadas associados à aplicação da emissão acústica na caracterização dos tamanhos de partículas sólidas.

2.1 Caracterização de tamanhos de partículas sólidas

O tamanho da partícula é uma das principais, quiza a mais importante propriedade física dos materiais particulados. A caracterização ou medição dos tamanhos de partículas é geralmente realizada em vários produtos e processos e, muitas vezes, é um parâmetro crítico na fabricação de muitos produtos. Segundo ALLEN [21][p. xix], os tamanhos de partículas influenciam diretamente diversas propriedades dos materiais, tais como:

- na sua taxa de reação ou de dissolução (p.e.: catalisadores, medicamentos);
- na sua estabilidade em suspensão (p.e.: medicamentos, tintas);
- na sua eficácia (p.e.: revestimentos em pó, tintas, rações animais e medicamentos);
- na sua aparência e sensação organoléptica (p.e.: café, chocolate);
- na sua eficiência da queima (p.e.: biomassa e carvão mineral);

Embora em um nível mais fundamental uma partícula possa ser definida como sendo uma sub-porção finita da matéria, no contexto deste trabalho esta definição

será restringida para incluir somente partículas sólidas com tamanhos expressos em micrômetros. O tamanho de uma partícula é usualmente expresso por seu diâmetro e tradicionalmente o estudo dos materiais particulados é restrito a faixa de 10^4 a 10^{-2} μm (TROTIER [22]).

As partículas são objetos tridimensionais que não podem ser completamente descritas por uma única dimensão linear a não ser que sejam cubos ou esferas perfeitas. Assim, para simplificar o processo de caracterização, é conveniente definir o tamanho da partícula usando o conceito de diâmetro característico equivalente. Neste caso o diâmetro da partícula é definido pelo diâmetro de uma esfera equivalente que possua a mesma propriedade (p.e.: massa, volume, área superficial, velocidade de sedimentação, etc.) que a partícula real. É importante ressaltar que diferentes métodos de caracterização utilizam diferentes diâmetros característicos equivalentes e portanto poderão não fornecer exatamente o mesmo resultado para o diâmetro da partícula. A Figura 2.1 mostra alguns exemplos de diâmetros característicos equivalentes.

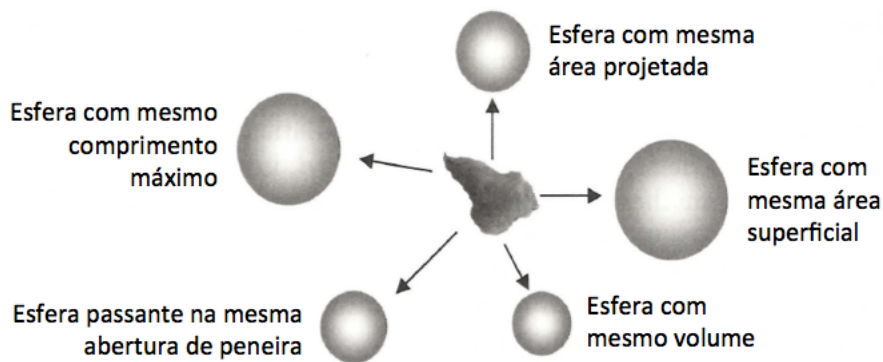


Figura 2.1: Exemplos de diâmetros característicos equivalentes (adaptado de TROTIER [22]).

A escolha do diâmetro característico equivalente a ser usado vai depender da aplicação e deve levar em consideração as informações necessárias à interpretação dos dados de tamanho da partícula. Por exemplo, no caso da produção de tintas, o diâmetro característico equivalente que melhor descreve o poder de recobrimento é o da área projetada. Já na produção de catalisadores, o diâmetro característico equivalente mais adequado é o da área superficial.

Por fim, um outro aspecto importante da caracterização dos tamanhos de partículas está relacionado à apresentação dos resultados. Sistemas particulados monodispersos, ou seja, compostos de partículas idênticas são extremamente raros. A quase totalidade dos sistemas particulados são polidispersos e consistem de uma distribuição estatística de partículas de diferentes tamanhos. Sendo assim, é uma prática comum representar esta distribuição dos tamanhos de partículas na forma

de uma curva de distribuição de frequência ou de uma curva de distribuição cumulativa. Exemplos de apresentação destes resultados em formato tabular e gráfico são mostrados na Tabela 2.1 e na Figura 2.2, respectivamente.

Tabela 2.1: Distribuição dos tamanhos de partículas (adaptado de TROTTIER [22]).

Faixa de diâmetro [μm]	Número [-]	Percentual [%]	Finos acumulados [%]
1-2	12	1.2	1.2
2-4	62	6.2	7.4
4-8	185	18.5	25.9
8-16	250	25.0	50.9
16-32	295	29.5	80.4
32-64	172	17.2	97.6
64-128	22	2.2	99.8
128-256	2	0.2	100.0




Figura 2.2: Histogramas dos dados da Tabela 2.1 em escala linear (esquerda) e logarítmica (direita) (adaptado de TROTTIER [22]).

2.1.1 Instrumentação

A distribuição dos tamanhos de partículas (DTP) pode ser determinada usando vários instrumentos disponíveis comercialmente ou usando instrumentos especialmente projetados para operar em ambientes específicos. Do ponto de vista do modo de operação, a grande maioria dos instrumentos comerciais opera em modo *offline*, embora alguns poucos também sejam aptos a operar em modo *online*, como também *inline*.

No modo *offline*, mais comum, amostras representativas dos materiais são manualmente extraídas, condicionadas e enviadas ao laboratório de controle de qualidade onde se encontra o instrumento de análise. Já nos modos *online* e *inline*, o instrumento encontra-se localizado no chão-de-fábrica, integrado ao processo produtivo e

em contato direto com o material, no caso do modo *inline*, ou dispendo de meios automáticos para a extração, condicionamento e análise das amostras, no caso do modo *online*. Operando em modos *online* ou *inline*, os instrumentos são capazes de fornecer medidas praticamente em tempo real permitindo assim o controle e monitoramento automáticos dos processos.

A Tabela 2.2 mostra um resumo das principais técnicas de caracterização dos tamanhos de partículas disponíveis. Uma discussão, mesmo que resumida, de cada uma destas técnicas está além do escopo deste trabalho. O leitor interessado em maiores detalhes poderá encontrá-los em diversas referências como em MERKUS [2], TROTTIER [22] e JILLAVENKATESA *et al.* [23].

2.1.2 Extração e condicionamento da amostra

Materiais particulados são normalmente produzidos, processados e armazenados em quantidades muito grandes (p.e.: toneladas), as quais normalmente são segregadas em lotes de fabricação.

Contrastando com os tamanhos típicos destes lotes, pequenas amostras variando de quilogramas a miligramas são utilizadas para a caracterização de um lote. Quase sempre é dado como certo que pequenas amostras extraídas e o lote têm a mesma composição, em outras palavras, que a amostra é representativa do lote. Em geral, no entanto, esta hipótese está longe de ser realista principalmente quando se deseja extrair uma amostra de 10 g representativa de um lote de fabricação de 10.000 kg.

Além disso, dependendo da técnica utilizada, a amostra extraída pode não se encontrar na forma adequada para apresentação ao instrumento. Por exemplo, algumas técnicas como a difração laser necessitam que a amostra sólida seja dispersa em um líquido para que a análise possa ser efetuada. Esta etapa intermediária entre a extração da amostra e sua análise propriamente dita é chamada de condicionamento (ou preparação) da amostra.

Cada uma destas etapas, além do próprio instrumento, irá representar uma fonte de erro. Na Figura 2.3 é ilustrada de forma genérica as contribuições do instrumento e das etapas de extração e condicionamento da amostra no erro de medição do tamanho de partícula.

Analisando a Figura 2.3 fica claro que as etapas de extração e condicionamento da amostra representam o grande calcanhar de Aquiles das técnicas de caracterização dos tamanhos de partículas, influenciando de forma significativa o erro total da medição.

A etapa de extração é frequentemente listada como a causa raiz de medições incorretas que podem resultar em enormes perdas financeiras, sobretudo no caso de produtos de alto valor agregado como os medicamentos. Além disso a necessidade

Tabela 2.2: Principais técnicas de caracterização (adaptado de JILLAVENKATESA *et al.* [23, p. 2]).

Técnica instrumental	Estabelecida?	Princípio físico	Faixa de medição [μm]
Espectroscopia de atenuação acústica	Não	Ultrassom	0,05 a 10
Sedimentação centrífuga e detecção óptica	Sim	Sedimentação	0,01 a 30
Sedimentação centrífuga e detecção por raios-X	Sim	Sedimentação	0,01 a 100
Eletrozona	Sim	Contagem de partículas	0,4 a 1.200
Espectroscopia eletroacústica	Não	Ultrassom	0,1 a 10
Difração laser	Sim	Espalhamento e interação de radiação eletromagnética	0,04 a 1.000
Microscopia óptica	Sim	Contagem de partículas	>1.0
Espalhamento de luz quasi-elástico	Sim	Espalhamento e interação de radiação eletromagnética	0,003 a 6
Microscopia de varredura eletrônica	Sim	Contagem de partículas	>0,1
Sedimentação gravitacional e detecção por raios-X	Sim	Contagem de partículas	0,5 a 100
Microeletroforese	Sim	Espalhamento e interação de radiação eletromagnética	0,1 a 1
Peneiramento	Sim	Peneiramento	5 a 10.000

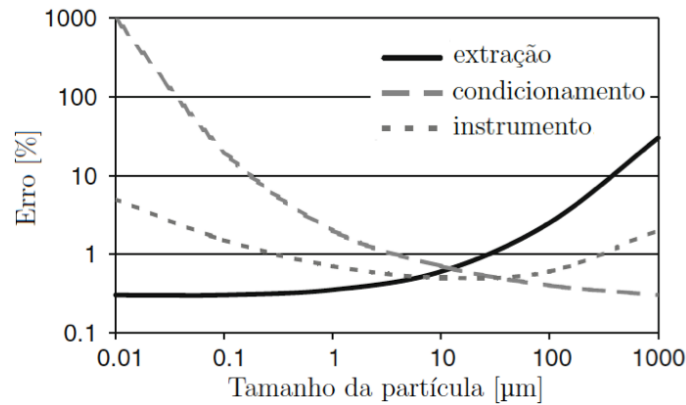


Figura 2.3: Principais fontes de erro na medição do tamanho de partícula (adaptado de MERKUS [2, p. 119]).

destas duas etapas também contribui para o aumento do custo total da análise, uma vez que demandam mais recursos de mão-de-obra e manutenção.

Portanto, é extremamente bem-vindo pela indústria o desenvolvimento de técnicas que não demandem a extração e o condicionamento de amostras como é o caso da que esta sendo proposta neste projeto de pesquisa.

2.2 Emissão acústica

O termo emissão acústica (EA) é usado no âmbito dos ensaios não-destrutivos para descrever o fenômeno pelo qual ondas elásticas transientes são geradas pela liberação rápida de energia de fontes localizadas em um material ensaiado (SOARES [24], ABNT [25]).

Uma definição mais informal e abrangente é dada por BEATTIE [26], segundo o qual a EA é o estudo e a utilização prática de ondas elásticas geradas por um material sujeito a um tensionamento externo.

Dado que o impacto de uma partícula sólida sobre a superfície de um material representa um tensionamento externo, esta última definição é bastante oportuna na medida em que ela permite associar o termo emissão acústica ao trabalho aqui apresentado.

De uma forma bem simples e objetiva pode ser afirmado que a emissão acústica é um fenômeno análogo a um terremoto. Assim o significado do termo é melhor compreendido pela análise das semelhanças entre ambos os fenômenos. Um terremoto é um fenômeno natural onde ocorre um movimento rápido de placas da crosta terrestre. Este deslocamento libera grandes quantidades de energia e gera ondas elásticas conhecidas como ondas sísmicas. Estas ondas se propagam esfericamente (em três dimensões) ao longo das camadas do subsolo e cilíndricamente (em duas dimensões) ao longo do solo.

Analogamente, no caso da EA, a onda elástica gerada percorre todo o material e também pode ser detectada a distâncias consideráveis de seu ponto de origem. Viajando desde a fonte até o ponto de detecção, a onda é sujeita a todas as características e variações de seu percurso acústico. Sua energia é atenuada por espalhamento geométrico e espalhamento por variações microscópicas e macroscópicas na estrutura do material.

O conteúdo de frequência da onda é determinado pela fonte e modificado a medida que esta se propaga através do material e ao longo de sua superfície. Em função disto, um observador fixo em um dado ponto do material irá observar formas de onda completamente diferentes resultantes de fontes idênticas originadas em locais diferentes. Este fato é o principal motivo que torna a análise de sinais de EA extremamente complexa.

As ondas propagadas são normalmente detectadas por um ou mais sensores que neste caso funcionam de forma semelhante a sismógrafos, convertendo os deslocamentos da superfície do material em sinais de tensão elétrica. Estes sinais elétricos são processados por uma instrumentação apropriada para análise posterior visando a identificação da fonte como também sua localização.

É interessante observar que no contexto dos ensaios não-destrutivos as fontes primárias geradoras de sinais de EA são aquelas associadas aos processos de fratura e deformação. Entretanto, outras fontes secundárias como vazamentos (BRUNNER e BARBEZAT [27], SOHAIB *et al.* [28]), fricção (BENABDALLAH e AGUILAR [29]), impacto (MOSER *et al.* [30]), cavitação (ALFAYEZ *et al.* [31]), mudanças de estado físico ou de fase cristalina (SAWADA *et al.* [32], BUILO e KUZNETSOV [33], SERRIS *et al.* [34]) e até mesmo reações químicas (BELCHAMBER *et al.* [35], WADE [36], WENTZELL *et al.* [37], VAN DIJCK e VAN HULLE [38]) também são capazes de gerar sinais de EA que podem ser detectados e analisados usando a mesma cadeia de medição.

A capacidade da técnica de EA de também detectar e analisar sinais gerados por fontes secundárias resultou na expansão das aplicações da técnica de EA para além das aplicações clássicas de detecção, localização e avaliação de falhas em estruturas de metal, concreto ou materiais compósitos. Atualmente a tecnologia de EA também é empregada em várias outras aplicações como, por exemplo, na detecção de vazamentos, na localização e monitoramento de corrosão, no monitoramento da integridade de equipamentos, na localização e avaliação de danos por impactos e também na caracterização dos tamanhos de partículas sólidas.

2.2.1 Cadeia de medição

A Figura 2.4 mostra a cadeia de medição da técnica de EA.

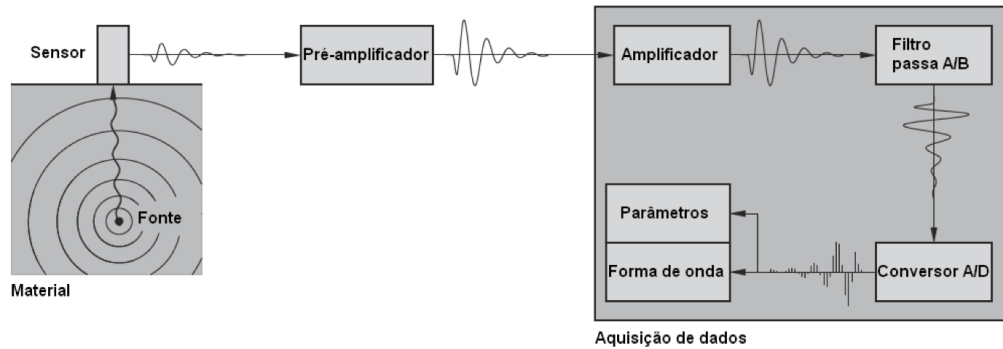


Figura 2.4: Cadeia de medição da técnica de EA (adaptado de KOCUR [39, p. 8]).

As deflexões da superfície do material são detectadas por sensores extremamente sensíveis capazes de detectar deformações da ordem de vários picômetros. Vários tipos de sensores podem ser empregados, entretanto em função das suas características de sensibilidade, robustez, custo e facilidade de manuseio, os sensores piezoelétricos são os mais populares em EA. Embora os sensores piezoelétricos sejam descritos em numerosos artigos e livros (GAUTSCHI [40], SAFARI e AKDOGAN [41]), duas características que desempenham um papel importante na detecção dos sinais de EA devem ser destacadas, a saber a sensibilidade e a faixa de frequência.

Para melhorar a sua sensibilidade, os sensores normalmente são operados em ressonância, ou seja, os sinais são detectados preferencialmente em um pequeno intervalo de frequências em função das características do sensor. A desvantagem desta abordagem é que normalmente a análise das frequências presentes no sinal é dificultada em função de que serão sempre realçadas aquelas frequências que se situam na faixa de operação do sensor. Esta dificuldade foi logo percebida pelos pesquisadores na medida em que os fundamentos teóricos da EA foram sendo desenvolvidos. Isto resultou no desenvolvimento de sensores de banda larga e alta sensibilidade que fornecem uma resposta "horizontal", ou seja, praticamente a mesma resposta em uma ampla faixa de frequência (PROCTOR [42], BUTTLE e SCRUBY [43], EVANS [44], MCLASKEY e GLASER [45]).

A Figura 2.5 mostra uma visão esquemática de um típico sensor piezoelétrico ressonante. Os sensores são fixados contra a superfície do material e os deslocamentos são transferidos para o elemento piezoelétrico dentro do sensor através da placa de contato¹. As vibrações mecânicas deformam o elemento piezoelétrico o qual responde gerando um sinal de tensão elétrica. O sinal gerado pelo sensor é, portanto, uma representação unidimensional no tempo da variação temporal de um deslocamento tridimensional da superfície.

¹Acoplantes (p.e.: graxa de silicone) são aplicados entre a superfície do material e a placa de contato para melhorar a transmissão dos sinais de EA.




Figura 2.5: Esquema de um típico sensor piezoelétrico ressonante (adaptado de UNNPORSSON [46, p. 2]).

Em função da sua baixa intensidade, o sinal de tensão elétrica produzido pelo elemento piezoelétrico é normalmente pré-amplificado² antes de ser transmitido ao equipamento de aquisição de dados.

Nos equipamentos comerciais de EA, como o AMSY-6 (VALLEN [47]), o sinal pré-amplificado proveniente do sensor é então processado conforme mostra a Figura 2.6.

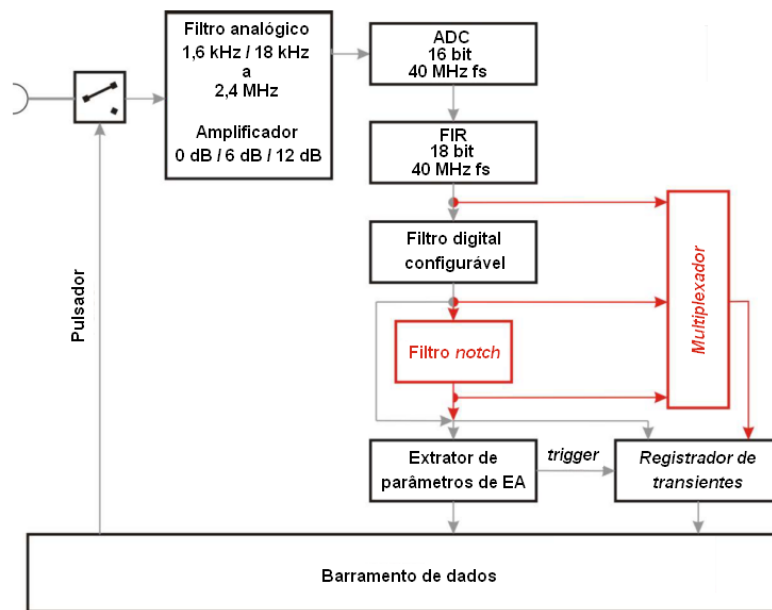


Figura 2.6: Diagrama de blocos de um canal do sistema AMSY-6 (adaptado de VALLEN [47, p. 12]).

Neste caso, o sinal de EA analógico é alimentado a um amplificador de ganho programável, a um filtro analógico passa alta (18 kHz ou 1,6 kHz), a um filtro analógico passa baixa *anti-aliasing* de 2,4 MHz e posteriormente ao conversor A/D,

²Frequentemente dentro do próprio sensor.

o qual converte o sinal de EA analógico filtrado e amplificado em um sinal de EA digital a uma taxa de amostragem de 40 MHz com 16 bit de resolução.

Uma filtragem digital adicional pode ser realizada e na sequência o sinal de EA digital resultante é processado para extração de diversos parâmetros (Tabelas 2.3 e 2.4) e, opcionalmente, as formas de onda dos sinais de EA digitalizados são então armazenadas para análises posteriores.

2.2.2 Modelagem da cadeia de medição

Na maioria dos casos práticos de interesse, os deslocamentos superficiais gerados pelas fontes de EA são muitas ordens de grandeza inferiores às dimensões do material em que o fenômeno da EA é observado. Além disso, a geração, propagação e detecção dos sinais de EA ocorre em uma escala de tempo da ordem de milésimos, ou mesmo microlesimos, de segundo.

Como as variações no tempo e no espaço são pequenas, a cadeia de medição mostrada na Figura 2.4 pode ser modelada como um sistema linear invariante no tempo usando o conceito de funções de transferência (ONO [48]).

No domínio da frequência a relação entre uma função de entrada $X(\omega)$ e uma função de saída $Y(\omega)$ é dada pela função de transferência $H(\omega)$:

$$Y(\omega) = X(\omega)H(\omega) \quad (2.1)$$

ou seja, no domínio da frequência a saída de um sistema é dada simplesmente pelo produto entre a função de entrada e a sua função de transferência.

Neste caso, a cadeia de medição pode ser representada na forma de um diagrama de blocos conforme mostra a Figura 2.7, onde $U(r, \omega)$ representa o deslocamento da superfície do material observado por um sensor localizado a uma distância r da fonte de excitação.




Figura 2.7: Diagrama de blocos da cadeia de medição de EA.

Além disso, a função de transferência global de sistemas associados em série pode ser escrita como o produto entre as funções de transferência de cada sistema. Desta forma, tomando como base o diagrama de blocos da Figura 2.7, o sinal registrado $V(r, \omega)$ será dado por:

$$V(r, \omega) = F_0(\omega)G_M(r, \omega)G_D(\omega) \quad (2.2)$$

onde $G_M(r, \omega)$ e $G_D(\omega)$ representam, respectivamente, as funções de transferência da propagação e do detector e $F_0(\omega)$ representa a fonte de excitação. O detector é definido aqui como o conjunto formado pelo sensor e pelo sistema de aquisição, ou seja:

$$G_D(\omega) = G_S(\omega)G_A(\omega) \quad (2.3)$$

onde $G_S(\omega)$ e $G_A(\omega)$ são, respectivamente, as funções de transferência do sensor e do sistema de aquisição. A Figura 2.8 mostra alguns exemplos de espectros de frequência da fonte, destas funções de transferência e do sinal registrado, obtidos numericamente usando o método dos elementos finitos (SAUSE [49]).

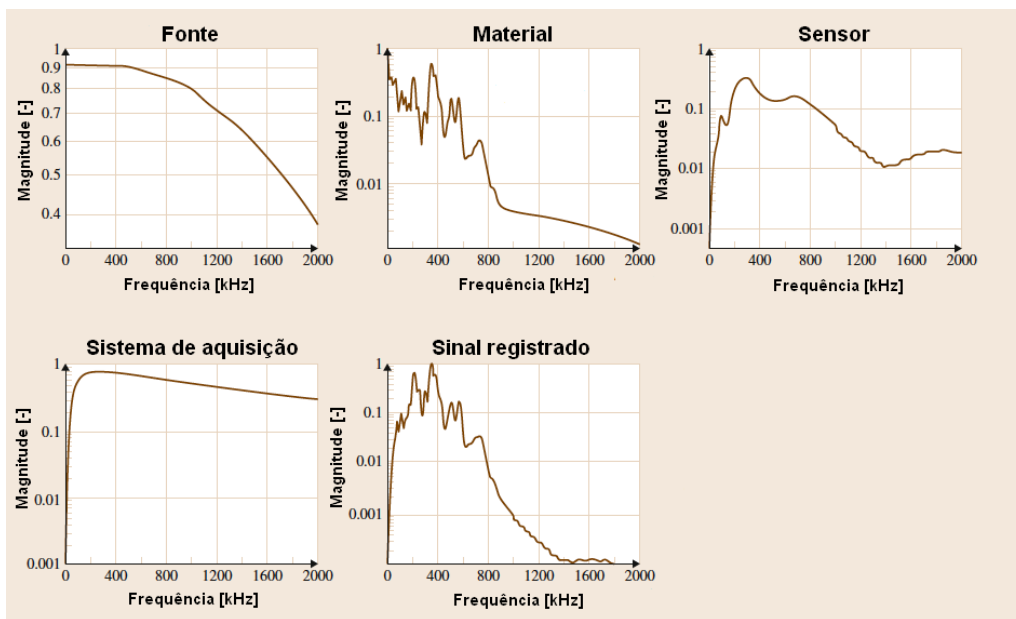


Figura 2.8: Exemplos de espectros de frequência da fonte, do material, do sensor, do sistema de aquisição e do sinal registrado (adaptado de ONO [48, p. 1211]).

2.2.3 Análise dos sinais

As abordagens de análise dos sinais de EA podem ser divididas em dois grandes grupos: as baseadas em parâmetros (clássicas) e as baseadas em forma de onda (quantitativas).

O motivo da existência destas duas abordagens está relacionado aos rápidos e crescentes desenvolvimentos na microeletrônica ao longo das últimas décadas. Historicamente, no início das aplicações práticas da EA era impossível registrar e armazenar um grande número de formas de onda de sinais de EA, mesmo que em um curto período de tempo. Embora os recentes avanços técnicos tenham viabilizado o armazenamento de extensas formas de onda e o surgimento de modernas técnicas que nelas são baseadas, o custo ainda relativamente elevado dos equipamentos de

aquisição que permitem adquiri-las é o motivo pelo qual as técnicas baseadas em parâmetros ainda são tão populares.

Abordagem baseada em parâmetros

Na abordagem clássica baseada em parâmetros, o sinal de EA digitalizado é processado via *software* de tal forma que um conjunto de parâmetros é extraído e posteriormente armazenado, enquanto o sinal propriamente dito é simplesmente descartado após a extração dos parâmetros. A ideia é que os sinais de EA são completamente descritos por este conjunto de parâmetros e o armazenamento desta relativamente pequena quantidade de dados consome menos tempo e espaço de armazenamento quando comparado aos dados da forma de onda completa.

A extração dos parâmetros do sinal de EA, além de reduzir a quantidade de informação contida na forma de onda do sinal a alguns poucos parâmetros (SAUSE [49]), tem a função, no contexto da inteligência computacional, de reduzir a dimensionalidade (compactar) e maximizar a separação das classes. Conforme mostrado na Figura 2.9, para um típico sinal registrado vários parâmetros podem ser utilizados, tanto no domínio do tempo quanto no domínio da frequência.




Figura 2.9: Exemplo de um típico sinal registrado no domínio do tempo e no domínio de frequência (adaptado de SAUSE [49, p. 49]).

Apesar de alguns destes parâmetros já fazerem parte de normas brasileiras e internacionais (ABNT [25], ASTM [50]), as definições dadas por diferentes fabricantes de sistemas de aquisição de EA apresentam algumas discrepâncias.

Desta forma, dado que a definição e o cômputo destes parâmetros é uma etapa importante que antecede a aplicação das técnicas de inteligência computacional, todos os parâmetros utilizados serão brevemente resumidos.

Enquanto os parâmetros básicos da Tabela 2.3 são praticamente auto-explicativos e cobertos pelas normas técnicas mencionadas anteriormente, este não é necessariamente o caso dos parâmetros derivados mostrados na Tabela 2.4. Como mencionado anteriormente, alguns destes parâmetros apresentam definições discre-

pantes entre os diversos fornecedores fabricantes de sistemas de aquisição e, portanto, serão definidos aqui na forma em que serão usados no contexto desta investigação.

Tabela 2.3: Parâmetros de EA básicos (adaptado de SAUSE [49, p. 49]).

Parâmetro	Definição	Unidade
t_0	Primeiro valor que excede o limiar	[s]
N_{EA}	Número de cruzamentos do limiar	[-]
t_{EA}	Intervalo entre o primeiro e o último valor que excede do limiar	[μ s]
V_{max}	Valor máximo do sinal	[V]
t_{pico}	Instante de tempo do valor máximo do sinal	[μ s]
f_{pico}	Frequência da máxima contribuição do sinal	[kHz]
N_{pico}	Número de cruzamentos do limiar entre t_0 e t_{pico}	[-]

Tabela 2.4: Parâmetros de EA derivados (adaptado de SAUSE [49, p. 49]).

Parâmetro	Definição	Unidade
Amplitude	$V_{dB} = 20 \log (V_{max}/1\mu V) - G_{preamp}$	[dB]
Contagem	N_{EA}	[-]
Duração	t_{EA}	[μ s]
Tempo de subida	$t_s = t_{pico} - t_0$	[μ s]
Contagem até o pico	N_{pico}	[-]
Valor quadrático médio	$V_{RMS} = \sqrt{\frac{1}{T} \int_{t_0}^{t_0+T} (V(t))^2 dt}$	[V]
Valor médio do sinal	$V_{ASL} = \sqrt{\frac{1}{T} \int_{t_0}^{t_0+T} V_{dB}(t) dt}$	[dB]
Frequência média	$f_{med} = N_{EA}/t_{EA}$	[kHz]
Frequência de reverberação	$f_{rev} = \frac{N_{EA} - N_{pico}}{t_0 + t_{EA} - t_{pico}}$	[kHz]
Frequência inicial	$f_{ini} = \frac{N_{pico}}{t_{pico} - t_0}$	[kHz]
Ângulo de subida	$\varphi_{sub} = \frac{180}{\pi} \tan^{-1} \left(\frac{V_{max}}{t_{pico} - t_0} \right)$	[$^\circ$]
Ângulo de descida	$\varphi_{dec} = \frac{180}{\pi} \tan^{-1} \left(\frac{V_{max}}{t_0 + t_{EA} - t_{pico}} \right)$	[$^\circ$]
Energia absoluta	$W_{EA} = \int_0^{t_{EA}} \frac{(V(t))^2}{10k\Omega} dt$	[nJ]
Frequência do pico	f_{pico}	[kHz]
Frequência centróide	$f_{cent} = \frac{\int fV(f)df}{\int V(f)df}$	[kHz]
Frequência ponderada	$f_{pond} = \sqrt{f_{pico} f_{centroid}}$	[kHz]
Potência parcial	$PP_{[f_1:f_2]} = 100 \frac{\int_{f_1}^{f_2} (U(f))^2 df}{\int_{f_i}^{f_f} (U(f))^2 df}$	[%]

A maioria dos parâmetros utilizados para descrever um sinal registrado é composta de valores extremos do sinal derivados dos domínios do tempo e da frequência conforme mostrado na Figura 2.9. Os valores quadrático médio V_{RMS} e médio do sinal V_{ASL} são utilizados como na eletrônica, onde descrevem a tensão efetiva em um intervalo de tempo característico T .

As três diferentes frequências de contagem, inicial f_{ini} , de reverberação f_{rev} e média f_{med} são usadas para fornecer uma estimativa da frequência característica antes e depois do valor máximo e como uma média de todo o sinal. Isto não deve ser entendido como uma análise de frequência, uma vez que o número de cruzamentos do limiar é normalmente muito baixo e assim fornece resultados muito imprecisos a cerca da frequência. Ao invés disso, as diferentes razões obtidas a partir destas três frequências podem ser usadas como uma medida da simetria do sinal.

Uma medida semelhante pode ser obtida a partir dos ângulos de subida φ_{sub} e descida φ_{dec} . Estes são utilizados para descrever os ângulos de inclinação das retas que unem o valor máximo do sinal aos pontos do primeiro e do último cruzamento do limiar. Já a energia absoluta W_{EA} é uma medida absoluta da energia elétrica do sinal registrado, considerando que a impedância de entrada do sistema de aquisição seja de $10\text{ k}\Omega$.

A frequência centróide f_{cent} é usada para caracterizar o conteúdo global de frequência do sinal registrado de maneira similar a que o centro de massa é usado para descrever as propriedades geométricas de um objeto com densidade constante. Assim ela pode ser entendida como uma informação adicional sobre a característica média de frequência do sinal e em geral é diferente da frequência da máxima contribuição do sinal f_{pico} . Esta última, por sua vez, é um parâmetro que apresenta elevada eficiência de discriminação dos sinais.

Para melhorar a representação de uma frequência característica associada ao sinal registrado foi também definida a frequência ponderada f_{pond} que combina a eficiência discriminadora da frequência da máxima contribuição do sinal f_{pico} com a informação sobre o conteúdo médio de frequência do sinal expresso pela frequência centróide f_{cent} . De forma similar, os diferentes níveis de potência parcial³ medem as contribuições de frequência dos sinais em um dado intervalo de frequência e assim são capazes de capturar a composição de frequência do sinal em mais de um valor característico.

Abordagem baseada em formas de onda

A abordagem quantitativa baseada em formas de onda envolve o registro e o armazenamento das formas de onda dos sinais registrados, o que permite uma análise de dados mais abrangente. O termo quantitativa foi introduzido por diversos autores (SCRUBY [51], SACHSE e KIM [52]) na década de 80 para diferenciá-la da abordagem paramétrica clássica.

Segundo GROSSE e OHTSU [53], uma das grandes vantagens da abordagem quantitativa é a capacidade de discriminação entre sinal e ruído baseada nas formas

³Neste estudo são utilizados quatro níveis definidos na Tabela B.1.

de onda, uma vez que as mesmas ainda são disponíveis após a medição e não foram eliminadas como normalmente é feito na abordagem clássica. Além disso é possível também aplicar diferentes métodos de análise de sinais usando algoritmos de pós-processamento. Estes algoritmos podem incluir diferentes técnicas de filtragem para melhorar a relação S/R, métodos de seleção e extração de características, redução de dimensionalidade e algoritmos de agrupamento e classificação (POMPONI e VINOGRADOV [54], RAMASSO *et al.* [55], ROSSETTI *et al.* [17], AGLETDINOV *et al.* [56])

A confiabilidade da interpretação dos dados pode ser melhorada significativamente se abordagens baseadas em forma de onda forem usadas. A desvantagem destas abordagens é que normalmente o volume de dados armazenado é muito grande.

Por exemplo, se 100 sinais de EA forem registrados por 16 sensores e convertidos com uma resolução de 16 bit a uma taxa de amostragem de 10 MHz com 2048 amostras cada um, a quantidade de dados a ser armazenada é da ordem de 8,5 GB. Durante um ensaio de EA este valor pode ser facilmente atingido em questão de minutos ou mesmo segundos, causando problemas até mesmo para os mais modernos sistemas de aquisição de EA.

Para reduzir a quantidade de dados a ser armazenada, ou seja, para eliminar dados que não sejam diretamente relacionados às fontes de EA, técnicas sofisticadas de *triggering* podem ser aplicadas.

A abordagem baseada em formas de onda ainda é um campo relativamente novo de pesquisa e, como resultado, existe uma carência de algoritmos e *software* para serem utilizados em um ambiente onde um número muito grande de sinais de EA deve ser processado automaticamente.

2.3 Técnicas de inteligência computacional

As subseções a seguir fornecem uma descrição resumida das técnicas de inteligência computacional (IC) utilizadas. Diferentes motivações levaram a seleção prévia destas técnicas em detrimento de tantas outras disponíveis e provavelmente também adequadas ao contexto.

Por exemplo, no caso da técnica projeção em estruturas latentes, o seu emprego em trabalhos anteriores (PAPP *et al.* [8], MATERO *et al.* [12, 13]) e a experiência anterior e bem sucedida do autor no emprego desta técnica em aplicações de quimiometria (CUNHA *et al.* [57]) foram as motivações da escolha.

O emprego em diversos trabalhos anteriores (ROSSETTI *et al.* [3], BOUCHARD *et al.* [6], CHEN e CHEN [7], BASTARI *et al.* [14], ROSSETTI *et al.* [17]) e suas posições no topo da lista das técnicas de IC motivaram a seleção das técnicas máquina de vetor de suporte e perceptron de múltiplas camadas.

Por fim, o fato de não ter sido utilizada em trabalhos anteriores e de também figurar como um algoritmo de aprendizagem de máquina bastante utilizado em função da sua eficiência, precisão e interpretabilidade (KE *et al.* [58]) motivaram a escolha da técnica máquina de melhoramento gradiente, embora a mesma apresente também algumas limitações na presença de rótulos ruidosos conforme relatado em LONG e SERVEDIO [59] e GÓMEZ-RÍOS *et al.* [60].

2.3.1 Projeção em estruturas latentes (PLS)

A projeção em estruturas latentes⁴ (PLS)(WOLD *et al.* [62], ABDI [63]) é uma técnica de IC que teve origem na Economia, ficou popular na quimiometria (ERIKSSON *et al.* [64], HALSTENSEN *et al.* [65]) e atualmente é aplicada até no processamento de imagens por ressonância magnética funcional (fMRI)(ANDERSEN *et al.* [66]). Ela tem sido desenvolvida por mais de 40 anos e pode ser empregada no aprendizado supervisionado tanto em problemas de regressão (PLS-R), quanto de classificação (PLS-DA). De certa forma, a PLS pode ser encarada como um "PCA supervisionado". Mas por que?

Considerando inicialmente um problema de regressão onde se dispõe de uma matriz de entradas \mathbf{X} e uma matriz de saídas \mathbf{Y} , a solução mais direta possível é a regressão linear múltipla (MLR), ou seja:

$$\mathbf{Y} = \mathbf{X}\mathbf{B} + \epsilon \quad (2.4)$$

onde ϵ é a matriz de resíduos e a solução de mínimos quadrados para B é dada por:

$$\mathbf{B} = (\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T\mathbf{Y} \quad (2.5)$$

O problema é que muitas vezes $\mathbf{X}^T\mathbf{X}$ é singular, ou porque o número de variáveis (colunas) em \mathbf{X} é maior que o número de observações (linhas), ou devido a colinearidades. Uma solução para este caso é decompor a matriz \mathbf{X} usando a PCA⁵, aproximá-la através de seus k componentes principais mais relevantes, ou seja:

$$\tilde{\mathbf{X}}_k = \mathbf{T}_k\mathbf{P}_k^T + \epsilon_X \quad (2.6)$$

e então obter a regressão entre \mathbf{Y} e $\tilde{\mathbf{X}}_k$, o que resulta nos seguintes coeficientes de regressão⁶:

$$\mathbf{B} = \mathbf{P}(\mathbf{T}^T\mathbf{T})^{-1}\mathbf{T}^T\mathbf{Y} \quad (2.7)$$

⁴Também conhecida como mínimos quadrados parciais (HASTIE *et al.* [61, p. 80])

⁵PEARSON [67]

⁶Onde \mathbf{T} e \mathbf{P} são as matrizes de escores e carregamentos, respectivamente (os subscritos k foram omitidos para maior clareza).

Esta abordagem, conhecida como regressão por componentes principais (PCR), é bastante simples, objetiva e contorna o problema da MLR, porém possui uma limitação. Na PCR, a informação nas variáveis independentes é compactada em um número k de componentes principais. Entretanto, não existe nenhum motivo *a priori* que garanta que os componentes principais associados aos maiores valores singulares sejam os mais úteis para a regressão.

Em outras palavras, dado que a PCA compacta a informação em \mathbf{X} sem levar em conta o que realmente tem caráter preditivo, então a preservação desta parte essencial dos dados nunca poderá ser garantida. Por outro lado, embora um modelo de previsão mais eficaz possa ser construído através de uma seleção rigorosa dos componentes principais com maior poder de previsão (BARROS e RUTLEDGE [68]), isto só aumenta a dificuldade, uma vez que selecionar é um processo muito mais difícil que determinar um valor de corte.

Visando uma solução para este problema, WOLD *et al.* [69] propoem a técnica regressão por projeção em estruturas latentes (PLS-R). Assim como na PCR, a PLS-R define variáveis latentes ortogonais que comprimem a informação e descartam o que é irrelevante. Entretanto, a PLS-R tem como objetivo explícito construir variáveis latentes de forma a capturar a maior variância em \mathbf{X} e \mathbf{Y} e maximizar a correlação entre elas. Colocando de outra forma, a PLS-R maximiza a covariância entre \mathbf{X} e \mathbf{Y} , mantendo todas as vantagens e eliminando os aspectos indesejáveis da PCR.

Na técnica PLS-R, os componentes⁷ são obtidos iterativamente. Um algoritmo básico (MEVIK e WEHRENS [70]) consiste em realizar uma decomposição em valores singulares (SVD) da matriz de covariância cruzada $\Sigma_{\mathbf{X}\mathbf{Y}} = \mathbf{X}^T \mathbf{Y}$. Os primeiros vetores singulares esquerdo e direito, \mathbf{w} e \mathbf{q} , são então utilizados para obter os escores (*scores*):

$$\mathbf{t} = \mathbf{X}\mathbf{w} = \mathbf{E}\mathbf{w} \tag{2.8a}$$

$$\mathbf{u} = \mathbf{Y}\mathbf{q} = \mathbf{F}\mathbf{q} \tag{2.8b}$$

onde \mathbf{E} e \mathbf{F} são inicializadas como \mathbf{X} e \mathbf{Y} , respectivamente. Normalmente, os escores da matriz \mathbf{X} são normalizados, ou seja:

$$\mathbf{t} = \mathbf{t} / \sqrt{\mathbf{t}^T \mathbf{t}} \tag{2.9}$$

Em seguida, os carregamentos (*loadings*) são calculados:

⁷Neste contexto chamados de variáveis ou estruturas latentes.

$$p = \mathbf{E}^T \mathbf{t} \quad (2.10a)$$

$$q = \mathbf{E}^T \mathbf{t} \quad (2.10b)$$

e, finalmente, as matrizes são "deflacionadas":

$$\mathbf{E}_{h+1} = \mathbf{E}_h - \mathbf{t}\mathbf{p}^T \quad (2.11a)$$

$$\mathbf{F}_{h+1} = \mathbf{F}_h - \mathbf{t}\mathbf{q}^T \quad (2.11b)$$

A estimação do próximo componente então recomeça com a decomposição em valores singulares (SVD) da nova matriz de covariância cruzada $\mathbf{E}_{h+1}^T \mathbf{F}_{h+1}$. Após cada iteração, os vetores \mathbf{w} , \mathbf{t} , \mathbf{p} e \mathbf{q} são armazenados como colunas nas matrizes \mathbf{W} , \mathbf{T} , \mathbf{P} e \mathbf{Q} , respectivamente. Dado que as colunas da matriz \mathbf{W} são obtidas por sucessivas "deflações", elas não podem ser diretamente comparadas. Uma forma alternativa de representar a matriz de carregamentos, de modo que todas as colunas se relacionem diretamente com a matriz X original, é dada por:

$$\mathbf{B} = \mathbf{R}(\mathbf{T}^T \mathbf{T})^{-1} \mathbf{T}^T \mathbf{Y} = \mathbf{R} \mathbf{T}^T \mathbf{Y} = \mathbf{R} \mathbf{Q}^T \quad (2.12)$$

lembrando que, assim como no caso da PCR, somente os primeiros k componentes são utilizados.

Cabe ainda ressaltar que a PLS-R possui uma outra característica interessante que é a possibilidade do cálculo direto de uma medida da importância das variáveis. Esta medida de importância é baseada na soma ponderada dos valores absolutos dos coeficientes de regressão. Os pesos neste caso são as reduções proporcionais das somas dos quadrados dos desvios ao longo de todas as variáveis latentes e são computados separadamente para cada resultado.

Embora o arcabouço apresentado até o momento tenha sido desenvolvido com foco no problema de regressão, duas pequenas modificações permitem adaptá-lo ao problema de classificação e assim obter uma outra técnica, conhecida como análise discriminante por projeção em estruturas latentes (PLS-DA).

A primeira modificação tem a ver com os dados de entrada e está associada à substituição da matriz de saídas \mathbf{Y} por uma matriz indicadora. A matriz indicadora é uma matriz onde as entradas só podem ser 0 ou 1, o somatório das linhas tem que ser igual a 1 e cada coluna representa uma classe.

Já a segunda modificação, consequência da primeira, está relacionada ao problema de transformar a matriz \mathbf{Y} prevista pela PLS-R em uma matriz indicadora. Uma solução simples para este problema é empregar uma função exponencial nor-

malizada⁸ para transformar os valores previstos das linhas da matriz \mathbf{Y} prevista pela PLS-R em "valores probabilísticos", ou seja, valores limitados ao intervalo entre 0 e 1 e cuja soma é igual a 1. A matriz resultante é, então, transformada em uma matriz indicadora substituindo os "valores probabilísticos" máximos de cada linha por 1 e os demais por 0, em outras palavras, a classe prevista será aquela que possuir o maior "valor probabilístico".

2.3.2 Máquina de vetor de suporte (SVM)

A aprendizagem por vetor de suporte é baseada em ideias simples originadas da teoria de aprendizagem estatística (VAPNIK [72]). A simplicidade vem do fato de que a SVM aplica um método linear simples aos dados, mas em um espaço de características de dimensão elevada não-linear relacionado ao espaço das variáveis de entrada. Além disso, apesar de ser possível imaginar a SVM como um algoritmo linear em um espaço de dimensão elevada, na prática, ela não envolve nenhum cálculo neste espaço de dimensão elevada. Esta simplicidade combinada com o desempenho do estado da arte em vários problemas de aprendizado (classificação, regressão e descoberta de novidade) contribuíram para a popularidade desta técnica.

No caso de problemas de classificação binária, a SVM separa as diferentes classes por meio de um hiperplano:

$$\mathbf{w}^T \Phi(x) + b = 0 \quad (2.13)$$

correspondendo à função de decisão

$$f(x) = \text{sgn} [\mathbf{w}^T \phi(x) + b] \quad (2.14)$$

De acordo com VAPNIK [72], o hiperplano ótimo, ou seja, aquele que fornece o melhor desempenho em termos de classificação, é aquele que maximiza a margem de separação entre as duas classes. Ele pode ser obtido resolvendo um problema de otimização quadrática com restrições cuja solução \mathbf{w} possui uma expansão $\mathbf{w} = \sum_i \alpha_i \Phi(x_i)$ em termos de um subconjunto dos vetores de treinamento que se localizam na margem. Estes vetores de treinamento, chamados de vetores de suporte, contêm toda a informação relevante sobre o problema de classificação.

No caso da técnica C -SVC (BOSER *et al.* [73], CORTES e VAPNIK [74]) utilizada na presente investigação, o problema de otimização primal tem a seguinte forma:

⁸Também conhecida como função *softmax* (BISHOP [71]).

$$\begin{aligned}
\text{minimizar } t(\mathbf{w}, \xi) &= \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{C}{m} \sum_{i=1}^m \xi_i \\
\text{sujeito a } y_i [\mathbf{w}^T \Phi(\mathbf{x}_i) + b] &\geq 1 - \xi_i \quad (i = 1, \dots, m) \\
\xi_i &\geq 0, \quad (i = 1, \dots, m)
\end{aligned} \tag{2.15}$$

onde m é o número de dados de treinamento, $y_i \in \{-1, 1\}$, $\Phi(\mathbf{x}_i)$ é uma função implícita que mapeia \mathbf{x}_i em um espaço de dimensão elevada e $C > 0$ é um parâmetro de regularização ajustável.

Através da relação prima-dual é possível obter o valor ótimo de \mathbf{w} na forma da seguinte expansão:

$$\mathbf{w} = \sum_{i=1}^m y_i \alpha_i \Phi(x_i) \tag{2.16}$$

onde os coeficientes não-nulos ocorrem quando um ponto (x_i, y_i) ativa a restrição, ou seja, o ponto é um vetor de suporte. Os coeficientes α_i são obtidos através da solução do respectivo problema dual⁹:

$$\begin{aligned}
\text{maximizar } W(\alpha) &= \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m \alpha_i \alpha_j y_i y_j k(\mathbf{x}_i, \mathbf{x}_j) \\
\text{sujeito a } 0 \leq \alpha_i &\leq \frac{C}{m} \quad (i = 1, \dots, m) \\
\sum_{i=1}^m \alpha_i y_i &= 0 \quad (i = 1, \dots, m)
\end{aligned} \tag{2.17}$$

onde $k(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i) \Phi(\mathbf{x}_j) \rangle$ é a chamada função núcleo.

Embora existam diversas funções núcleo $k(\mathbf{x}_i, \mathbf{x}_j)$, as quatro funções núcleo mais comumente empregadas são:

- linear: $k(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j$;
- polinomial: $k(\mathbf{x}_i, \mathbf{x}_j) = (\gamma \mathbf{x}_i^T \mathbf{x}_j + r)^d, \gamma > 0$;
- função de base radial (RBF): $k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2), \gamma > 0$, e;
- tangente hiperbólica: $k(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\gamma \mathbf{x}_i^T \mathbf{x}_j + r)$;

O parâmetro de regularização ajustável C controla o custo da penalidade da SVM classificar incorretamente um vetor de treinamento, ou seja, ele controla a complexidade da função de previsão. Valores elevados de C irão forçar a SVM a criar funções de previsão complexas o suficiente de modo que poucos vetores de

⁹O qual pode ser resolvido por meio de diversos algoritmos como, por exemplo, o algoritmo SMO (PLATT [75]).

treinamento serão classificados incorretamente, enquanto valores baixos irão fornecer funções de previsão mais simples.

Embora a técnica C -SVC tenha sido originalmente desenvolvida para o problema de classificação binária, a mesma pode ser generalizada para o problema de k classes, onde $k > 2$, usando esquemas de votação do tipo "um contra um" ou "um contra todos". No esquema "um contra todos", k classificadores binários são treinados para separar uma classe das restantes. Para a previsão, a observação desconhecida é então classificada como pertencente à classe do classificador que produzir o valor de decisão mais alto.

Já no esquema "um contra um", $k(k - 1)/2$ classificadores binários são construídos onde cada um é treinado para duas classes somente. A previsão de um observação desconhecida é realizada através de uma votação onde cada classificador fornece uma previsão e a classe que obter mais votos é aquela atribuída à observação desconhecida.

2.3.3 Máquina de melhoramento gradiente (GBM)

A máquina de melhoramento gradiente (GBM) foi proposta com base na conexão entre o melhoramento (*boosting*) e a otimização. A GBM é baseada na extensão feita FRIEDMAN [76] e FRIEDMAN [77] do trabalho inicial de FRIEDMAN [78].

De uma forma geral, em qualquer problema de estimação de função, o que se deseja é obter uma função de classificação (ou regressão), $\hat{f}(\mathbf{x})$, que minimiza a esperança de uma função de perda, $\Psi(y, f)$, ou seja:

$$\hat{f}(x) = \min_{f(x)} E_{y|x} [\Psi(y, f(x)) | x] \quad (2.18)$$

Os modelos de classificação (regressão) paramétricos assumem que $\hat{f}(\mathbf{x})$ é uma função com um número finito de parâmetros, β , e os estima através da seleção dos valores que minimizam uma função de perda para uma amostra de dados de treinamento (\mathbf{x}_i, y_i) , de forma que

$$\hat{\beta}(\mathbf{x}) = \min_{\beta} \sum_{i=1}^m \Psi(y_i, f(\mathbf{x}_i; \beta)) \quad (2.19)$$

onde m é o número de dados de treinamento.

Já no caso de funções $\hat{f}(\mathbf{x})$ não-paramétricas, o problema se torna mais difícil. Neste caso, de forma similar a FRIEDMAN [78], é possível modificar a estimativa corrente de $\hat{f}(\mathbf{x})$ através da adição de uma nova função $\hat{f}(\mathbf{x})$ de uma maneira gananciosa (gulosa, míope ou *greedy*). Em outras palavras, sendo $F_i = f(\mathbf{x}_i)$, o que se deseja é reduzir o valor da seguinte função de dimensão m .

$$J(\mathbf{f}) = \sum_{i=1}^m \Psi(y_i, F_i) \quad (2.20)$$

Neste caso, usando um conceito da otimização, $-\nabla J(\mathbf{f})$ fornece a direção local de maior decaimento de $J(\mathbf{f})$. Com base no gradiente de descida é possível atualizar $\hat{f}(\mathbf{x})$ da seguinte forma:

$$\hat{f} \leftarrow \hat{f} - \rho \nabla J(\mathbf{f}) \quad (2.21)$$

onde ρ é o tamanho do passo na direção do gradiente de descida.

Embora esta abordagem seja bastante plausível, ela possui duas limitações. Primeiro, ela só ajusta $f(\mathbf{x}_i)$ para os valores de \mathbf{x}_i conhecidos. Segundo, ela não leva em conta que observações com vetores \mathbf{x}_i similares são propensas a ter também valores similares de $f(\mathbf{x}_i)$.

Ambas estas limitações podem causar efeitos desastrosos no erro de generalização. Visando contornar este problema, FRIEDMAN [76] sugere selecionar uma classe de funções que utilize a informação dos vetores de treinamento $f(\mathbf{x}_i)$ para aproximar o gradiente, normalmente uma árvore de classificação (ou de regressão).

Esta linha de pensamento produz o algoritmo de melhoramento gradiente de Friedman (Algoritmo 1). A cada iteração de melhoramento o algoritmo determina o gradiente, a direção na qual ele precisa melhorar o ajuste dos dados, e seleciona uma função em particular a partir de uma classe de funções permitidas que esta mais alinhada com esta direção.

Algoritmo 1: Melhoramento gradiente de Friedman.

- 1 Carregar os dados de treinamento (\mathbf{x}, \mathbf{y})
 - 2 Definir o número de iterações de melhoramento T
 - 3 Definir a função de perda $\Psi(\mathbf{y}, \mathbf{f})$
 - 4 Definir a classe de funções $h(\mathbf{x}, \theta)$
 - 5 Inicializar $\hat{f}_0(\mathbf{x})$ como uma constante
 - 6 **for** t em $1, \dots, T$ **do**
 - 7 Calcular o gradiente de descida: $g_t(x) = \left. -\frac{\partial}{\partial f(\mathbf{x})} \Psi(\mathbf{y}, f(\mathbf{x})) \right|_{f(\mathbf{x})=\hat{f}_{t-1}(\mathbf{x})}$
 - 8 Treinar o modelo base $h(\mathbf{x}, \theta_t)$ para prever $g_t(\mathbf{x})$ em função de \mathbf{x}
 - 9 Encontrar o passo ótimo do gradiente de descida:
 $\rho_t = \min_{\rho} \sum_{i=1}^n \Psi \left[y_i, \hat{f}_{t-1}(x_i) + \rho h(x_i, \theta_t) \right]$
 - 10 Atualizar a estimativa de $\hat{f}(\mathbf{x})$: $\hat{f}_t(\mathbf{x}) \leftarrow \hat{f}_{t-1}(\mathbf{x}) + \rho_t h(\mathbf{x}, \theta_t)$
 - 11 **end**
-

2.3.4 Perceptron de múltiplas camadas (MLP)

O perceptron de múltiplas camadas (MLP) ou rede neural artificial direta é um aproximador universal¹⁰ e também um dos muitos tipos diferentes de redes neurais artificiais que foram propostos. As redes neurais artificiais (ANNs, também abreviadas por redes neurais¹¹, NNs) formam uma família de técnicas de modelagem extremamente flexíveis inspirada na maneira como os neurônios nos cérebros humanos são conectados.

Embora os princípios das NNs já tivessem sido definidos nos anos cinquenta do século passado, com o perceptron de Rosenblatt (ROSENBLATT [80]), a técnica só ganhou momento de fato cerca de vinte anos depois, com a publicação do livro de RUMELHART e MCCLELLAND [81]. O MLP consiste de vários neurônios artificiais, tipicamente organizados em três camadas, como mostrado na Figura 2.10.




Figura 2.10: Modelo de uma rede neural artificial direta (ou MLP) e de um neurônio artificial.

Quando apresentado a sinais de entrada a_i , um neurônio artificial irá fornecer um sinal de saída a_{out} correspondente a uma transformação $g(\bullet)$ da soma das entradas ponderadas:

¹⁰Conforme rigorosamente demonstrado por CYBENKO [79], um MLP é capaz de aproximar uniformemente qualquer função contínua que encaixe em um hipercubo unitário.

¹¹Embora o grande Prof. Evaristo Biscaia do PEQ/COPPE insista em chamá-las de redes neuronais, pois segundo ele, a palavra neural se refere a nervo e não a neurônio.

$$z = b + \left(\sum_{i=1}^N a_i w_i \right) \quad (2.22a)$$

$$a_{out} = g(z) \quad (2.22b)$$

Para aqueles neurônios localizados na camada de entrada, a transformação $g(\bullet)$ (ou função de ativação) é normalmente a função identidade, entretanto para aqueles neurônios localizados na camada intermediária (ou escondida), outras funções de ativação podem ser utilizadas como, por exemplo:

- linear: $g(\bullet) = \lambda[(\bullet)]$;
- degrau: $g(\bullet) = U(\bullet)$;
- retificadora linear: $g(\bullet) = \max(0, (\bullet))$;
- logística: $g(\bullet) = 1/[1 + \exp(-\lambda[(\bullet)])]$;
- gaussiana: $g(\bullet) = \exp(-(\bullet)^2/\sigma^2)$, e;
- tangente hiperbólica: $g(\bullet) = \tanh(\bullet)$;

A topologia destas redes é bastante flexível. É possível utilizar múltiplas camadas escondidas, remover ligações entre unidades específicas ou mesmo adicionar conexões que contornam camadas. Entretanto, a estrutura mais comum é a de uma rede completamente conectada como aquela mostrada na Figura 2.10, que consiste de uma camada de entrada, uma camada escondida e uma camada de saída.

A natureza dos dados, no caso de problemas de classificação o número de preditores e o número de classes, determina o número de unidades nas camadas de entrada e de saída, respectivamente. Entretanto, o número de neurônios da camada escondida é um parâmetro que necessita ser ajustado.

As conexões entre os neurônios são ponderadas: um sinal de saída de um respectivo neurônio é enviado para todos os neurônios conectados da próxima camada multiplicado pelos seus respectivos pesos, os quais formam o modelo de uma topologia de rede particular.

De fato, treinar um MLP significa obter os valores dos pesos que minimizam uma dado critério de ajuste (*fit criterion*). Este critério de ajuste normalmente corresponde a uma medida do erro E cometido pelo MLP para um dado conjunto de valores dos pesos w_i . De acordo com VENABLES e RIPLEY [82], este critério de ajuste pode também incluir um termo de regularização que visa auxiliar o processo de otimização, como também evitar o sobre-ajuste. Neste caso, o critério de ajuste é alterado para

$$J = E + \lambda_d \sum_{i=1}^N w_i^2 \quad (2.23)$$

onde λ_d é um parâmetro ajustável que controla o impacto deste termo de regularização no critério de ajuste e é chamado decaimento dos pesos (*weight decay*) ou simplesmente decaimento (*decay*).

Com relação ao algoritmo de treinamento, o mais popular é chamado de algoritmo de retro-propagação (*backpropagation*) (RUMELHART e MCCLELLAND [81]) e consiste numa adaptação dos pesos w_i baseada no método do máximo gradiente de descida (DEBYE [83]), através da apresentação repetida dos dados de treinamento seguida da avaliação do desempenho nos dados de validação. Para evitar o sobre-ajuste, o processo de treinamento é encerrado quando o critério de ajuste J avaliado no conjunto de validação deixa de melhorar.

Entretanto, este algoritmo não é o único e muitos outros foram propostos. Por exemplo, em HAGAN e MENHAJ [84]) o algoritmo de treinamento é formulado como um problema de otimização numérica e é resolvido usando o algoritmo Levenberg-Marquardt (LM¹²).

2.4 Emissão acústica aplicada à caracterização de tamanhos de partículas

O primeiro registro do uso de sinais de EA para a caracterização dos tamanhos de partículas sólidas foi feito a cerca de quarenta anos. Em seu artigo seminal¹³, LEACH *et al.* [5] descrevem um novo método de determinação dos tamanhos de partículas sólidas baseado no fato de que as colisões entre elas produzem sinais de EA cujas características estão relacionadas aos seus tamanhos, distribuição dos tamanhos e também a sua forma. O método proposto utiliza estes sinais de EA e é extremamente rápido pois, segundo os autores, demanda menos de 10 ms para a caracterização do tamanho de esferas metálicas e de vidro na faixa de 3 cm até 50 μm de diâmetro. Os autores concluem o artigo indicando a possibilidade de utilização do método no monitoramento *online* dos processos de mistura, formulação e moagem de pós. Este artigo é o primeiro de uma sequência de cinco artigos publicados sobre este tema (LEACH *et al.* [86], LEACH e RUBIN [87], LEACH *et al.* [88], LEACH *et al.* [89]).

Alguns anos mais tarde, ARRINGTON [90] publica uma revisão sobre o uso da instrumentação de EA para monitorar o escoamento de pós na qual são examinadas

¹²LEVENBERG [85]

¹³O qual contabiliza até hoje um total de 57 citações na literatura.

duas aplicações: uma associada a medição da vazão de pós metálicos e outra relativa à investigação dos perfis de velocidade em leitos fluidizados.

KWAN e LEACH [91], em 1985, mostram que as frequências dos sinais de EA também estão relacionadas com a relação entre o diâmetro e o quadrado do comprimento das partículas, expandindo assim a aplicação para partículas cilíndricas.

Os anos 90 se iniciam com BUTTLE *et al.* [92] apresentando dois outros métodos de caracterização de tamanhos usando um método acústico baseado na detecção e medida das ondas elásticas geradas pelos impactos das partículas sólidas com uma pequena placa. O sinal de EA é medido por um sensor piezoelétrico de alta fidelidade e é caracterizado pela amplitude e tempo de subida das ondas P¹⁴. Uma abordagem teórica baseada na teoria do impacto de Hertz¹⁵ e na teoria da propagação das ondas elásticas é desenvolvida e utilizada para determinar a relação entre a dinâmica do impacto da partícula e o sinal de EA. O primeiro método é baseado somente em medidas de amplitude necessitando, porém, de uma precisa calibração do sistema e o pleno conhecimento da velocidade de impacto da partícula, do ângulo de incidência e do coeficiente de restituição. O segundo método incorpora medidas do tempo de subida e depende moderadamente da amplitude do sinal, minimizando assim a necessidade de uma calibração absoluta precisa. Além disso, este segundo método não requer o conhecimento da velocidade de impacto, do ângulo de incidência e do coeficiente de restituição. Os tamanhos de partículas obtidos pelos dois métodos são comparados com medidas das distribuições dos tamanhos de partículas obtidas através de vídeo-microscopia. Os resultados obtidos mostram que o primeiro método subestima as partículas menores em cerca de 20 a 30% e superestima as partículas maiores em 5 a 10%, enquanto o segundo método consistentemente subestima todos os tamanhos e fornece desvios muito menores.

Em 1994, pesquisadores do UMIST¹⁶ publicam o primeiro artigo associando técnicas de emissão acústica e de inteligência computacional para o monitoramento não-invasivo de reações de cristalização. BOUCHARD *et al.* [6] utilizaram um instrumento¹⁷ especialmente desenvolvido para o monitoramento de processos químicos usando a técnica acústica passiva. Uma extensa série de experimentos foi realizada em reatores de duas unidades diferentes da Imperial Chemical Industries. A partir de características extraídas dos sinais brutos de EA adquiridos, eles desenvolveram vários modelos para a previsão dos tamanhos de partículas em três faixas (400-455 μm , 160-250 μm e 80-115 μm) usando técnicas como o perceptron de múltiplas ca-

¹⁴Primárias ou de compressão.

¹⁵HERTZ [93, p. 146]

¹⁶University of Manchester Institute of Science and Technology

¹⁷ACM 100 Acoustic Crystallisation Monitor (AEA Technology, Risley, Warrington)

madas (MLP¹⁸) e o k-vizinhos mais próximos (k-NN¹⁹). Taxas globais de acerto entre 58 e 93% foram obtidas. Os pesquisadores concluem que, embora as técnicas de inteligência computacional possam ser usadas para extrair informação dos sinais de EA, a calibração é específica para cada reator. Além disso, um número muito grande de bateladas deve ser monitorada para gerar um banco de dados grande o suficiente, o que pode representar semanas ou meses de trabalho de monitoramento e desenvolvimento.

Mais de 20 anos após a publicação do trabalho pioneiro de LEACH *et al.* [5], HIRAJIMA e TSUNEKAWA [96] publicam resultados de estudos fundamentais sobre o mecanismo de geração de sinais de EA emitidos pelo impacto de partículas em uma placa ou nas paredes de um tanque agitado. Nestes estudos é verificado empiricamente que os sinais de EA de alta frequência exibem mudanças características associadas ao tamanho e ao número de partículas. Um aumento no tamanho ou no número de partículas resulta em um aumento de diversos parâmetros medidos e também dos espectros de potência dos sinais. A partir dos resultados experimentais, os autores desenvolvem uma relação empírica entre a energia relativa dos sinais e o diâmetro e número de partículas. Um sistema de monitoração híbrido baseado em medidas de turbidez e dos sinais de EA é também desenvolvido e aplicado em um processo de aglomeração em líquidos utilizado para a produção de micro-esferas de zirconia com diâmetros inferiores a 500 μm .

Ainda em 2000, pesquisadores da Glaxo Wellcome²⁰ publicam o primeiro artigo envolvendo uma aplicação na indústria farmacêutica. WHITAKER *et al.* [97] reportam o emprego de uma nova técnica de monitoramento de processos de granulação de alto cisalhamento usando sinais de EA, a qual demonstra ser capaz de monitorar mudanças nas propriedades físicas de pós durante a sua granulação. Os autores concluem o artigo com a seguinte afirmação:

“Acoustic monitoring has a number of advantages over the existing techniques used. In particular, it is non-invasive, inexpensive and has been shown to be sensitive. Experimental work performed on other pharmaceutical operations (unpublished work) has demonstrated that acoustic emissions can be used successfully to monitor these processes and that this technique, therefore, has a wider applicability than that presented in this paper.”

Posteriormente, em 2004, um grupo de pesquisadores da Universidade de Strathclyde publica o primeiro de uma série de artigos sobre monitoramento de tamanhos de partículas durante reações químicas usando EA. Neste primeiro artigo, NORDON *et al.* [98] investigam a viabilidade de monitorar uma reação de esterificação

¹⁸RUMELHART *et al.* [94]

¹⁹COVER e HART [95]

²⁰Atualmente GlaxoSmithKline.

heterogênea entre o ácido itaconico e o 1-butanol. Um transdutor piezoelétrico ressonante de 90 kHz é fixado à parede externa de um reator agitado encamisado de vidro de 1 L para a detecção dos sinais de EA até o limite de 300 kHz. O efeito da concentração e do tamanho das partículas sobre a EA também foi investigado, com concentrações elevadas e grandes partículas fornecendo sinais mais fortes. O efeito da temperatura e da concentração de 1-butanol no progresso das reações foi monitorado usando EA, entretanto os autores concluem que não foi possível diferenciar os sinais de EA entre mudanças de concentração e tamanhos de partículas usando o sensor piezoelétrico ressonante.

Dois anos mais tarde, este mesmo grupo publica seu segundo artigo. Desta vez, NORDON *et al.* [99] utilizaram um transdutor piezoelétrico de banda larga sensível até 750 kHz. Eles observaram um aumento da área total do espectro dos sinais na faixa de 55 a 500 kHz em função do aumento da velocidade de agitação, da concentração e do tamanho das partículas. Com base em diversos experimentos, também foi verificada a possibilidade de se estimar o diâmetro médio das partículas através da potência parcial do sinal na faixa entre 55 e 200 kHz. A mesma reação anterior foi monitorada e, na medida em que a reação progredia, uma redução da área total do espectro dos sinais foi observada. Através dos experimentos realizados pode ser verificado empiricamente que a amplitude do sinal contém informação a cerca da concentração e do tamanho das partículas, enquanto a sua frequência fornece informação sobre mudanças no tamanho médio das partículas. Este artigo foi acompanhado pela publicação de outros dois (CARSON *et al.* [100], TRAMONTANA *et al.* [101]).

Uma nova modelagem teórica que descreve o movimento das partículas em um reator agitado, as suas colisões com as paredes do reator, as vibrações subsequentes que são propagadas pelas paredes do reator e sua detecção por um sensor ultrassônico é proposta por CARSON *et al.* [100]. O impacto entre as partículas e a parede é modelado usando a teoria do impacto de Hertz-Zener²¹. Dados experimentais foram utilizados em conjunto com o modelo direto proposto, resultando em um problema inverso para a DTP usando a função-custo dos mínimos quadrados. Os autores comentam também que a aplicação de um operador de suavização integral sobre os espectros dos sinais de EA melhora de forma significativa a precisão e a robustez da abordagem.

Trabalhando no mesmo problema, mas utilizando um método diferente para previsão da propagação dos sinais de EA, TRAMONTANA *et al.* [101] descrevem uma nova abordagem para a análise das complexas interações entre as partículas e a parede do reator usando o método dos elementos finitos (FEM). Através deste método, um modelo bidimensional de quatro camadas para previsão da propagação das on-

²¹ZENER [102]

das elásticas é desenvolvido e validado experimentalmente. A fonte de excitação, representando os estímulos gerados pelas colisões das partículas com a parede interna do reator, foi modelada usando a teoria do impacto de Hertz. Os resultados das simulações usando o método dos elementos finitos foram capazes de prever: o aumento da energia dos sinais com o aumento tanto da concentração quanto do tamanho das partículas, a redução dos principais componentes de frequência do sinal com o aumento do tamanho das partículas e um efeito de filtro passa-baixas introduzido pelo próprio reator. Segundo os autores, o resultado mais significativo obtido através das simulações foi o fato da frequência de interesse se situar abaixo de 150 kHz, com os principais componentes de frequência do sinal de EA entre 10 e 60 kHz, fato este comprovado experimentalmente através do emprego de transdutores ultrassônicos ressonantes e e banda larga.

No trigésimo aniversário da publicação do artigo de LEACH *et al.* [5], um grupo da Universidade de Zhejiang publica um trabalho sobre a utilização dos espectros de potência dos sinais de EA no monitoramento do tamanho médio de partículas em leitos fluidizados (JIANG *et al.* [103]). Os autores verificaram que a frequência principal dos espectros de potência dos sinais pode ser relacionada ao "tempo de colisão médio de Landau-Lifshitz"²². Combinando a expressão do "tempo de colisão médio" com relações empíricas entre a velocidade superficial do gás e o diâmetro das partículas, eles desenvolveram um modelo para a previsão da frequência principal dos espectros de potência dos sinais. Eles também verificaram uma influência significativa da formação de grumos²³ no leito fluidizado com a estrutura do espectro de potência dos sinais de EA. Testes em leitos fluidizados frios em escala de laboratório e quentes em escala industrial mostraram haver uma concordância muito boa entre a frequência principal medida e a prevista pelo modelo, fato este que corroborou para a conclusão que os espectros de potência dos sinais de EA podem ser utilizados com sucesso para monitorar o tamanho médio de partículas e a formação de grumos em leitos fluidizados.

Em CARSON *et al.* [105], o mesmo grupo de Strathclyde novamente ataca o problema inverso de recuperação de tamanho de partícula a partir de dados experimentais. Segundo os autores, o objetivo primário do trabalho é desenvolver uma expressão analítica para as vibrações resultantes do impacto de uma partícula esférica com uma placa plana circular. Através de um desenvolvimento matemático bem sofisticado, uma expressão para a frequência máxima do espectro do sinal de EA em termos dos parâmetros do sistema é obtida. Como resultado, a dependência

²²Na realidade um equívoco de nomenclatura, pois em LANDAU e LIFSCHITZ [104, p. 36], mais especificamente na resolução do *Problem 1*, é desenvolvida uma expressão para o tempo de colisão de duas esferas a qual, de fato, trata-se do tempo de contato dado pela teoria do impacto de Hertz.

²³Pequenas porções do material cujas partículas estão aglomeradas.

explícita entre o tamanho da partícula impactante, a sua velocidade de impacto e a frequência máxima do espectro é encontrada, ao menos do ponto de vista teórico. Usando esta nova modelagem, o problema inverso de recuperação do tamanho de partícula a partir de dados experimentais é então revisitado. Com base em resultados de experimentos de impacto de partículas com uma placa fina e de impactos de múltiplas partículas com a parede de um reator agitado, os autores concluem que é possível recuperar o tamanho da partícula usando a abordagem proposta.

Em 2008, mais uma vez técnicas de inteligência computacional são utilizadas em conjunto com os sinais de EA, desta vez para a caracterização do tamanho de partículas em um leito fluidizado de escala piloto (CHEN e CHEN [7]). Neste artigo, os autores propõem um método no qual os sinais de EA de diferentes tamanhos de partículas são decompostos em oito níveis por uma *wavelet* de Daubechies de terceira ordem após terem o nível de ruído atenuado por meio de um filtro *wavelet* sym8 combinado com a seleção de limiar pelo método SURE²⁴. Para superar a colinearidade e reduzir o número de variáveis é empregada a análise de componentes principais (PCA²⁵) e, então, um MLP com duas camadas escondidas é utilizado para prever o tamanho da partícula com base nos componentes principais. Respaldados por taxas de acerto superiores a 98%, os pesquisadores concluem que o método proposto é adequado à medição do tamanho médio de partículas em reatores de leito fluidizado a partir de medições *online* dos sinais de EA.

Neste mesmo ano, pesquisadores da Universidade de Purdue nos EUA (PAPP *et al.* [8]) publicam outro trabalho envolvendo uma aplicação na indústria farmacêutica. Na pesquisa realizada, sinais de EA na faixa de 20 a 1.000 kHz emitidos durante um processo de granulação de alto cisalhamento são registrados e analisados utilizando técnicas de inteligência computacional²⁶ com a intenção de obter relações entre as variações das propriedades físicas dos grânulos produzidos e a evolução das emissões acústicas que ocorrem durante sua formação. Os sinais obtidos em dois granuladores diferentes foram utilizados para a obtenção de um modelo de quatro componentes o qual se mostrou capaz de prever a distribuição dos tamanhos dos grânulos na faixa de 53 a 1.180 μm com um erro médio de previsão inferior a 2%. Além da previsão dos tamanhos de partículas, os pesquisadores investigaram também a possibilidade de previsão do teor de umidade dos grânulos.

Em 2009, o grupo de Zhejiang publica um novo artigo onde sinais de EA são utilizados para detecção de aglomerações em reatores de polimerização ([9]). Neste artigo é apresentada uma nova técnica não-invasiva de EA combinada com um método de comparação de atratores, a qual é baseada na comparação de séries temporais de

²⁴DONOHO e JOHNSTONE [106]

²⁵PEARSON [67]

²⁶PCA e regressão por projeção em estruturas latentes (PLS-R)(WOLD *et al.* [62]).

sinais de EA adquiridos em condições normais com séries temporais medidas durante a operação do leito agitado. O método emprega, para esta comparação, uma característica estatística S^{27} que testa a hipótese nula da identidade entre duas distribuições de probabilidade multidimensionais. Resultados experimentais obtidos a partir de um reator de leito agitado horizontal de escala laboratorial demonstram que o método é sensível a pequenas mudanças na DTP. Os autores concluem que o método proposto não oferece somente um alerta antecipado, mas também possui o potencial de localizar a aglomeração em um reator através do emprego de múltiplos sensores de EA.

Em uma série de dois artigos (CARSON *et al.* [108] e CARSON *et al.* [109]), o grupo de Strathclyde volta a apresentar novos desenvolvimentos teóricos e resultados experimentais a cerca do problema de monitoramento de tamanhos de partículas durante reações químicas. No primeiro artigo, os autores apresentam a derivação de uma nova expressão analítica para a força de impacto transiente, enquanto no segundo artigo é apresentado um novo modelo analítico no qual o sensor de EA é modelado analiticamente através de um modelo de sistemas lineares. Este novo modelo é então utilizado para simular múltiplos impactos entre as partículas e a parede do reator com cada partícula impactando um ponto da superfície do reator escolhido aleatoriamente. Os sinais de EA simulados para o impacto de cada partícula são escalonados também de forma aleatória no tempo e somados para obter o que seria sinal de EA resultante de múltiplos impactos. Comparando os resultados simulados com os experimentais, os autores concluem que o novo modelo analítico desenvolvido apresenta um desempenho satisfatório.

Já em uma outra linha de investigação, com maior foco no processamento dos sinais de EA, o grupo de Zhejiang estuda as características estruturais dos sinais de EA com o objetivo de extrair o máximo de informação útil (HE *et al.* [10], [11]). Nestes estudos, a estrutura dos sinais medidos em leitos fluidizados (sistema gás-sólido) é dissecada usando a transformada *wavelet* e a análise de faixa re-escalada²⁸. Um critério geral é proposto para separar os sinais de EA em três escalas características: microescala, mesoescala e macroescala. Com base neste método de resolução dos sinais, os autores foram capazes de extrair características úteis que foram utilizadas para estabelecer um modelo relativamente simples de previsão *online* dos tamanhos médios e da DTP em leitos fluidizados. O modelo linear empírico baseado em níveis de energia das escalas mostrou uma boa concordância com os dados obtidos pelo método de peneiramento em leitos fluidizados de escala laboratorial e industrial, sendo os desvios relativos da ordem de 4 a 5%. Com base nos resultados obtidos os autores concluem que as características extraídas através da análise das caracte-

²⁷DIKS *et al.* [107]

²⁸Também conhecida como análise de Hurst (HURST [110])

terísticas estruturais dos sinais de EA são bastante úteis para o estabelecimento de modelos efetivos de previsão *online*.

Em mais uma aplicação na indústria farmacêutica, um grupo de pesquisadores da Universidade de Kuopio publica dois artigos sobre a utilização de sinais de EA no monitoramento de tamanhos de grânulos em processos de granulação por pulverização em leito fluidizado (MATERO *et al.* [12], MATERO *et al.* [13]). No primeiro artigo, MATERO *et al.* [12] introduzem uma abordagem para a implementação de modelos de previsão em tempo real do tamanho e do teor de umidade de grânulos. Neste trabalho, os modelos de previsão foram desenvolvidos usando o método PLS-R combinado às informações dos espectros de frequência dos sinais de EA segmentados em 32 bandas, além de seis parâmetros do processo. Já no segundo, MATERO *et al.* [13] apresentam um modelo quantitativo onde os espectros dos sinais são combinados e modelados usando o modelo Tucker-3²⁹ para compressão e o modelo multilinear PLS³⁰ para regressão. Os sinais de EA são adquiridos através de sensores piezoelétricos ressonantes de 150 kHz e, segundo os autores, o estudo realizado mostra pela primeira vez que a fase de nucleação da granulação pode ser detectada usando técnicas de EA possibilitando, assim, a previsão da distribuição dos tamanhos dos grânulos no produto final por meio da medição da EA durante a fase de nucleação.

BASTARI *et al.* [14], em 2011, introduzem um método inovador para caracterização dos tamanhos de partículas de carvão pulverizado em uma usina termelétrica. A ideia básica por trás da metodologia proposta reside na identificação da relação desconhecida entre os sinais de EA e a distribuição dos tamanhos de partículas. Em uma primeira etapa, os sinais de EA adquiridos são decompostos para extração de características usando a transformada de pacote *wavelet* (WPT³¹). Na sequência, a dimensionalidade do espaço de características é reduzida empregando PCA. Na etapa final, um MLP é treinado para mapear o vetor de características na DTP. Segundo os autores, a solução proposta possui diversas vantagens como baixo custo e baixa invasividade, o que permite uma fácil integração da técnica em unidades industriais já existentes. Por fim, os pesquisadores concluem que o princípio de medição desenvolvido também pode ser aplicado a diferentes aplicações de caracterização de tamanhos sempre que um pó sólido é transportado pneumáticamente.

Em 2012, uma associação entre pesquisadores da Universidade de Western Ontario e da GlaxoSmithKline publica outra aplicação na indústria farmacêutica. Segundo HANSULD *et al.* [15]:

“In pharmaceutical manufacturing, control of particle size is crucial for achieving

²⁹TUCKER [111]

³⁰BRO [112]

³¹COIFMAN e WICKERHAUSER [113]

reproducible products of acceptable quality. Robust technologies to measure particle size online during operations such as blending, granulation and tableting are required, but to date have not been implemented.”

Neste trabalho, a correlação entre emissões acústicas audíveis (EAA) e os tamanhos de partículas é investigada. Através de experimentos controlados envolvendo dois granuladores de tamanhos diferentes, os sinais de EAA foram coletados usando um microfone posicionado sobre o leito móvel do granulador. Os resultados obtidos mostraram a existência de uma correlação empírica entre os tamanhos de partículas e os espectros de frequência segmentados em bandas de 10 Hz na faixa de 20 Hz a 20 kHz. Usando técnicas de inteligência computacional³², os autores construíram modelos de previsão para os tamanhos de partículas em função dos espectros segmentados dos sinais de EAA. Os pesquisadores concluem que os resultados suportam o desenvolvimento de correlações entre os sinais de EAA e os tamanhos de partícula e encorajam desenvolvimentos futuros da técnica de EAA para o monitoramento *online* e não-intrusivo na indústria farmacêutica. Baseada nestes e em outros resultados da sua tese de doutorado, HANSULD [115] conclui que:

“Overall, the work demonstrates AAEs provide a robust measure of the complex interactions known to occur during granulation and with the use of multivariate analysis techniques it is possible to extract relevant information to increase process understanding and assist in optimization and control.”

Ainda sobre processos de granulação na indústria farmacêutica, pesquisadores da Universidade de Leeds e da AstraZeneca publicam em 2014 uma nova investigação cujo foco é estudar as emissões acústicas de um granulador em escala laboratorial (WATSON *et al.* [19]). Usando um sofisticado modelo dinâmico computacional baseado no método dos elementos discretos (DEM)³³ foi possível calcular a frequência dos diferentes tipos de impactos das partículas sólidas dentro do granulador (p.e.: partícula-partícula, partícula-parede, partícula-impelidor). Diversas simulações foram realizadas variando as propriedades relevantes das partículas com o objetivo de investigar como estas propriedades afetam as frequências de contato. Além disso, os autores realizaram experimentos para adquirir os sinais de EA usando o sensor piezoelétrico de 150 kHz e também um sistema fotográfico de alta velocidade para acessar visualmente o tamanho dos grânulos adjacentes às paredes do granulador. As imagens registradas e as frequências de contato simuladas foram então utilizadas para avaliar qualitativamente a evolução dos sinais de EA³⁴. Embora a investigação não apresente nenhum modelo quantitativo de previsão, os autores concluem que:

“The combination of computational modelling with high speed photography re-

³²PCA e projeção ortogonal em estruturas latentes (OPLS)(TRYGG e WOLD [114]).

³³CUNDALL e STRACK [116]

³⁴Interessante ressaltar que no corpo do artigo os autores aparentemente confundem a frequência de contatos com a frequência dos sinais de EA.

sulted in a greater understanding of the AE results. With further modifications and appropriate statistical analysis the technique could be developed further to, monitor actual granule properties and be used as a more effective granulation monitoring system.”

Em outra aplicação associada ao monitoramento dos tamanhos de partículas de combustível sólido pulverizado em usinas termoelétricas, HU *et al.* [16] apresentam o protótipo de um sistema de instrumentação para a medição *online* da DTP usando sinais de EA. O método proposto extrai a informação dos tamanhos de partículas dos sinais impulsivos gerados pelos impactos das partículas com um guia de ondas metálico inserido no fluxo das partículas. Uma relação simples entre os tamanhos de partículas e a tensão de pico do sinal é estabelecida através de uma modelagem matemática do fenômeno de impacto. A identificação da tensão de pico do sinal de EA é realizada usando um algoritmo de detecção de pico baseado em energia. Os resultados experimentais obtidos com pérolas de vidro demonstram a capacidade do protótipo de discriminar partículas de diferentes tamanhos a partir do sinais de EA registrados. Os autores informam que o desempenho do sistema em termos de precisão é melhor no caso de baixa concentração e alta velocidade das partículas, dado que neste caso os sinais são mais fortes e melhor resolvidos no tempo. Eles concluem o artigo com a seguinte observação sobre futuros desenvolvimentos:

“Future work will include numerical simulation of particle collision and AE wave propagation, optimized design of the sensing head, development of denoising techniques, and online sizing of irregular biomass particles.”

Mais de dez anos depois de publicar o primeiro artigo, o grupo de Strathclyde apresenta o desenvolvimento de um sistema de monitoramento ultrassônico passivo para a detecção das emissões acústicas geradas pelos impactos de partículas sólidas na parede de um reator químico (TRAMONTANA *et al.* [20]). Novamente é utilizado FEM para a modelagem e simulação da propagação das ondas elásticas. Através das análises das simulações, os autores foram capazes de obter especificações para os transdutores piezoelétricos do sistema, resultando em uma configuração composta por dois transdutores de características complementares: banda estreita/alta sensibilidade; banda larga/baixa sensibilidade. Os autores destacam que o transdutor ressonante fornece discriminação da concentração de partículas, enquanto o não-ressonante de banda larga demonstra potencial para a estimação dos tamanhos de partícula *in situ*. Ainda, segundo os autores:

“The performance afforded by this approach has considerable potential for real-time process monitoring in the chemicals and pharmaceutical industries.”

A eficácia de diferentes algoritmos de inteligência computacional na estimação da DTP de pós usando EA é avaliada por ROSSETTI *et al.* [17] da Universidade Politecnica delle Marche. O desempenho dos modelos desenvolvidos usando dife-

rentes algoritmos foi avaliado contra os dados de referência obtidos de um sistema industrial descrito em BASTARI *et al.* [14]. Este sistema monitora continuamente a DTP do carvão pulverizado transportado pneumáticamente em dutos através de sinais de sensores piezoelétricos instalados na superfície externa dos dutos. Os dados de referência são provenientes de campanhas de medição realizadas sob diferentes condições de operação dos dutos. Cada observação é composta de 64 características, representando diferentes níveis de energia extraídos dos sinais brutos, e 3 alvos representando os valores medidos dos percentuais de partículas de carvão inferiores a 300, 150 e 75 μm . Três das técnicas mais comuns em problemas de regressão são avaliadas: o MLP, a máquina de vetor de suporte (SVM)³⁵ e a máquina de aprendizagem extrema (ELM)³⁶. Os resultados mostram que as técnicas avaliadas são capazes de gerar boas estimativas para a DTP e, em muitos casos, superam o desempenho do sistema comercial. Particularmente, a técnica de regressão SVM apresenta os melhores resultados em termos do erro médio de previsão, enquanto as técnicas MLP e ELM apresentam desempenhos inferiores, porém em linha com os valores de referência. Finalmente, os pesquisadores concluem o trabalho com o seguinte comentário:

“Future developments of the study will aim to assess the applicability of machine learning techniques for PSD distribution estimation in different contexts (food powders, pharmaceutical, etc.), to expand the fields of application. Others machine learning algorithms, in combination with alternative feature sets, will be also tested to verify the possibility of further reducing the estimation error.”

Visando o desenvolvimento de um sistema de monitoramento *online* da DTP através de sinais de EA, pesquisadores da Universidade de Cranfield em colaboração com a Procter and Gamble iniciam a publicação de uma série de artigos (NSUGBE *et al.* [119, 120, 121, 122]). NSUGBE *et al.* [119] propõem um método baseado em técnicas de processamento de sinal no domínio do tempo para a estimação dos tamanhos de partículas em misturas de sabão em pó a partir dos sinais de EA. No último artigo da série, em 2018, NSUGBE *et al.* [122] concluem que:

“The results of the experiments showed that the PSD of the particle mixtures being investigated could be identified with an average absolute error of 6%.”

Ainda em 2018, o grupo de pesquisadores da Universidade Politecnica delle Marche publica um novo artigo sobre o monitoramento da DTP de carvão pulverizado em usinas termoelétricas. Neste artigo, diferentemente do anterior, ROSSETTI *et al.* [3] formulam o problema como sendo de classificação ao invés de regressão. Três técnicas de classificação, o MLP, a ELM e a SVM foram comparadas e diversos testes foram realizados com o objetivo de estudar o efeito do número de classes, do

³⁵VAPNIK [72]

³⁶HUANG *et al.* [117], HUANG *et al.* [118]

tamanho do conjunto de dados e da redução do número de falso-positivos sobre a eficácia da abordagem. Ainda, segundo os autores:

“Obtained results showed that, using two classes give the most accurate results, using only the 90% of the available data can still provide comparable classification results, and the level of false positive can be effectively reduced.”

Encerrando esta visão geral de quatro décadas temos um recente artigo de pesquisadores da Universidade de North China Electric Power associando técnicas de EA e processamento de sinais para a caracterização dos tamanhos de partículas. Neste artigo, AN *et al.* [18] utilizam a técnica de decomposição de modo empírico conjunta (EEMD³⁷) para extrair funções de modo empírico (IMF) dos sinais de EA. As características destes sinais são então analisadas em ambos os domínios de tempo e frequência e a fração de contribuição para o erro médio quadrático (MSECF) das diferentes IMFs é utilizada para prever os tamanhos de partículas sólidas. Os autores justificam o uso da EEMD no lugar da decomposição usando WPT, adotada por BASTARI *et al.* [14], em função do fato de que a seleção da função *wavelet* e do nível de decomposição é um processo complexo que necessita de uma seleção manual em várias situações.

2.4.1 Lacunas identificadas e direcionamento

Esta visão geral fornece evidências de que os desenvolvimentos recentes sofrem de reprodutibilidade e generalização, pois são baseados em dados de experimentos muito específicos (ROSSETTI *et al.* [3], CHEN e CHEN [7], PAPP *et al.* [8], CAO *et al.* [9], HE *et al.* [10], REN *et al.* [11], MATERO *et al.* [12, 13], BASTARI *et al.* [14], HANSULD *et al.* [15], HU *et al.* [16], ROSSETTI *et al.* [17], AN *et al.* [18]) ou simulados a partir de modelagens computacionalmente intensivas (WATSON *et al.* [19], TRAMONTANA *et al.* [20]) ou que empregam abordagens inadequadas ao contexto³⁸ (CARSON *et al.* [100, 105, 108, 109]). Sendo assim, a superação destas lacunas contribui para o desenvolvimento e a comparação de abordagens para a caracterização de tamanhos de partículas sólidas usando emissão acústica e inteligência computacional. Além disso, uma outra lacuna revelada por intermédio desta visão geral é a não incorporação do conhecimento especialista de emissão acústica associado a outros contextos como, por exemplo, o dos ensaios não-destrutivos. Esta lacuna, aliada ao reconhecido desafio associado à interpretação e análise dos sinais de emissão acústica devido, principalmente, a sua elevada dimensionalidade, motiva a avaliação de abordagens que combinem a inteligência computacional e o conhecimento especialista de emissão acústica associado ao contexto dos ensaios não-destrutivos.

³⁷WU e HUANG [123]

³⁸Como é demonstrado na Subseção 3.2.5 e na Seção 5.1.

Capítulo 3

Modelagem da Cadeia de Medição

Conforme apontado por PROSSER *et al.* [124], a capacidade de modelar com precisão os sinais de EA oferece um potencial significativo para melhorar a sua interpretação. Também HAMSTAD *et al.* [125] salienta que os sinais simulados de EA são muito superiores aos experimentais para estudos de identificação da fonte. Isto se justifica pelo fato de que os dados simulados são melhor caracterizados, uma vez que neste caso existe um conhecimento exato de informações importantes nem sempre disponíveis em dados experimentais como: a forma, a localização da fonte e o campo de deslocamento vertical captado por um sensor de banda larga perfeito a uma distância conhecida da fonte. Soma-se a isto o fato de que os dados simulados são em grande parte livres de ruído.

Embora essas observações tenham sido feitas em relação ao uso tradicional da EA para ensaios não-destrutivos, elas também se aplicam ao contexto de caracterização dos tamanhos de partículas sólidas, uma vez que em última análise o que se procura é de fato identificar a fonte do sinal de EA. Portanto, considerando o papel relevante da simulação dos sinais de EA, será apresentada neste Capítulo uma proposta de modelagem bastante geral para simular a cadeia de medição de EA para a caracterização de tamanhos de partículas sólidas. O objetivo aqui é o de contribuir para uma melhor compreensão dos principais fatores que impactam o desempenho da técnica de forma reproduzível e utilizando dados bem caracterizados.

A modelagem proposta baseia-se em várias simplificações e aproximações, mas, como introduz um modelo de propagação baseado na teoria das ondas de Lamb LAMB [126], é mais adequada ao contexto do que a abordagem utilizada por CARSON *et al.* [100, 105, 108, 109], conforme será demonstrado oportunamente. Além disso, como não emprega nenhum método computacional intensivo para modelar a propagação de ondas ou a resposta do sensor, é muito mais simples e prática do que a alternativa apresentada por WATSON *et al.* [19] e TRAMONTANA *et al.* [20].

Isto posto, a seguir são apresentados os aspectos teóricos e o desenvolvimento da modelagem proposta para a cadeia de medição de EA conforme o diagrama de

blocos apresentado na Figura 2.7 do Capítulo 2.

3.1 Fonte de excitação $F_0(\omega)$

A fonte de excitação associada a um impacto nada mais é do que a variação temporal da força que o impactante (p.e.: uma partícula sólida) exerce sobre o impactado (p.e: o meio de propagação) durante o tempo em que os dois permanecem em contato. Desta forma, para simular estas fontes de excitação é necessário o entendimento da dinâmica do fenômeno de impacto¹.

Mas o que é impacto? Segundo HERTZ [93], impacto é o fenômeno que ocorre quando dois corpos entram em contato através de uma pequena área da superfície de ambos e ao mesmo tempo exercem um sobre o outro uma pressão finita distribuída sobre esta área de contato.

Embora outras teorias tenham sido desenvolvidas ao longo dos anos (HAYAKAWA e KUNINAKA [127]), a teoria do impacto de Hertz ainda permanece útil e válida, sendo empregada em várias pesquisas recentes (KOCUR [39], MCLASKEY e GLASER [45], TRAMONTANA *et al.* [20]).

De acordo com a teoria do impacto de Hertz, durante o impacto elástico de uma esfera de raio b com uma placa plana, a força de impacto transiente é dada por:

$$F_0(t) = \begin{cases} k\alpha(t)^{3/2} & 0 \leq t \leq t_c \\ 0 & t > t_c \end{cases} \quad (3.1)$$

onde $\alpha(t)$ é a indentação relativa (ou extensão da compressão) transiente,

$$k = \frac{4}{3}\sqrt{b} \left(\frac{1 - \nu_1^2}{E_1} + \frac{1 - \nu^2}{E} \right)^{-1} \quad (3.2)$$

e ν_1 , ν , E_1 , E são as razões de Poisson e os módulos de Young da esfera e da placa, respectivamente².

A partir da Equação 3.1 é possível calcular a energia potencial U dos corpos durante o contato, ou seja,

$$U(t) = \frac{2}{5}k[\alpha(t)]^{5/2} \quad (3.3)$$

uma vez que $F(t) = \partial U(t)/\partial \alpha(t)$. Aplicando a lei da conservação de energia durante o tempo de contato entre os corpos, temos:

¹O problema do impacto entre corpos sólidos elásticos foi abordado matematicamente pela primeira vez por HERTZ [93]. Hertz desenvolveu esta teoria no feriado de Natal de 1880, aos vinte e três anos.

²O leitor interessado pode obter as definições destas propriedades elásticas dos materiais em LANDAU e LIFSCHITZ [104][p.13]

$$\frac{1}{2}m_1 \left[\frac{d\alpha(t)}{dt} \right]^2 + \frac{2}{5}k[\alpha(t)]^{5/2} = \frac{1}{2}m_1v^2 \quad (3.4)$$

onde m_1 e v são a massa da esfera e a velocidade de impacto, respectivamente.

Uma vez que a indentação máxima α_0 entre a esfera e a placa irá ocorrer no momento em que a velocidade relativa $d\alpha(t)/dt$ entre ambas se anular, então:

$$\alpha_0 = \frac{5}{4} \left(\frac{m_1}{k} \right)^{2/5} v^{4/5} \quad (3.5)$$

Durante o contato entre os corpos, a indentação α varia de 0 até α_0 e novamente retorna a 0, logo o tempo de contato t_c é dado pela seguinte relação obtida a partir da Equação 3.4:

$$t_c = 2 \int_0^{\alpha_0} \frac{d\alpha}{[v^2 - (4k/5m_1)\alpha^{5/2}]^{1/2}} \quad (3.6)$$

Por meio de uma mudança de variáveis, a Equação 3.6 pode ser re-escrita como:

$$t_c = 2 \frac{\alpha_0}{v} \int_0^1 \frac{dx}{(1 - x^{2/5})^{1/2}} \quad (3.7)$$

A integral na Equação 3.7 pode ser calculada fazendo $x^{2/5} = y$ e usando a definição da função Beta $B(z, w)$ (ABRAMOWITZ [128]):

$$\int_0^1 \frac{dx}{(1 - x^{2/5})^{1/2}} = \frac{2}{5} \int_0^1 y^{2/5-1}(1 - y)^{1/2-1} dy = \frac{2}{5} B\left(\frac{2}{5}, \frac{1}{2}\right) \quad (3.8)$$

ou seja,

$$t_c = \frac{4}{5} B\left(\frac{2}{5}, \frac{1}{2}\right) \frac{\alpha_0}{v} \quad (3.9)$$

Embora a Equação 3.4 não possua solução analítica, a relação entre a indentação relativa e o tempo pode ser calculada numericamente por meio da seguinte relação inversa³:

$$t = \int_0^\alpha \frac{d\alpha}{[v^2 - (4k/5m_1)\alpha^{5/2}]^{1/2}} \quad (3.10)$$

³Obtida a partir da Equação 3.4.

Os valores assim calculados de $\alpha(t)$ podem então ser substituídos na Equação 3.1 resultando na força de impacto transiente $F_0(t)$, cuja representação no domínio da frequência pode ser obtida por meio da transformada de Fourier, ou seja:

$$F_0(\omega) = \int_0^{\infty} F_0(t) e^{-i\omega t} dt \quad (3.11)$$

3.2 Propagação $G_M(r, \omega)$

Embora tenha sido dada preferência a utilização de uma abordagem analítica de modelagem é importante para fins de comparação mencionar brevemente duas abordagens numéricas também empregadas para a modelagem da propagação, a saber: os métodos diretos e os métodos de traçado de raio.

Nos métodos diretos o meio de propagação é representado por uma malha numérica finita uni-, bi- ou tridimensional. As equações diferenciais parciais, incluindo as correspondentes condições de contorno, são resolvidas por métodos discretos, como por exemplo:

- o método das diferenças finitas (SMITH [129], FORNBERG [130], SAMARSKII [131], MOCZO *et al.* [132], , STRIKWERDA [133], SILVA [134]);
- o método dos elementos finitos (ZIENKIEWICZ e TAYLOR [135], COOK *et al.* [136]);
- o método dos elementos de contorno (CHO e ROSE [137], XU [138]);
- os métodos espectrais (FORNBERG [139], FORNBERG [140], DAUDT *et al.* [141], TREFETHEN [142], BOYD [143], COSTA [144], SHEN e TANG [145], BAZÁN [146]), e;
- a abordagem de simulação de interação local (DELSANTO *et al.* [147], DELSANTO *et al.* [148], DELSANTO *et al.* [149], DOBIE *et al.* [150])

Os métodos diretos, embora baseados em discretizações, podem ser muito precisos quando uma malha suficientemente fina é utilizada. Uma outra característica interessante dos métodos diretos é a possibilidade de simular a propagação de ondas elásticas em geometrias bastante complexas. Por outro lado, apesar de diversos melhoramentos, os métodos diretos tendem a ter uma implementação complexa e são computacionalmente intensivos (p.e.: tempo de processamento, quantidade de memória etc.), características que os tornam muitas vezes pouco competitivos em relação a outros métodos como, por exemplo, os métodos do traçado de raios.

Os métodos de traçado de raios ou métodos assintóticos tentam resolver as equações diferenciais parciais do problema de propagação de ondas através de aproximações assintóticas das soluções obtidas pela chamada teoria dos raios (CERVENY [151]). Um raio representa um caminho preferencial onde a energia se propaga de uma fonte a um receptor. Ao invés de considerar o campo de ondas na sua totalidade, a teoria dos raios procura expressar este campo através de uma superposição de "eventos", onde cada evento é caracterizado por um tempo de trânsito e uma amplitude. Embora sejam métodos muito eficientes, são considerados métodos aproximados de previsão de campos acústicos por não considerarem o campo de ondas completo.

Em função das características destas abordagens numéricas e da necessidade de uma modelagem que fosse precisa, rápida e de fácil implementação optou-se por uma terceira via baseada na teoria das ondas de Lamb⁴, descrita em diversos trabalhos (DITRI *et al.* [152], PAVLAKOVIC e ROSE [153], WILCOX [154], PREGO-BORGES [155], GIURGIUTIU [156]), porém nunca antes adotada no contexto da modelagem da cadeia de medição de EA para a caracterização dos tamanhos de partículas sólidas.

Para facilitar o entendimento, um breve resumo da teoria elastodinâmica com foco na derivação e solução analítica da equação do movimento de Navier é apresentado nas subseções 3.2.1 e 3.2.2. Na subseção 3.2.3 é descrito um método de solução analítica aplicável ao caso simples de uma excitação pontual na superfície de uma placa e na subseção 3.2.4 é apresentada uma generalização deste método que permite a obtenção de um modelo analítico para previsão da propagação usando o princípio da superposição. Finalmente, na subseção 3.2.5 são discutidas duas outras soluções analíticas simplificadas utilizadas em trabalhos da literatura no contexto da modelagem da cadeia de medição de EA para a caracterização dos tamanhos de partículas sólidas (CARSON *et al.* [100], CARSON *et al.* [105], CARSON *et al.* [108], CARSON *et al.* [109]).

3.2.1 Equações do movimento

De acordo com LANDAU e LIFSCHITZ [104], a rápida liberação de energia resultante da deformação mecânica de um sólido, além de resultar na geração de ondas elásticas, também resulta na geração de calor que varia ao longo do tempo e do espaço. Este fato não é um mero detalhe, uma vez que ele aumenta significativamente a complexidade do problema e dificulta sobremaneira a obtenção de uma solução exata das equações de movimento. Por outro lado, admitindo-se que a propagação espacial do calor seja mais lenta do que os movimentos oscilatórios no

⁴LAMB [126]

interior do sólido, as deformações podem ser consideradas como adiabáticas (LANDAU e LIFSCHITZ [104, p. 101]). Neste caso, a teoria elastodinâmica fornece uma formulação teórica básica para a compreensão do fenômeno de propagação das ondas elásticas.

A teoria elastodinâmica (ACHENBACH [157], POLLARD [158], KOLSKY [159], GRAFF [160]) pode ser resumida pelas relações cinemáticas, pela lei de Hooke generalizada e pela equação de equilíbrio dinâmico.

As relações cinemáticas

$$\epsilon_{ij} = \frac{1}{2} (u_{i,j} - u_{j,i}) \quad (3.12)$$

descrevem a correlação entre o tensor de deformação $\epsilon_{ij} = \epsilon(\epsilon, t)$ e o campo de deslocamento $u_i = \mathbf{u}(\mathbf{x}, t)$ no \mathbb{R}^3 . Usando a notação de Einstein (EINSTEIN [161]), as coordenadas dos eixos são definidas por x_i e pelos vetores base i_j ($j = 1, 2, 3$). Considerando uma relação linear entre tensão e deformação e aplicando a lei de Hooke generalizada

$$\sigma_{ij} = C_{ijkl}\epsilon_{kl} \quad (3.13)$$

as relações constitutivas podem ser formuladas para um contínuo linear elástico.

Na Equação 3.13, $\sigma_{ij} = \sigma(\mathbf{x}, t)$ e $C_{ijkl} = \mathbf{C}(\mathbf{x})$ representam, respectivamente, o tensor de tensão e o tensor elástico de quarta ordem. Em três dimensões, um tensor de quarta ordem contém $3^4 = 81$ elementos, neste caso, 81 constantes elásticas. Entretanto, pode ser mostrado, usando a conservação do momento angular e argumentos da termodinâmica, que os tensores possuem as seguintes simetrias (BOWER [162]):

$$\epsilon_{kl} = \epsilon_{lk} \quad (3.14)$$

$$C_{ijkl} = C_{ijlk} = C_{jikl} = C_{klij} \quad (3.15)$$

Isto reduz o número das constantes elásticas para 21. Considerando um meio de propagação homogêneo e isotrópico, pode ser mostrado (MALVERN [163]) que, neste caso, o tensor elástico (linear) de quarta ordem é dado por:

$$C_{ijkl} = \lambda \delta_{ij} \delta_{kl} + \mu (\delta_{ik} \delta_{jl} + \delta_{il} \delta_{jk}) \quad (3.16)$$

onde δ_{ij} é a função delta de Kronecker ($\delta_{ij} = 1$ para $i = j$ e $\delta_{ij} = 0$ para $i \neq j$) e os dois únicos elementos independentes λ e μ são conhecidos, respectivamente, como o primeiro e o segundo parâmetros de Lamé em homenagem ao matemático francês Gabriel Lamé.

A substituição da Equação 3.16 na Equação 3.13 fornece o tensor de tensão para um meio homogêneo isotrópico:

$$\sigma_{ij} = \lambda \delta_{ij} \epsilon_{kk} + 2\mu \epsilon_{ij} \quad (3.17)$$

O segundo parâmetro de Lamé (μ), também conhecido como módulo de cisalhamento, é uma medida da resistência do meio de propagação ao cisalhamento ou torção (quanto maior o módulo de cisalhamento, mais rígido será o meio). Já o primeiro parâmetro de Lamé (λ), apesar de não possuir um significado físico claro, define importantes constantes elásticas do meio, em combinação com o módulo de cisalhamento (μ). No caso de meios de propagação isotrópicos, constantes elásticas como o módulo de Young E e a razão de Poisson ν (a razão entre a contração lateral e a extensão longitudinal) podem ser expressas como relações entre λ e μ , conforme mostrado na Tabela 3.1.

Finalmente, aplicando a equação de balanço de momento às tensões que atuam em um elemento infinitesimal do meio propagação, é possível obter a equação de equilíbrio dinâmico (também conhecida como "lei do movimento" de Cauchy):

$$\rho u_{i,tt} = \sigma_{ij,j} + f_i \quad (3.18)$$

onde ρ é a massa específica do meio e $f_i = \mathbf{f}(\mathbf{x}, t)$ é o campo de força de corpo. Observe que $\sigma_{ij,j} = \frac{\partial \sigma_{ij}}{\partial x_j}$ é a primeira derivada parcial do tensor de tensão em relação à direção x_j e $u_{i,tt} = \frac{\partial^2 u_i}{\partial t^2}$ é a segunda derivada parcial do campo de deslocamento em relação ao tempo t . Substituindo as relações cinemáticas (Equação 3.12) e a lei de Hooke generalizada (Equação 3.17) na equação de equilíbrio dinâmico (Equação 3.18), o sistema de três equações diferenciais parciais acopladas

$$\rho u_{i,tt} = (\lambda + \mu) u_{k,ki} + \mu u_{i,kk} + f_i \quad (3.19)$$

é obtido, o qual é conhecido como equação do movimento de Navier em homenagem ao engenheiro, matemático e físico francês Claude Louis Marie Henri Navier. A Equação 3.19 (ACHENBACH [157][p.56]) também pode ser expressa segundo a notação vetorial

	E, ν	E, μ	λ, μ
λ	$\frac{E\nu}{(1+\nu)(1-2\nu)}$	$\frac{\mu(E-2\mu)}{3\mu-E}$	λ
μ	$\frac{E}{2(1+\nu)}$	μ	μ
E	E	E	$\frac{\mu(3\lambda+2\mu)}{\lambda+\mu}$
ν	ν	$\frac{E-2\mu}{2\mu}$	$\frac{\lambda}{2(\lambda+\mu)}$

Tabela 3.1: Relações entre as constantes elásticas isotrópicas.

$$\rho \ddot{\mathbf{u}} = (\lambda + \mu) \nabla \nabla \cdot \mathbf{u} + \mu \nabla^2 \mathbf{u} + \mathbf{f} \quad (3.20)$$

a qual é uma forma mais adequada para a sua solução.

3.2.2 Decomposição do campo de deslocamento

A equação do movimento de Navier (Equação 3.20) apresenta uma característica adversa para sua solução na medida em que os componentes do campo de deslocamento $\mathbf{u} = [u_1, u_2, u_3]$ encontram-se todos acoplados. Uma forma elegante de manipular esta equação é através do emprego de funções potenciais para decompor o campo de deslocamento \mathbf{u} em dois campos, um associado às ondas longitudinais e o outro associado às ondas transversais. Neste caso, usando as derivadas dos potenciais de Helmholtz escalar ϕ e vetorial Ψ (ACHENBACH [157]), o campo de deslocamento pode ser escrito como:

$$\mathbf{u} = \nabla \phi + \nabla \times \Psi + \mathbf{f} \quad (3.21)$$

onde $\nabla \phi$ é o gradiente de ϕ e $\nabla \times \Psi$ é o rotacional de Ψ . Na ausência de forças de corpo ($\mathbf{f} = 0$), a Equação 3.21 é substituída na Equação 3.20, de forma a separar o campo de deslocamento em uma parte dilatacional (irrotacional) e outra isocórica (volume constante). Re-escrevendo a Equação 3.20, após a substituição temos

$$\rho \frac{\partial^2}{\partial t^2} [\nabla \phi + \nabla \times \Psi] = (\lambda + \mu) \nabla \nabla \cdot [\nabla \phi + \nabla \times \Psi] + \mu \nabla^2 [\nabla \phi + \nabla \times \Psi] \quad (3.22)$$

e sendo $\nabla \cdot \nabla \phi = \nabla^2 \phi$ e $\nabla \cdot \nabla \times \Psi = 0$, a equação equivalente

$$\nabla \left[(\lambda + \mu) \nabla^2 \phi - \rho \ddot{\phi} \right] + \nabla \times \left[\mu \nabla^2 \Psi - \rho \ddot{\Psi} \right] = 0 \quad (3.23)$$

é obtida. Como esta equação é satisfeita quando os termos entre colchetes se anulam, isto resulta nas seguintes equações diferenciais desacopladas

$$\nabla^2 \phi = \frac{1}{c_l^2} \ddot{\phi} \quad (3.24a)$$

$$\nabla^2 \Psi = \frac{1}{c_t^2} \ddot{\Psi} \quad (3.24b)$$

onde c_l e c_t são as velocidades das ondas longitudinais (dilatacionais, de compressão) e transversais (isocóricas, de cisalhamento), respectivamente. A razão κ entre estas velocidades é função da razão de Poisson ν , uma vez que:

$$\kappa = \frac{c_l}{c_t} = \sqrt{\frac{\lambda + 2\mu}{\mu}} = \sqrt{\frac{2(1-\nu)}{1-2\nu}} \quad (3.25)$$

Dada a faixa de variação da razão de Poisson ν nos sólidos ($0 \leq \nu \leq 0.5$), resulta que as ondas longitudinais se propagam mais rapidamente que as transversais, sendo este o motivo pelo qual aquelas também são conhecidas como ondas P (primárias), enquanto estas são conhecidas como ondas S (secundárias).

3.2.3 Excitação harmônica pontual

As Equações 3.24 descrevem o comportamento das ondas no interior de um sólido. Para modelar a propagação de ondas elásticas geradas pela aplicação de uma excitação harmônica, pontual e axialmente simétrica na superfície de uma placa plana, homogênea e isotrópica de espessura d , coordenadas retangulares e cilíndricas polares são definidas como mostra a Figura 3.1 onde o meio plano da camada corresponde a $z = 0$.




Figura 3.1: Coordenadas retangulares e cilíndricas polares definidas para uma placa plana, homogênea e isotrópica de espessura d .

Em função da simetria axial, a tensão angular transversa $\sigma_{z\theta}$ será nula, o campo de deslocamento será independente do ângulo θ e o componente angular do campo de deslocamento u_θ também será nulo. Estes dois últimos requisitos podem ser satisfeitos fazendo com que os componentes em r e θ do potencial vetorial de Helmholtz Ψ sejam nulos. Assim, o referido potencial vetorial é reduzido a um escalar, o componente na direção z ($\psi = \psi_z$).

Considerando os potenciais de Helmholtz como sendo harmônicos, ou seja, dependentes de $e^{-i\omega t}$, as Equações 3.24 podem ser re-escritas (em coordenadas cilíndricas polares) como:

$$\frac{\partial^2 \phi}{\partial r^2} + \frac{1}{r} \frac{\partial \phi}{\partial r} + \frac{\partial^2 \phi}{\partial z^2} + \frac{\omega^2}{c_l^2} \phi = 0 \quad (3.26a)$$

$$\frac{\partial^2 \psi}{\partial r^2} + \frac{1}{r} \frac{\partial \psi}{\partial r} - \frac{\psi}{r^2} + \frac{\partial^2 \psi}{\partial z^2} + \frac{\omega^2}{c_t^2} \psi = 0 \quad (3.26b)$$

Neste caso, dada a natureza axisimétrica do problema, a transformada de Hankel fornece um meio conveniente para a obtenção de uma solução em forma fechada. Dada uma função arbitrária $b(r)$, a transformada de Hankel de ordem n e sua inversa são definidas como (PIESSENS [164]):

$$\begin{aligned} B_n(\xi) &= \mathcal{H}_n \{b(r)\} = \int_0^\infty r b(r) J_n(\xi r) dr \\ b(r) &\equiv \mathcal{H}_n^{-1} \{B_n(\xi)\} = \int_0^\infty \xi B_n(\xi) J_n(\xi r) d\xi \end{aligned} \quad (3.27)$$

onde $J_n(\bullet)$ representa a função de Bessel de primeiro tipo de ordem n . Usando integração por partes, pode ser mostrado que

$$\begin{aligned} \mathcal{H}_0 \left\{ \frac{d^2 b(r)}{dr^2} + \frac{1}{r} \frac{db(r)}{dr} \right\} &= -\xi^2 B_0(r) \\ \mathcal{H}_1 \left\{ \frac{d^2 b(r)}{dr^2} + \frac{1}{r} \frac{db(r)}{dr} - \frac{b(r)}{r^2} \right\} &= -\xi^2 B_1(r) \end{aligned} \quad (3.28)$$

na medida em que $b(r)$ e suas derivadas, com respeito a r , se anulam para $r = 0$ e para $r \rightarrow \infty$.

Aproveitando as propriedades das Equações 3.28, a transformada de Hankel de ordem zero é aplicada na Equação 3.26a e a transformada de Hankel de primeira ordem é aplicada na Equação 3.26b, resultando nas seguintes equações diferenciais:

$$\frac{d^2 \Phi_0}{dz^2} - (\xi^2 - k_l^2) = 0 \quad (3.29a)$$

$$\frac{d^2 \Psi_1}{dz^2} - (\xi^2 - k_t^2) = 0 \quad (3.29b)$$

onde ξ , $k_l = \omega/c_l$ e $k_t = \omega/c_t$ são o número de onda, o número de onda longitudinal e o número de onda transversal, respectivamente.

Uma solução geral para o conjunto de Equações 3.29 é dada por:

$$\Phi_0(\xi, z) = S_1(\xi)\cosh(q_l z) + A_1(\xi)\sinh(q_l z) \quad (3.30a)$$

$$\Psi_1(\xi, z) = A_t(\xi)\cosh(q_t z) + S_t(\xi)\sinh(q_t z) \quad (3.30b)$$

onde $S_l(\xi)$, $A_l(\xi)$, $S_t(\xi)$ e $A_t(\xi)$ são funções arbitrárias, $q_l = \sqrt{\xi^2 - k_l^2}$ e $q_t = \sqrt{\xi^2 - k_t^2}$.

As funções arbitrárias das Equações 3.30 podem ser obtidas satisfazendo as condições de contorno. Como as condições de contorno são impostas nos componentes de tensão e não nos potenciais de Helmholtz, torna-se necessário expressar os componentes de tensão em termos dos referidos potenciais. Usando as Equações 3.21, 3.12 e 3.17 é possível re-escrever os componentes de tensão em função dos potenciais de Helmholtz:

$$\sigma_{zz}(r, z) = \lambda \left[\frac{\partial^2 \phi}{\partial r^2} + \frac{1}{r} \frac{\partial \phi}{\partial r} + \frac{\partial^2 \phi}{\partial z^2} \right] + 2\mu \left[\frac{\partial^2 \phi}{\partial z^2} + \frac{1}{r} \frac{\partial}{\partial r} \left(r \frac{\partial \psi}{\partial z} \right) \right] \quad (3.31a)$$

$$\sigma_{rz}(r, z) = -\mu \left[2 \frac{\partial^2 \phi}{\partial r \partial z} + \frac{\partial^2 \psi}{\partial r^2} + \frac{1}{r} \frac{\partial \psi}{\partial r} - \frac{\psi}{r} - \frac{\partial^2 \psi}{\partial z^2} \right] \quad (3.31b)$$

Aplicando a transformada de Hankel de ordem zero na Equação 3.31a e a transformada de Hankel de ordem um na Equação 3.31b obtém-se as condições de contorno transformadas:

$$\Sigma_{zz}(\xi, z) = H_0 \{ \sigma_{zz}(r, z) \} = -\lambda k_l^2 \Phi_0 + 2\mu \frac{d^2 \Phi_0}{dz^2} + 2\mu \xi \frac{d\Psi_1}{dz} \quad (3.32a)$$

$$\Sigma_{rz}(\xi, z) = H_1 \{ \sigma_{rz}(r, z) \} = -\mu \left\{ 2\xi \frac{d\Phi_0}{dz} + \xi^2 \Psi_1 + \frac{d^2 \Psi_1}{dz^2} \right\} \quad (3.32b)$$

Substituindo a solução geral (Equações 3.30) nas condições de contorno transformadas (Equações 3.32) relativas às superfícies da placa ($z = \pm d/2$), é possível obter a seguinte equação matricial:

$$\begin{bmatrix} \Sigma_{zz}(\xi, z = +d/2) \\ \Sigma_{zz}(\xi, z = -d/2) \\ \Sigma_{rz}(\xi, z = +d/2) \\ \Sigma_{rz}(\xi, z = -d/2) \end{bmatrix} = \mu A \begin{bmatrix} S_l(\xi) \\ A_l(\xi) \\ A_t(\xi) \\ S_t(\xi) \end{bmatrix} \quad (3.33)$$

onde

$$A = \begin{bmatrix} (\xi^2 + q_t^2) \cosh(q_l d/2) & (\xi^2 + q_t^2) \sinh(q_l d/2) & 2i\xi q_t \sinh(q_t d/2) & 2i\xi q_t \cosh(q_t d/2) \\ (\xi^2 + q_t^2) \cosh(q_l d/2) & -(\xi^2 + q_t^2) \sinh(q_l d/2) & -2i\xi q_t \sinh(q_t d/2) & 2i\xi q_t \cosh(q_t d/2) \\ 2i\xi q_t \sinh(q_l d/2) & 2i\xi q_t \cosh(q_l d/2) & -(\xi^2 + q_t^2) \cosh(q_t d/2) & -(\xi^2 + q_t^2) \sinh(q_t d/2) \\ -2i\xi q_t \sinh(q_l d/2) & 2i\xi q_t \cosh(q_l d/2) & -(\xi^2 + q_t^2) \cosh(q_t d/2) & (\xi^2 + q_t^2) \sinh(q_t d/2) \end{bmatrix} \quad (3.34)$$

Para que a Equação 3.33 possua soluções não triviais, o determinante da matriz \mathbf{A} deve ser nulo. Por meio de manipulações algébricas, o determinante da matriz \mathbf{A} na Equação 3.34 pode ser fatorado no produto de dois fatores:

$$\Delta_S = (\xi^2 + q_t^2)^2 \cosh(q_l d/2) \sinh(q_t d/2) - 4\xi^2 q_t q_l \cosh(q_t d/2) \sinh(q_l d/2) \quad (3.35)$$

que representa a função de dispersão do modo simétrico das ondas de Lamb unidimensionais em uma superfície livre, e

$$\Delta_A = (\xi^2 + q_t^2)^2 \sinh(q_l d/2) \cosh(q_t d/2) - 4\xi^2 q_t q_l \sinh(q_t d/2) \cosh(q_l d/2) \quad (3.36)$$

que representa a função de dispersão do modo anti-simétrico das ondas de Lamb unidimensionais em uma superfície livre.

No caso em que ambas as superfícies livres da placa estejam imersas no vácuo, as relações entre a frequência ω e o número de onda ξ , conhecidas como curvas de dispersão, podem ser obtidas para cada um dos modos simétrico e anti-simétrico igualando as Equações 3.35 e 3.36 a zero e obtendo suas raízes reais para diversos valores de frequência ω em um dado intervalo (VIKTOROV [165]). No caso de outras estruturas, como cascas cilíndricas ou placas imersas em um fluido, as curvas de dispersão podem ser obtidas através de métodos matriciais como o método da matriz de transferência (HASKELL [166]) e o método da matriz global (KNOPOFF [167], LOWE [168], PAVLAKOVIC *et al.* [169]).

A Equação 3.33 fornece a relação entre as funções arbitrárias da solução geral (Equação 3.30) e as condições de contorno transformadas, as quais são definidas pela excitação aplicada à placa. Conforme mostrado na Figura 3.2, uma excitação pontual, harmônica e axialmente simétrica aplicada na região $r \equiv \sqrt{x^2 + y^2} \leq a$ da superfície da placa irá resultar nas seguintes condições de contorno:




Figura 3.2: Excitação pontual, harmônica e axialmente simétrica aplicada na região $r \equiv \sqrt{x^2 + y^2} \leq a$ da superfície da placa.

$$\sigma_{zz}(r, z = +d/2) = \begin{cases} f(r) & 0 < r \leq a \\ 0 & r > a \end{cases} \quad (3.37a)$$

$$\sigma_{zz}(r, z = -d/2) = 0 \quad (3.37b)$$

$$\sigma_{rz}(r, z = +d/2) = \begin{cases} g(r) & 0 < r \leq a \\ 0 & r > a \end{cases} \quad (3.37c)$$

$$\sigma_{rz}(r, z = -d/2) = 0 \quad (3.37d)$$

onde $f(r)$ é a distribuição axial das tensões normais e $g(r)$ é a distribuição das tensões transversas na direção radial.

Aplicando a transformada de Hankel de ordem zero na Equação 3.37a e a transformada de Hankel de ordem um na Equação 3.37c, obtêm-se as seguintes condições de contorno transformadas:

$$\begin{bmatrix} \Sigma_{zz}(\xi, z = +d/2) \\ \Sigma_{zz}(\xi, z = -d/2) \\ \Sigma_{rz}(\xi, z = +d/2) \\ \Sigma_{rz}(\xi, z = -d/2) \end{bmatrix} = \begin{bmatrix} F_0(\xi) \\ 0 \\ G_1(\xi) \\ 0 \end{bmatrix} \quad (3.38)$$

Igualando a Equação 3.38 a Equação 3.33 e aplicando regra de Cramer é possível obter as seguintes expressões para as funções arbitrarias da Equação 3.30:

$$S_l(\xi) = \frac{A_{14}(\xi) G_1(\xi) - A_{34}(\xi) F_0(\xi)}{2\mu^2 \Delta_S(\xi)} \quad (3.39a)$$

$$A_l(\xi) = \frac{A_{13}(\xi) G_1(\xi) - A_{33}(\xi) F_0(\xi)}{2\mu^2 \Delta_A(\xi)} \quad (3.39b)$$

$$A_t(\xi) = \frac{A_{32}(\xi) F_0(\xi) - A_{12}(\xi) G_1(\xi)}{2\mu^2 \Delta_A(\xi)} \quad (3.39c)$$

$$S_t(\xi) = \frac{A_{31}(\xi) F_0(\xi) - A_{11}(\xi) G_1(\xi)}{2\mu^2 \Delta_S(\xi)} \quad (3.39d)$$

Substituindo estas expressões na Equação 3.30 e aplicando as transformadas inversas de Hankel de ordens apropriadas, é possível obter as soluções para os potenciais de Helmholtz. Restringindo a generalidade da excitação para o caso em que a mesma seja normal ($g(r) = 0$) e uniforme ($f(r) = -\sigma_0$), resolvendo as integrais resultantes das transformadas inversas usando o teorema dos resíduos e efetuando o algebrismo necessário, é possível obter a seguinte expressão para o componente vertical do vetor de deslocamento \mathbf{u}

$$u_3 = -\frac{\pi\sigma_0}{2\mu} \left\{ \begin{array}{l} \sum_{\xi_S} \frac{aJ_1(\xi a)}{\xi} \xi \frac{q_l [(q_t^2 - \xi^2) \sinh(q_t d/2) \sinh(q_l d/2)]}{\partial \Delta_S / \partial \xi} H_0^{(1)}(\xi r) \\ + \\ \sum_{\xi_A} \frac{aJ_1(\xi a)}{\xi} \xi \frac{q_l [(q_t^2 - \xi^2) \cosh(q_t d/2) \cosh(q_l d/2)]}{\partial \Delta_A / \partial \xi} H_0^{(1)}(\xi r) \end{array} \right\} e^{-i\omega t} \quad (3.40)$$

onde $H_0^{(1)}(\bullet)$ é a função de Hankel de primeiro tipo e ordem zero.

Restringindo ainda mais a generalidade da excitação para o caso em que a mesma seja pontual, dado que

$$\lim_{a \rightarrow 0} \frac{aJ_1(\xi a)}{\xi} = a^2 \lim_{a \rightarrow 0} \frac{J_1(\xi a)}{\xi a} = \frac{a^2}{2} \quad (3.41)$$

então a Equação 3.40 pode ser re-escrita como:

$$u_3(r, t, \omega) = -F_0 \frac{1}{4\mu} \left\{ \begin{array}{l} \sum_{\xi_S} \xi \frac{q_l [(q_t^2 - \xi^2) \sinh(q_t d/2) \sinh(q_l d/2)]}{\partial \Delta_S / \partial \xi} H_0^{(1)}(\xi r) \\ + \\ \sum_{\xi_A} \xi \frac{q_l [(q_t^2 - \xi^2) \cosh(q_t d/2) \cosh(q_l d/2)]}{\partial \Delta_A / \partial \xi} H_0^{(1)}(\xi r) \end{array} \right\} e^{-i\omega t} \quad (3.42)$$

onde $F_0 = \pi a^2 \sigma_0$ é a amplitude da excitação pontual.

A Equação 3.42 fornece o deslocamento vertical da superfície da placa e representa um modelo de previsão da propagação de ondas elásticas geradas pela aplicação de uma excitação pontual, harmônica e axialmente simétrica na superfície de uma placa plana, homogênea, isotrópica de espessura d imersa no vácuo. A excitação harmônica é dada por uma força de amplitude F_0 e frequência ω aplicada no ponto da superfície da placa $r = 0$ no instante de tempo $t = 0$.

3.2.4 Generalização para uma excitação transiente

A solução particular dada pela Equação 3.42 para a previsão dos campos acústicos está associada a uma fonte de excitação harmônica no tempo, ou seja, uma fonte de excitação que possui duração infinita e largura de banda infinitesimal. Entretanto, no caso dos campos acústicos gerados pelo impacto de partículas sólidas, a fonte de excitação é transiente, ou seja, possui duração e largura de banda finitas.

Assim, para que seja possível prever estes campos acústicos o modelo precisa considerar a excitação das ondas elásticas sobre um intervalo finito do espectro de frequência ao invés de em uma única frequência.

Uma solução natural para este problema pode ser obtida usando o princípio da superposição. Em todos os sistemas causais e lineares, o princípio da superposição assegura que a resposta causada por dois ou mais estímulos é dada pela soma das respostas causadas por cada estímulo individualmente.

Na prática isto significa que a resposta em um intervalo finito do espectro de frequência pode ser obtida através do somatório das respostas individuais a estímulos correspondentes a cada frequência presente no intervalo. Adicionalmente, cabe ressaltar que o princípio da superposição é válido neste caso pelo fato da Equação 3.19 ser linear e de natureza hiperbólica, o que garante a sua causalidade.

Desta forma, a generalização do modelo pode ser obtida naturalmente aplicando-se a transformada de Fourier inversa sobre o resultado do produto entre a transformada de Fourier complexa da fonte de excitação $F_0(\omega)$ e a função de transferência da propagação, ou seja,

$$u_3(r, t) = \frac{1}{2\pi} \int F_0(\omega) G_M(r, \omega) e^{i\omega t} d\omega \quad (3.43)$$

onde a função de transferência da propagação é dada por

$$G_M(r, \omega) = \frac{1}{4\mu} \left\{ \begin{array}{l} \sum_{\xi_S} \xi \frac{q_l [(q_t^2 - \xi^2) \sinh(q_t d/2) \sinh(q_l d/2)]}{\partial \Delta_S / \partial \xi} H_0^{(1)}(\xi r) \\ + \\ \sum_{\xi_A} \xi \frac{q_l [(q_t^2 - \xi^2) \cosh(q_t d/2) \cosh(q_l d/2)]}{\partial \Delta_A / \partial \xi} H_0^{(1)}(\xi r) \end{array} \right\} \quad (3.44)$$

Uma observação importante com relação à função de transferência do meio de propagação $G_M(r, \omega)$ é que, embora ela tenha sido obtida considerando o caso particular de uma placa plana, homogênea, isotrópica de espessura d imersa no vácuo, ainda assim é possível generalizá-la para a previsão de campos acústicos em outros meios de propagação desde que suas curvas de dispersão, ou seja, as relações entre a frequência ω e o número de onda ξ , sejam conhecidas⁵.

3.2.5 Abordagens analíticas simplificadas

Outras abordagens analíticas também são utilizadas na modelagem da propagação de sinais de EA gerados por impactos de partículas na superfície de um material. Estas abordagens são baseadas em teorias aproximadas que simplificam a Equação 3.19 para o caso da propagação de ondas em uma placa plana, homogênea, isotrópica de espessura d imersa no vácuo. As duas teorias aproximadas mais empregadas são a teoria de Kirchhoff-Love e a teoria de Mindlin.

LOVE [170] desenvolveu a teoria de Kirchhoff-Love, a qual é uma extensão para placas finas da teoria da vigas de Euler-Bernoulli. Através desta teoria é possível obter a seguinte simplificação da Equação 3.19 para o caso o caso da propagação de ondas em um placa plana, homogênea, isotrópica de espessura d imersa no vácuo:

$$\rho \ddot{u} = \frac{1}{d} \left[\frac{Ed^3}{12(1-\nu^2)} \right] \nabla^4 u + f \quad (3.45)$$

Posteriormente, baseando-se em hipóteses menos restritivas que aquelas propostas por Kirchhoff, MINDLIN [171] generalizou a teoria das placas finas para o caso das placas espessas. Analogamente ao caso anterior, a seguinte simplificação da Equação 3.19 pode ser obtida:

⁵As curvas de dispersão utilizadas nesta investigação foram obtidas por meio do *software* Disperse (PAVLAKOVIC *et al.* [169]).

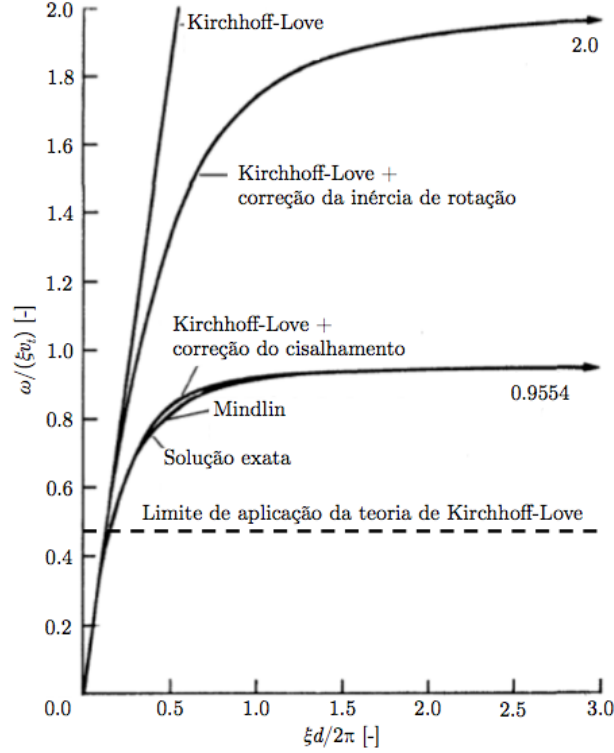


Figura 3.3: Comportamento dispersivo do modo anti-simétrico de ordem zero obtido através de diferentes teorias (adaptado de MINDLIN [171][Fig. 1]).

$$\rho \ddot{u} = \frac{1}{d} \left\{ \nabla^2 - \left[\frac{\rho}{\kappa^2 \mu} \right] \frac{\partial^2}{\partial t^2} \right\} \left\{ \left[\frac{Ed^3}{12(1-\nu^2)} \right] \nabla^2 - \left[\frac{\rho d^3}{12} \right] \frac{\partial^2}{\partial t^2} \right\} u \quad (3.46)$$

$$+ \left\{ 1 - \left[\frac{Ed^2}{12\kappa^2\mu(1-\nu^2)} \right] \nabla^2 + \left[\frac{\rho d^2}{12\kappa^2\mu} \right] \frac{\partial^2}{\partial t^2} \right\} f \quad (3.47)$$

onde κ é o coeficiente de cisalhamento.

Embora também seja possível obter expressões para a função de transferência do meio de propagação $G_M(r, \omega)$ tendo como ponto de partida a Equação 3.45 ou a Equação 3.46 ao invés da Equação 3.19, as expressões obtidas são incapazes de reproduzir de forma adequada o fenômeno de propagação das ondas de Lamb unidimensionais em uma superfície livre na região de alta frequência.

O primeiro motivo desta incapacidade advém do fato de que estas duas teorias aproximadas só conseguem prever um único modo de propagação das ondas, o modo anti-simétrico de ordem zero, também conhecido como "modo flexural". Estas teorias ignoram completamente a propagação de modos anti-simétricos de ordem superior, como também dos modos simétricos de todas as ordens. Além disso, conforme mostrado na Figura 3.3, a teoria de Kirchhoff-Love só é capaz de prever razoavelmente o comportamento dispersivo do "modo flexural" na região de baixa frequência.

No caso do impacto de partículas sólidas de dimensão elevada estas duas limitações não acarretam grandes desvios porque a fonte irá excitar predominantemente as baixas frequências. Isso porque na região de baixa frequência o modo simétrico de ordem zero apresenta baixa intensidade e também porque não ocorre propagação dos modos de ordem superior conforme pode ser verificado no exemplo de curvas de dispersão mostrado na Figura 3.4.

Por outro lado, grandes desvios são esperados quando do impacto de partículas sólidas de dimensão reduzida, uma vez que neste caso a fonte também é capaz de excitar as frequências mais altas. Na região de alta frequência os desvios esperados são ainda mais elevados no caso da teoria de Kirchhoff-Love conforme mostrado na Figura 3.3.

Por fim é importante mencionar que, apesar destas limitações já serem conhecidas há muito tempo, ainda assim a teoria aproximada de Kirchhoff-Love foi utilizada de forma incorreta, ou seja, fora da faixa de aplicação, em uma série de trabalhos recentes (CARSON *et al.* [100, 105, 108, 109]). Nestes artigos, a frequência máxima do sinal modelado é da ordem de 600 kHz porém, considerando as características do meio de propagação modelado, a teoria de Kirchhoff-Love só seria válida até aproximadamente 4 kHz.

No trabalho aqui apresentado estas duas teorias também foram erroneamente empregadas em etapas iniciais: primeiro a de Kirchhoff-Love (Equação 3.45) depois a de Mindlin (Equação 3.46). Entretanto, ao serem constatadas as suas limitações, uma nova linha de estudos foi iniciada, a qual resultou na abordagem apresentada anteriormente baseada na teoria das ondas de Lamb (Equação 3.44).

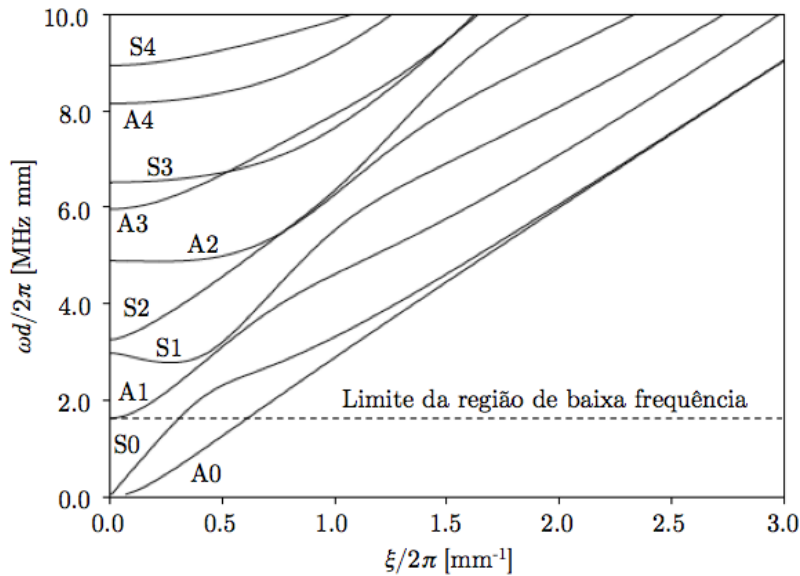


Figura 3.4: Exemplo de curvas de dispersão de uma placa plana, homogênea, isotrópica ($\nu = 0,286$).

3.3 Detector $G_D(\omega)$

Conforme mencionado na subseção 2.2.2 do Capítulo 2, nesta investigação o detector é definido como o conjunto formado pelo sensor e pelo sistema de aquisição, ou seja:

$$G_D(\omega) = G_S(\omega)G_A(\omega) \quad (3.48)$$

onde $G_S(\omega)$ e $G_A(\omega)$ são, respectivamente, as funções de transferência do sensor e do sistema de aquisição.

Em contraste com as funções de transferência da fonte e do meio de propagação, cuja abordagem analítica é capaz de fornecer modelos bastante satisfatórios, o mesmo não é verdade no caso da modelagem das funções de transferência do sensor e do sistema de aquisição. Neste caso uma abordagem empírica usando técnicas experimentais é mais indicada, pois é capaz de fornecer modelos mais aproximados da realidade.

No caso do sistema de aquisição, a sua função de transferência pode ser facilmente obtida por meio de um analisador de redes (AGILENT [172]). Por outro lado em função do sofisticado projeto do sistema de aquisição de EA é de se esperar que a influência do sistema de aquisição na característica do sinal registrado seja mínima. Desta forma, caso dados experimentais do sistema de aquisição de EA não estejam disponíveis, podemos considerar que o mesmo seja ideal, ou seja, $G_A(\omega) = 1$.

De fato, como mostrado na Figura 2.8, das duas de funções de transferência que compõem o detector, a função de transferência do sensor $G_S(\omega)$ é a que mais impacta a característica do sinal registrado, sobretudo no caso dos sensores ressonantes. Ao contrário do sistema de medição, a determinação da função de transferência⁶ dos sensores piezoelétricos de emissão acústica é muito mais difícil.

Diversos métodos experimentais foram propostos para a calibração primária de sensores piezoelétricos de emissão acústica. Os mais comuns são a calibração pela função degrau (ASTM [173]) e a calibração por reciprocidade (ISO [174]). Outros métodos empregando vibrômetros laser também são aplicáveis (GROSSE [175], GOUJON e BABOUX [176], MONNIER *et al.* [177]) e, recentemente, MCLASKEY e GLASER [45] propoaram um novo método de calibração baseado no impacto de esferas.

Conforme observado por GOUJON e BABOUX [176], não há expectativa de se obter uma função de transferência absoluta do sensor uma vez que a característica de sensibilidade de frequência do sensor também depende das propriedades elásticas do meio de propagação sobre o qual ele é aplicado. Este efeito é causado pela diferença entre as impedâncias acústicas entre o sensor e o meio de propagação. Outra possível influência sobre a função de transferência dos sensores é a presença de

⁶Também conhecida como calibração primária.

acoplantes entre o sensor e o meio de propagação. Conforme reportado recentemente por THEOBALD *et al.* [178], os acoplantes exercem influencia na sensibilidade dos sensores, entretanto esta influência é desprezível quando comparada a outras fontes⁷.

Contudo, segundo BEATTIE [26][p. 37], ainda assim a curva de calibração fornecida pelos fabricantes representa uma boa aproximação para a função de transferência do sensor. Normalmente a resposta relativa do sensor nas curvas de calibração é expressa em dB referenciado a $1 \text{ V (m s}^{-1}\text{)}^{-1}$, entretanto muitos fabricantes expressam a resposta relativa referenciada a $1 \text{ V } \mu\text{bar}^{-1}$. A Figura 3.5 mostra uma curva da calibração primária de um sensor de EA típico.




Figura 3.5: Curva de calibração de um sensor de EA típico (adaptado de PAC [179]).

Já a Figura 3.6 mostra a representação gráfica da função de transferência $G_C(\omega)$ obtida através da digitalização⁸ da calibração primária de um sensor de EA típico. Finalmente, a Equação 3.49 fornece a função de transferência $G_S(\omega)$ ⁹:

$$G_S(\omega) = \omega Z_M G_C(\omega) \quad (3.49)$$

onde Z_M é a impedância acústica do bloco de calibração, expressa em $\mu\text{bar (m s}^{-1}\text{)}^{-1}$.




Figura 3.6: Função de transferência de um sensor de EA típico.

⁷Por exemplo, a própria variabilidade intrínseca ao processo de fabricação.

⁸Usando o pacote `digitizer` (POISOT [180]).

⁹A multiplicação pelo termo ωZ_M converte a curva de calibração, que é a resposta ao degrau, na resposta ao impulso referenciada a $1 \text{ V (m s}^{-1}\text{)}^{-1}$

Capítulo 4

Método

Neste Capítulo são descritos os métodos utilizados. As Seções subsequentes 4.1 e 4.2 resumem os métodos utilizados na implementação do simulador e na sua validação, respectivamente. Uma breve descrição da aplicação e do método para produzir a base de dados são apresentados na Seção 4.3. A Seção 4.4 descreve os pré-processamentos utilizados pelas abordagens desenvolvidas. Através do emprego de um método clássico de detecção de eventos de EA baseado em limiar foi possível utilizar uma formulação de classificação para o problema. Neste caso, ao invés de se utilizar a prática comum de mapear os sinais de EA nos teores de classes de tamanhos de partículas, optou-se por inicialmente classificar cada evento individualmente para, em seguida, agregá-los e produzir o resultado final. Uma vantagem adicional e inovadora desta nova abordagem é que ela não necessita de re-treinamento. O método associado ao pré-processamento especialista, uma outra proposta inovadora, pois incorpora o conhecimento especialista de EA dos ensaios-não destrutivos, é descrito na Subseção 4.4.1. A Subseção 4.4.2 descreve o pré-processamento estatístico, o qual também é inovador, pois opera diretamente sobre os sinais brutos de EA no domínio do tempo sem a necessidade de transformá-los para o domínio da frequência, e inclui um procedimento simples de compactação usando PCA. As figuras de mérito, os métodos de sintonia dos parâmetros ajustáveis, bem como os métodos de estimação e comparação de desempenho são descritos na Seção 4.5. A Seção 4.6 resume os métodos relacionados à implementação das técnicas de inteligência computacional. As Seções 4.7 e 4.8 encerram o Capítulo descrevendo os métodos das abordagens desenvolvidas e de referência, respectivamente.

4.1 Implementação do simulador

A modelagem da cadeia de medição de EA descrita no Capítulo 3 foi implementada no pacote `pongaR`¹, desenvolvido na linguagem R (R CORE TEAM [181]), que utiliza códigos e funções dos pacotes `seewave` (SUEUR *et al.* [182]), `tuneR` (LIGGES *et al.*

[183]) e `parallel` (RIPLEY *et al.* [184]), para processar os sinais de EA simulados e acelerar os cálculos.

O pacote está disponível no GitHub (<https://github.com/gmxavier/pongaR>) e um exemplo de caso de uso é mostrado no Apendice A.

4.2 Validação do simulador

Para validação do simulador foi empregada a abordagem proposta por MOSER *et al.* [185] e DOBIE *et al.* [150], a qual é baseada no gráfico de contorno das curvas de dispersão simuladas. O referido gráfico de contorno foi obtido utilizando o método proposto por ALLEYNE e CAWLEY [186], o qual se baseia na amostragem espacial da resposta ao impulso do meio de propagação, seguida da aplicação da transformada rápida de Fourier² no tempo e no espaço.

Em outras palavras, a placa³ é excitada por um impulso pontual e amostrada espacialmente para criar uma série de medidas de deslocamento vertical da superfície ao longo do tempo na forma de uma matriz tempo-distância $s(t, x)$. Aplicando-se a transformada rápida de Fourier bidimensional nesta matriz tempo-distância, uma matriz frequência-número de onda $S(\omega, k)$ é produzida e utilizada para gerar o gráfico de contorno que mostra as curvas de dispersão simuladas.

$$S(\omega, k) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} s(t, x) e^{-i(\omega t - kx)} dt dx \quad (4.1)$$

Uma avaliação quantitativa também pode ser realizada aplicando-se um algoritmo bidimensional de extração de picos⁴ à matriz frequência-número de onda $S(\omega, k)$ para a extração dos máximos locais. Estes máximos locais correspondem aos valores numéricos das curvas de dispersão simuladas e, desta forma, é possível quantificar a concordância entre os valores estimados e aqueles fornecidos pela teoria analítica⁵. Da mesma forma que em DOBIE *et al.* [150], a medida da concordância utilizada foi o erro médio quadrático padronizado ($sMSE$) dado por:

$$sMSE(\hat{x}) = \frac{100}{N\sigma_x^2} \sum_{i=1}^N (x_i - \hat{x}_i)^2 \quad (4.2)$$

onde \hat{x} e x são os valores dos números de onda estimado e fornecido pela teoria analítica, respectivamente.

¹O nome deriva da palavra *ponga*, que em Tupi-Guarani significa soar.

²COOLEY e TUKEY [187]

³Que é o meio de propagação.

⁴MORHÁČ *et al.* [188]

⁵PAVLAKOVIC *et al.* [169]

4.3 Base de dados

A base de dados foi construída de forma a reproduzir as características de uma aplicação real de caracterização dos tamanhos de partículas no contexto de uma importante indústria de processos. Questões de confidencialidade impedem a revelação tanto da aplicação real quanto da indústria de processos envolvida.

A aplicação consiste na quantificação do teor de finos⁶ em amostras de material particulado e guarda semelhanças com diversas outras aplicações reais como, por exemplo, a descrita em NSUGBE *et al.* [122].

Os sinais de EA que compõem a base de dados foram simulados usando o Algoritmo 2 e as funções do pacote `pongaR`. Por ser uma base de dados simulada e, portanto, bem caracterizada e reproduzível, é possível quantificar com exatidão os percentuais em número de cada classe de tamanhos de partículas em cada sinal.

Algoritmo 2: Simulação de sinal de EA

- 1 Definir as características das partículas, do meio de propagação e do detector
 - 2 Definir os limites mínimo e máximo do diâmetro das partículas, da velocidade de impacto e da distância do sensor ao ponto de impacto
 - 3 Definir a taxa de impactos e a duração do sinal de EA
 - 4 Sortear os instantes dos impactos
 - 5 **para** cada instante de impacto **faça**
 - 6 Sortear os valores para o tamanho da partícula, a velocidade de impacto e a distância entre o sensor e o ponto de impacto
 - 7 Calcular e armazenar o sinal de EA correspondente a este instante de impacto
 - 8 **fim**
 - 9 Somar todos os sinais armazenados para obter o sinal de EA correspondente aos múltiplos impactos
-

4.4 Pré-processamentos

Uma vez obtidos, os sinais de EA são então pré-processados para a detecção e extração de características especialistas (Subseção 4.4.1) ou de características estatísticas (Subseção 4.4.2).

⁶Entende-se como finos a quantidade, em número, massa ou volume de material particulado que passa por um determinado tamanho de peneira.

4.4.1 Especialista

O pré-processamento especialista consiste na detecção dos eventos (*hits*) e extração de seus parâmetros de EA⁷ usando o método de detecção de eventos de EA baseado em limiar. Segundo UNNPORSSON [46][p. 3], existem muitos métodos que podem ser usados para detectar e determinar os eventos de EA, contudo um método comum usado em diversos sistemas comerciais baseados em parâmetros⁸ é comparar o sinal de EA com um certo valor de limiar especificado.

Este valor é normalmente definido do lado positivo do sinal, logo acima do ruído, e mantido fixo. Em alguns casos, o limiar é flutuante, isto é, é ajustado regularmente de modo que fique logo acima do ruído⁹. Um evento é detectado através da comparação do sinal de EA com o valor de limiar e se o sinal ultrapassar este valor, um evento é detectado. Após um evento de EA ter sido detectado, ele é determinado.

Três parâmetros são normalmente usados para a determinação de um evento de EA: o *Hit Definition Time (HDT)*, o *Hit Lockout Time (HLT)* e o *Peak Definition Time (PDT)*. O parâmetro *HDT* especifica o tempo máximo entre os cruzamentos do limiar, ou seja, se nenhum cruzamento ocorrer durante este tempo, então o evento é finalizado. Se o *HDT* é ajustado muito alto, então o detector pode considerar dois ou mais eventos como sendo um só. Se o *HDT* é ajustado muito baixo, o detector pode não capturar completamente o evento de EA e possivelmente considerar um evento como sendo vários.

O parâmetro *HLT* especifica o tempo que deve passar após um evento ter sido detectado até um novo evento pode ser detectado. Se o *HLT* é ajustado muito alto, então o detector pode não ser capaz de capturar o próximo evento e se for ajustado muito baixo, o detector pode capturar modos de onda mais atrasados como um evento.

O parâmetro *PDT* especifica o máximo tempo permitido, após um evento ter sido detectado, para determinar o valor máximo do sinal (Tabela 2.3). Se o *PDT* é ajustado muito alto, então medições incorretas do valor máximo do sinal são mais prováveis de ocorrer. É recomendado que o *PDT* seja ajustado o mais baixo quanto possível. Contudo, deve se ter cuidado para não ajustá-lo muito baixo, porque isso pode fazer com que o valor máximo do sinal real não seja identificado. Uma vez que determinado o evento, os seus parâmetros de EA podem ser extraídos. As etapas deste pré-processamento são mostradas no Algoritmo 3, o qual foi implementado na função `getFeatures` do pacote `pongAR`.

Os principais parâmetros do detector de eventos (*HDT*, *HLT* e *PDT*) foram

⁷Definidos nas Tabelas 2.3 e 2.4

⁸VALLEN [47], PAC [189]

⁹É importante observar que não foi adicionado ruído aos sinais de EA simulados. Sendo assim, o valor de limiar foi especificado a partir da parametrização padrão adotada na literatura (BEATTIE [26])

Algoritmo 3: Pré-processamento especialista

```
1 Definir os parâmetros do detector de eventos
2 Carregar os sinais de EA
3 para cada sinal de EA faça
4   | Detectar o evento
5   | para cada evento faça
6   |   | Calcular e armazenar os parâmetros de EA
7   | fim
8 fim
```

obtidos através de uma análise estatística das características dos sinais de EA simulados oriundos de impactos individuais de partículas. Neste caso, é importante ressaltar que sem contar com a possibilidade de simulação dos sinais de EA, seria praticamente impossível obtê-los, uma vez que a adoção inicial de valores recomendados usuais¹⁰ se mostrou bastante inadequada (Seção 5.3). Além disso, não foi encontrado na literatura nenhum método de ajuste destes parâmetros, com exceção de um comentário de BEATTIE [26] com relação ao assunto:

“In most AE tests, the exact values of these three times are not critical, but the values of the settings should be considered, especially if a high average repetition rate with short emissions is expected.”

Ou seja, no caso da caracterização de tamanhos de partículas sólidas usando EA, em que há uma elevada taxa de repetição média dos eventos e emissões de curta duração, o ajuste destes parâmetros deve ser considerado ao contrário do que ocorre na maioria dos testes de EA para fins de ensaios não-destrutivos.

Por fim, uma vez que o cálculo das características especialistas não depende da estatística da amostra de eventos considerada, este pré-processamento não necessita ser feito individualmente para cada conjunto de treinamento (ou teste) e, portanto, pode ser realizado *a priori* para todos os eventos detectados.

4.4.2 Estatístico

O pré-processamento estatístico consiste na extração de características das séries temporais de amplitude dos eventos detectados. Como estas séries temporais possuem dimensão e colinearidade elevadas, para superar a colinearidade e reduzir a dimensão foi empregada PCA¹¹ da mesma forma que em CHEN e CHEN [7], PAPP *et al.* [8], BASTARI *et al.* [14] e HANSULD *et al.* [15].

Uma vez que os eventos de EA detectados são dessincronizados e possuem janelas de durações variadas, foi necessário realizar uma sincronização prévia seguida de uma

¹⁰PAC [189]

¹¹PEARSON [67]

padronização do tamanho das janelas dos eventos detectados de forma a manter a dimensionalidade dos dados constante. O Algoritmo 4 descreve o pré-processamento estatístico.

Concluindo, uma vez que neste caso o cálculo das características estatísticas depende da estatística da amostra de eventos considerada, este pré-processamento necessita ser feito, conforme mostrado no Algoritmo 4, individualmente para cada conjunto de treinamento e, portanto, não pode ser realizado *a priori* e simultaneamente para todos os eventos detectados.

Algoritmo 4: Pré-processamento estatístico

- 1 Carregar os eventos detectados
- 2 **para** cada evento **faça**
- 3 Calcular as correlações com os demais eventos
- 4 Calcular e armazenar a mediana^a, o desvio absoluto mediano das correlações e o instante de tempo do valor máximo do sinal (Tabela 2.3)
- 5 **fim**
- 6 Ordenar os eventos por mediana, inverso do desvio absoluto das medianas e instante de tempo do valor máximo do sinal
- 7 Escolher o primeiro da lista como evento de referência
- 8 **para** cada evento diferente do evento de referência **faça**
- 9 Sincronizar^b o evento com o evento de referência usando correlação cruzada e atraso máximo igual à duração do evento de referência
- 10 **fim**
- 11 Padronizar o tamanho das janelas dos eventos detectados
- 12 Aplicar PCA com prévia remoção da média e limiar de energia de 99% no caso do conjunto de treinamento ou, no caso do conjunto de teste, projetar os dados nos componentes extraídos do conjunto de treinamento

^aA mediana foi utilizada por representar o valor esperado de forma mais robusta.

^bAlinhar temporalmente.

4.5 Figuras de mérito, sintonia, estimação e comparação de desempenho

A quantificação do desempenho das técnicas de classificação foi realizada usando a figura de mérito do índice *SP* (SIMAS FILHO *et al.* [190])¹² adaptado para problemas envolvendo mais de duas classes e definido como:

¹²A origem do nome vem do fato de que na definição deste índice está incluída uma soma e um produto, daí a sigla *SP*.

$$SP = \sqrt{\frac{\sum_{i=1}^{N_c} PD_i}{N_c}} \times \sqrt[2]{\prod_{i=1}^{N_c} PD_i} \quad (4.3)$$

onde $PD_i = TP_i/CP_i$ é a probabilidade de detecção da classe i , N_c é o número de classes, TP_i é o número de eventos da classe i corretamente classificados e CP_i é o número de eventos da classe i no conjunto de dados. Embora existam diversas outras figuras de mérito, a utilização do índice SP é justificada pelo fato de que a sua utilização em trabalhos anteriores (CIODARO *et al.* [191]) apresentou vantagens interessantes com relação a outras opções como, por exemplo, a acurácia.

Para avaliar a importância das variáveis de entrada foram utilizadas como figuras de mérito a relevância e a relevância agregada. Segundo SEIXAS e CALÔBA [192], a relevância de uma dada variável de entrada x é obtida substituindo o valor da mesma no conjunto de dados pelo seu valor médio, fornecendo este novo conjunto à técnica de classificação já treinada para previsão e determinando a diferença entre os índices SP do conjunto de dados original e deste novo conjunto, ou seja:

$$RV_x = SP_x - SP_{\bar{x}} \quad (4.4)$$

onde SP_x é o índice SP do conjunto de dados original e $SP_{\bar{x}}$ é o índice SP do novo conjunto.

Com base nos valores de relevância calculados, as variáveis de entrada podem ser ordenadas pela sua importância. Optou-se aqui por este método pelo fato de que o mesmo simplifica o procedimento clássico¹³ de remover uma a uma as variáveis de entrada e observar o efeito destas remoções no desempenho da técnica de classificação.

Já a relevância agregada, inspirada em ÉVORA *et al.* [194], é uma forma de consolidar, em um único valor, os valores de relevância de uma dada variável de entrada x obtidos em técnicas de classificação diferentes. O cálculo da relevância agregada consiste em, para uma dada técnica de classificação, ordenar as variáveis de entrada pela sua relevância em ordem crescente e atribuir a cada uma das variáveis de entrada uma pontuação correspondente a sua posição na lista de relevância ordenada em ordem decrescente.

Em outras palavras, considerando que o número de variáveis de entrada seja N_x , será atribuído N_x pontos à variável mais importante, $N_x - 1$ pontos à segunda variável mais importante e um ponto à variável menos importante, pois um seria a posição desta variável caso a relevância fosse ordenada em ordem decrescente. Uma vez atribuídas as pontuações em cada uma das técnicas de classificação, o valor da

¹³SUNG [193][p. 407]

relevância agregada de uma dada variável de entrada x é então obtido somando-se as pontuações alcançadas em cada uma das técnicas avaliadas.

Com relação à sintonia dos parâmetros ajustáveis foi utilizado o método de busca em grelha¹⁴ e para a estimação de desempenho foi utilizado o método da validação cruzada por k -fold¹⁵. Embora existam outros métodos para a realização destas tarefas, optou-se aqui por estes em função da simplicidade e do seu amplo emprego na literatura. Por fim, para a comparação dos desempenhos entre pares de técnicas de classificação foi utilizado o teste de postos com sinais de Wilcoxon¹⁶, o qual não faz suposições de comensurabilidade das medidas de desempenho e é relativamente robusto a valores espúrios.

4.6 Implementação das técnicas de IC

As tarefas de implementação, treinamento e sintonia dos parâmetros ajustáveis das técnicas de IC descritas na Seção 2.3 foram realizadas usando diversas funções do pacote `caret` desenvolvido por KUHN *et al.* [197]. Como o referido pacote não calcula os valores do índice SP , duas novas funções tiveram que ser desenvolvidas e incorporadas de forma a permitir a utilização do índice SP como figura de mérito. A função `plsda` deste mesmo pacote foi utilizada para implementar a técnica de classificação PLS (PLS-DA), sendo que parâmetro ajustável neste caso foi o número de estruturas latentes (`ncomp`).

A técnica de classificação C -SVC foi implementada usando a função `ksvm` do pacote `kernlab` (KARATZOGLOU *et al.* [198]). A referida técnica foi avaliada usando o esquema de votação "um contra um" e as funções de núcleo (`kernel`) do tipo linear (`vanilladot`) e RBF (`rbfdot`). Os parâmetros ajustáveis foram o parâmetro de regularização C (`C`) e o hiperparâmetro γ (`sigma`) da RBF.

A função `gbm` do pacote `gbm` (RIDGEWAY [199]) foi utilizada para implementar a técnica de classificação GBM. Os parâmetros ajustáveis foram o número de iterações de melhoramento (`n.trees`) e a profundidade máxima da árvore (`interaction.depth`). Os demais parâmetros, `shrinkage` e `n.minobsinnode`, foram mantidos nos valores de 0,1 e 10, respectivamente.

A técnica MLP, tanto no cenário de classificação como no de regressão, foi implementada através da função `nnet` do pacote `nnet` (VENABLES e RIPLEY [82]). A função de ativação logística, com $\lambda = 1$, foi utilizada para os neurônios da camada escondida em ambos os cenários. Para a camada de saída no cenário de classificação foi mantida a função logística, enquanto que para o cenário de regressão foi

¹⁴HSU *et al.* [195]

¹⁵HASTIE *et al.* [61][p. 241]

¹⁶HOLLANDER e WOLFE [196][p. 40], implementado através da função `wilcox.test` do pacote `stats` (R CORE TEAM [181])

utilizada a função de ativação linear também com $\lambda = 1$. O treinamento foi baseado no algoritmo Broyden-Fletcher-Goldfarb-Shanno (BFGS¹⁷) usando os critérios de parada *default*, o número máximo de pesos (**MaxNWts**) igual a 8000 e o número máximo de iterações (**maxit**) igual a 1000, sendo que os parâmetros ajustáveis foram o decaimento (**decay**) e o número de neurônios na camada escondida (**size**).

4.7 Abordagens desenvolvidas

As abordagens desenvolvidas diferem entre si na combinação das etapas de pré-processamento e classificação. As abordagens desenvolvidas baseadas em parâmetros (Seção 2.2.3) utilizam o pré-processamento especialista descrito na Subseção 4.4.1, enquanto aquelas baseadas em formas de onda (Seção 2.2.3) utilizam o pré-processamento estatístico descrito na Subseção 4.4.2.

Após a extração de características, classificadores baseados nas técnicas de IC (Seções 2.3 e 4.6) são treinados usando a figura de mérito e os métodos de sintonia e estimação de desempenho descritos na Seção 4.5. A Figura 4.1 mostra os diagramas de blocos das abordagens desenvolvidas, totalizando sete variantes das duas diferentes abordagens de análise de sinais de emissão acústica, ou seja, a abordagem baseada em parâmetros e a abordagem baseada em formas de onda.

É importante observar que de acordo com esta formulação do problema, ambas as abordagens desenvolvidas preveem para cada evento detectado a sua classe de tamanho de partícula. Neste caso, é possível obter a DTP (Seção 2.1.1) em base número, ou seja, o número np_i de partículas com tamanho correspondente à classe i para um dado sinal de EA através da agregação dos valores previstos por classe.

A DTP expressa em base número pode ser convertida em percentuais em massa através da seguinte relação¹⁸:

$$wppi = \frac{np_i(2b_i)^3}{\sum_{i=1}^{N_c} [np_i(2b_i)^3]} \times 100 \quad (4.5)$$

onde $2b_i$ é o diâmetro de partícula representativo da classe i .

A partir da DTP expressa como percentuais em massa é possível, por exemplo, calcular o teor de finos em amostras de material particulado simplesmente somando-se os valores correspondentes as classes cujos diâmetros representativos são inferiores ao diâmetro representativo do teor de finos. Desta forma, as abordagens desenvolvidas apresentam uma vantagem inovadora de não necessitarem de re-treinamento em caso de alteração do diâmetro representativo do teor de finos.

¹⁷FLETCHER [200]

¹⁸Obtida a partir das relações fundamentais entre massa e volume e entre o diâmetro e o volume da esfera.

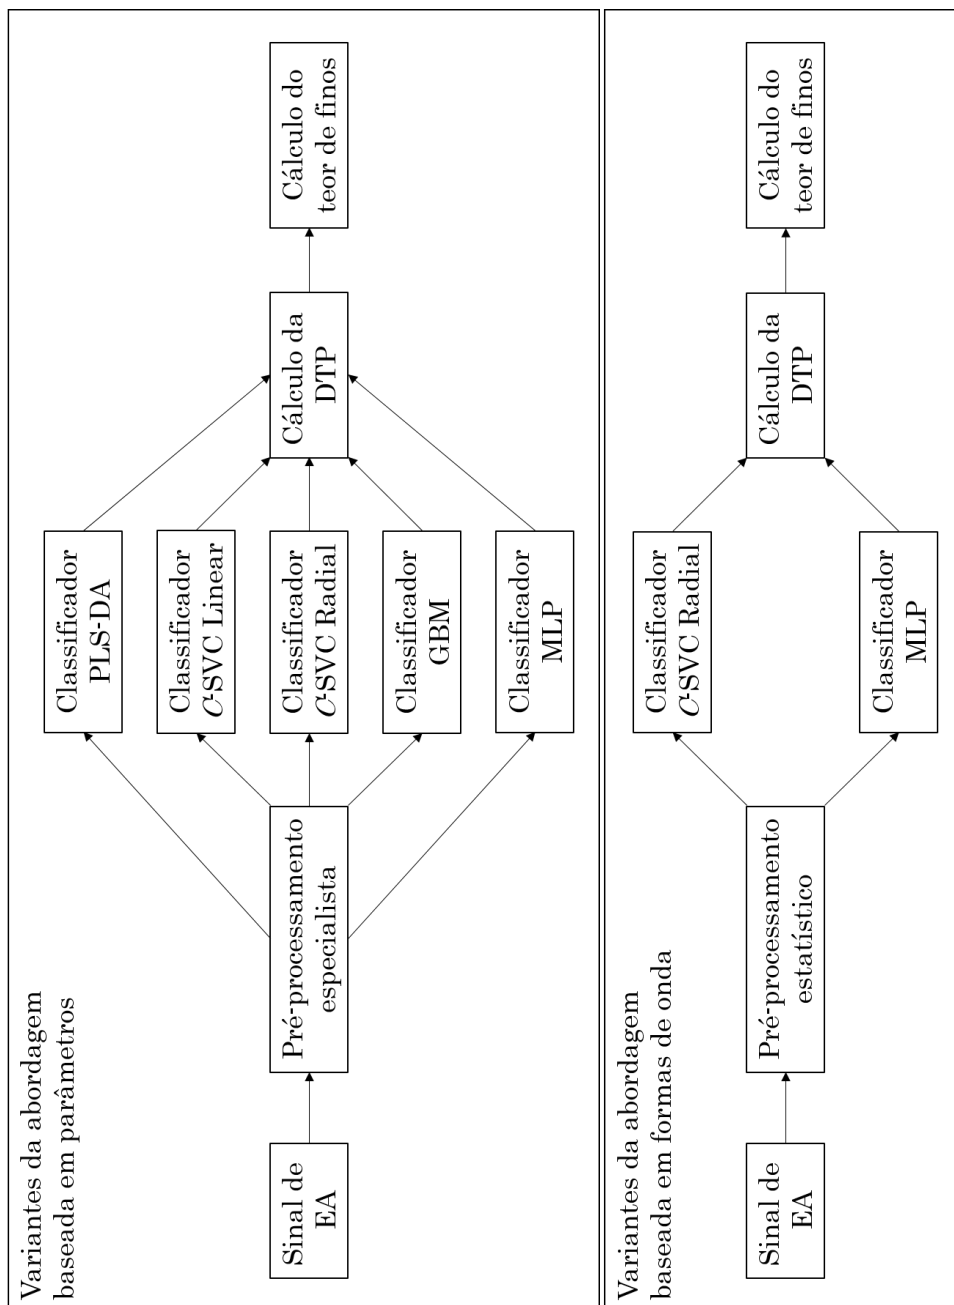


Figura 4.1: Diagramas de blocos das abordagens desenvolvidas.

4.8 Abordagem de referência

A abordagem de referência selecionada foi a descrita em BASTARI *et al.* [14]. A seleção desta entre as tantas outras apresentadas na Seção 2.4 foi motivada pelo seu elevado número de citações¹⁹ e também pelo fato de que a mesma está incorporada a um sistema industrial utilizado em usinas termoeletricas (COLLURA *et al.* [201]).

O Algoritmo 5 apresenta a extração de características usada por BASTARI *et al.* [14] e adaptada para a base de dados simulada.

Algoritmo 5: Extração de características da abordagem de referência

```
1 Carregar os sinais de EA
2 para cada sinal de EA faça
3     Dividir em janelas de 100.000 amostras
4     para cada janela faça
5         Normalizar para energia unitária
6         Decompor usando a transformada de pacote wavelet com uma função
           Coiflet de ordem 4 e 6 níveis de decomposição
7         Calcular e armazenar o vetor de energias dos sinais de sub-banda
           correspondentes aos nós terminais da árvore de pacote wavelet
           completa
8     fim
9     Calcular e armazenar a média dos vetores de energia correspondentes a
           25 janelas contíguas
10 fim
11 Aplicar PCA com prévia remoção da média, ajuste de escala unitária e limiar
           de energia de 98%
12 Armazenar a matriz de projeções com prévia remoção da média e ajuste de
           escala unitária
```

Após extrair as características de todas as aquisições simultaneamente, BASTARI *et al.* [14] treinaram um MLP com P entradas, uma camada escondida, H neurônios na camada escondida e três saídas. As entradas correspondem às características extraídas (projeções nos P componentes principais), enquanto as saídas correspondem aos percentuais em massa de partículas menores que 300, 150 e 75 μm . Neste caso, a diferença entre a abordagem original e a implementada é que esta última possui uma única saída que é o teor de finos²⁰.

Para o treinamento do MLP, BASTARI *et al.* [14] utilizaram uma modificação

¹⁹Ao todo são 22 citações contra 57 de LEACH *et al.* [5], entretanto o trabalho de BASTARI *et al.* [14] foi publicado em 2011 e o de LEACH *et al.* [5] em 1977.

²⁰O percentual em massa de partículas menores que 700 μm .

do método de retro-propagação baseada no algoritmo Levenberg-Marquardt (LM²¹) (HAGAN e MENHAJ [84]). Devido as características da função `nnet`, utilizada aqui para implementar a técnica MLP, o algoritmo LM teve que ser substituído pelo algoritmo BFGS. Como a abordagem é formulada como um problema de regressão, a figura de mérito utilizada por BASTARI *et al.* [14] foi a raiz do erro médio quadrático (*RMSE*) dada por:

$$RMSE(\hat{x}) = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2} \quad (4.6)$$

onde o circunflexo sobre a variável indica o valor estimado.

Embora a abordagem de BASTARI *et al.* [14] possua muitas citações e tenha sido incorporada a um produto comercial é importante ressaltar algumas de suas imperfeições. Ao realizar a extração de características de todas as aquisições simultaneamente antes do treinamento do MLP, BASTARI *et al.* [14] cometem um erro muito comum de introduzir informação do conjunto de teste nos conjuntos de treinamento e validação.

Além disso, os referidos autores adotam para a validação cruzada o método *hold-out*, o qual é normalmente contra-indicado neste caso, pois gera resultados de desempenho tendenciosos e que não levam em conta a flutuação estatística do conjunto de dados.

Apesar de terem sido identificados estas duas imperfeições, somente a última foi corrigida nesta implementação. O objetivo desta correção foi padronizar o método de estimação de desempenho e também permitir a realização de testes de comparação com as demais abordagens avaliadas da forma mais honesta possível.

Por não fazer parte do escopo deste trabalho e por se tratar de um processo complexo que necessita de uma seleção manual para cada problema (AN *et al.* [18]), nenhuma tentativa de seleção da função *wavelet* e do nível de decomposição da transformada de pacote *wavelet*²² foi realizada.

²¹LEVENBERG [85]

²²O leitor interessado pode obter detalhes sobre esta técnica de processamento de sinais em GAO e YAN [202].

Capítulo 5

Resultados e Discussão

Neste Capítulo são apresentados e discutidos os resultados obtidos. A Seção 5.1 foca nos resultados obtidos na validação do simulador proposto, enquanto Seção 5.2 mostra a base de dados. A Seção 5.3 apresenta os resultados da abordagem baseada em parâmetros introduzida no Tópico 2.2.3 e engloba os resultados da sintonia dos parâmetros ajustáveis, das análises de relevância das variáveis individual e agregada e de uma análise comparativa dos desempenhos dos modelos selecionados de cada técnica avaliada. A Seção 5.4 temos os resultados da abordagem baseada em formas de onda introduzida no Tópico 2.2.3 que são os resultados da sintonia dos parâmetros ajustáveis e uma análise comparativa dos desempenhos dos modelos selecionados de cada técnica avaliada. Na Seção 5.5 são apresentados os resultados de uma análise comparativa dos desempenhos dos modelos selecionados de cada uma das abordagens avaliadas, como também uma avaliação do desempenho final obtido. A Seção 5.6 encerra o Capítulo mostrando os resultados da sintonia da abordagem de referência e da avaliação do desempenho final obtido.

5.1 Validação do simulador

A seguir são apresentados e discutidos os resultados da validação do simulador implementado no pacote `pongaR` (Seção 4.1) utilizando a modelagem descrita no Capítulo 3. A validação foi realizada através de experimentos numéricos conforme o método descrito na Seção 4.2. A Figura 5.1 mostra uma imagem da matriz tempo-distância obtida usando a abordagem analítica proposta (Equação 3.44)¹.

¹Figuras semelhantes podem ser obtidas usando as abordagens analíticas simplificadas (Equações 3.45 e 3.46)




Figura 5.1: Imagem da matriz tempo-distância dos sinais de EA simulados através da abordagem analítica proposta (placa de titânio, $d = 5$ mm, fonte de excitação impulso pontual).

A Figura 5.2 mostra o gráfico de contorno produzido pela aplicação da transformada de Fourier rápida bidimensional na matriz tempo-distância², bem como os valores exatos da teoria analítica³.




Figura 5.2: Gráfico de contorno das curvas de dispersão simuladas usando a abordagem proposta e os valores exatos da teoria analítica (linhas pontilhadas azuis).

A Figura 5.3 mostra o gráfico das curvas de dispersão simuladas usando a abordagem proposta (Equação 3.44), a teoria de Kirchhoff-Love (Equação 3.45) e a teoria

²Ou naquelas obtidas usando as abordagens analíticas simplificadas (Equações 3.45 e 3.46)

³PAVLAKOVIC *et al.* [169]

de Mindlin (Equação 3.46), bem como os valores exatos da teoria analítica⁴.




Figura 5.3: Valores exatos da teoria analítica (linhas pontilhadas azuis) e máximos locais extraídos das curvas de dispersão simuladas usando a abordagem proposta (círculos pretos), a teoria de Kirchhoff-Love (quadrados vermelhos) e a teoria de Mindlin (triângulos verdes).

O desempenho quantitativo das três abordagens analíticas de modelagem da propagação mostradas na Figura 5.3 pode ser comparado através da Tabela 5.1 que mostra a medida de concordância $sMSE$ (Seção 4.2) para cada modo de onda de Lamb obtido nos experimentos numéricos.

Tabela 5.1: Medida de concordância $sMSE$ das abordagens analíticas para cada modo de onda de Lamb.

Modo de onda de Lamb	Abordagem analítica		
	Kirchhoff-Love	Mindlin	Proposta
S0	-	-	0,01543
A0	3904	0,5609	0,00723
S1	-	-	0,05616
A1	-	115,8	0,01402
S2	-	-	0,04197

A Figura 5.3 mostra claramente as limitações das abordagens analíticas simplificadas em modelar a propagação dos sinais de EA em estruturas do tipo placa. A teoria de Kirchhoff-Love é capaz de modelar apenas o modo de onda de Lamb anti-simétrico mais baixo (A0) e, mesmo para este modo, ela apresenta um desvio grosseiro a medida que a frequência aumenta.

⁴PAVLAKOVIC *et al.* [169]

Por outro lado, a teoria de Mindlin consegue modelar os modos A0 e A1 e realmente apresenta um desempenho melhor para o modo A0 do que a teoria de Kirchhoff-Love. No entanto, o desempenho da teoria de Mindlin para o modo A1 também se degrada muito com o aumento da frequência, de forma análoga ao que ocorre com a teoria de Kirchhoff-Love para o modo A0. Por último, nenhuma destas duas abordagens analíticas simplificadas é capaz de modelar os modos de onda de Lamb simétricos (S).

De acordo com DOBIE *et al.* [150], um *sMSE* menor que 5,0 indica uma concordância ótima, enquanto um valor menor que 1,0 indica uma concordância excelente. Ou seja, os resultados obtidos indicam que a abordagem analítica utilizada é, de fato, superior às abordagens analíticas simplificadas utilizadas em trabalhos anteriores (CARSON *et al.* [100, 105, 108, 109]).

5.2 Base de dados

A base de dados utilizada consiste de sinais de EA simulados numericamente e provenientes do impacto de partículas sólidas com uma placa. Os tamanhos das partículas sólidas encontram-se distribuídos em três classes de tamanhos adequadas à aplicação e nomeadas de X550, X650 e X750, as quais correspondem a partículas com tamanho entre 500 e 600 μm , entre 600 e 700 μm e entre 700 e 800 μm , respectivamente.

Em função das características da aplicação, cada sinal de EA simulado tem duração de 250 ms com uma frequência média de eventos de 2000 s^{-1} , sendo a distribuição da velocidade de impacto das partículas em todos os impactos uniforme e limitada entre 3 e 5 m s^{-1} . Na aplicação em questão, o teor de finos corresponde ao percentual em massa (%m) de partículas menores que 750 μm . Os cinco teores de finos adotados e suas correspondentes DTPs, expressas como percentuais em número (%n), encontram-se listados na Tabela 5.2. Ao todo foram simulados 120 sinais de EA igualmente distribuídos entre os cinco teores, ou seja, 24 sinais de EA para cada teor de finos.

Tabela 5.2: Teores de finos e DTPs em número.

Teor de finos [%m]	DTP [%n]		
	X550	X650	X750
11,6	10	10	80
25,8	20	20	60
34,3	25	25	50
43,9	30	30	40
67,6	40	40	20

As definições necessárias e utilizadas para a simulação dos sinais de EA que compõem a base de dados são listados na Tabela 5.3, enquanto a Figura 5.4 mostra um exemplo de sinal de EA simulado. A parametrização do detector de eventos é mostrada na Tabela 5.4. Através desta parametrização foi possível obter um detector de eventos de EA com uma probabilidade de detecção igual a 0,9993 e uma taxa de falsa descoberta igual a 0,0007.

Tabela 5.3: Definições utilizadas para simulação dos sinais de EA.

Definição	Valor	Unidade
Partículas		
Módulo de Young	74,6	[GPa]
Razão de Poisson	0,2285	[-]
Massa específica	2480	[kg m ⁻³]
Diâmetro		
Classe X550	min 500 / max 600	[µm]
Classe X650	min 600 / max 700	[µm]
Classe X750	min 700 / max 800	[µm]
Velocidade de impacto	min 3 / max 5	[m s ⁻¹]
Meio de propagação		
Módulo de Young	121,1	[GPa]
Razão de Poisson	0,3016	[-]
Massa específica	4460	[kg m ⁻³]
Comprimento	0,508	[m]
Largura	0,381	[m]
Espessura	0,005	[m]
Detector		
Taxa de amostragem	10	[MSPS]
Modelo do sensor	R15I-UC	[-]
Filtro passa-banda	min 50 / max 1000	[kHz]
Ganho do amplificador	80	[dB]
Distância do ponto de impacto	min 50 / max 254	[mm]
Taxa de impactos	2000	[s ⁻¹]
Duração do sinal de EA	250	[ms]

Tabela 5.4: Parametrização do detector de eventos.

Parâmetro	Definição	Valor	Unidade
G_{preamp}	Ganho do pré-amplificador	40	[dB]
$N_{pretrig}$	Número de amostras <i>pre-trigger</i>	0	[-]
U_{thr}	Limiar de detecção	10	[mV]
t_{max}	Duração máxima do evento	0,3	[ms]
N_{max}	Número máximo de eventos detectados	5000	[-]
HDT	<i>Hit Definition Time</i>	100	[μ s]
HLT	<i>Hit Lockout Time</i>	10	[μ s]
PDT	<i>Peak Definition Time</i>	50	[μ s]




Figura 5.4: Exemplo de sinal de EA simulado.

5.3 Abordagem baseada em parâmetros

A seguir são apresentados e discutidos os resultados da abordagem baseada em parâmetros introduzida na Subseção 2.2.3 e implementada segundo o método descrito na Seção 4.7. Ao todo cinco variantes foram avaliadas, as quais consistem da combinação do pré-processamento estatístico, descrito na Subseção 4.4.1, com cada uma das cinco técnicas de IC introduzidas na Seção 2.3 e implementadas conforme descrito na Seção 4.6.

A Tabela 5.5 fornece as faixas adotadas para especificação das grelhas na sintonia dos parâmetros ajustáveis, sendo fixado em 10 o número de *fold*s do método de validação cruzada.

Tabela 5.5: Especificação das grelhas (abordagem baseada em parâmetros).

Técnica	Parâmetro	Mínimo	Máximo	Incremento
PLS-DA	Número de estruturas latentes	1	19	+1
	<i>C</i> -SVC linear	Parâmetro <i>C</i>	10^{-3}	10
<i>C</i> -SVC radial	Parâmetro <i>C</i>	10^{-1}	10^2	$\times 10$
	Hiperparâmetro γ	0,02	0,14	+0,02
GBM	Iterações de melhoramento	1	9	+4
	Profundidade máxima	10	300	+10
MLP	Decaimento	10^{-5}	10^{-1}	$\times 10^2$
	Número de neurônios na camada escondida	4	24	+4

A Figura 5.5 mostra, para a técnica PLS-DA (Subseção 2.3.1 e Seção 4.6), a variação do índice *SP* (Secção 4.5) com o número de estruturas latentes durante o ajuste deste parâmetro. Assim como nas demais figuras, a barra de erro corresponde a mais ou menos um desvio-padrão. A inserção abaixo da curva mostra a variação em uma escala expandida do índice *SP*, pois excluiu as quatro primeiras estruturas latentes.

Analisando a inserção da Figura 5.5 podemos verificar que o menor número de estruturas latentes para manter o índice *SP* na região acima de 0,90 é seis. Entretanto, em função do critério adotado para seleção do melhor modelo, o número de estruturas latentes selecionado foi 17.

A relevância das variáveis⁵ para a técnica PLS-DA, calculada segundo o método descrito na Seção 4.5, é mostrada na Figura 5.6.

A Figura 5.6 mostra que os parâmetros de EA derivados (Tabela 2.4) no domínio da frequência foram nitidamente as variáveis mais relevantes neste caso, sendo que as maiores relevâncias foram das potências parciais 4 e 3. Dentre os parâmetros derivados de EA no domínio do tempo, os que figuraram como variáveis mais relevantes foram o valor quadrático médio e o valor médio do sinal e entre as menos relevantes temos o tempo de subida e a amplitude.

⁴

⁵As variáveis neste caso são todos os parâmetros derivados de EA definidos na Tabela 2.4. A relação entre os nomes e as abreviaturas utilizadas é fornecida na Tabela B.1.




Figura 5.5: Variação do índice SP com o número de estruturas latentes (técnica PLS-DA / pré-processamento especialista).




Figura 5.6: Relevância das variáveis (técnica PLS-DA / pré-processamento especialista).

A Figura 5.7 mostra, para a técnica C -SVC linear (Subseção 2.3.2 e Seção 4.6), a variação do índice SP com o parâmetro de regularização C durante o ajuste deste parâmetro.




Figura 5.7: Variação do índice SP com o parâmetro de regularização C (técnica C -SVC linear / pré-processamento especialista).

Analisando a Figura 5.7 podemos verificar que valores do parâmetro C acima de um levam o índice SP para valores na faixa de 0,96. Mais uma vez, em função do critério adotado para seleção do melhor modelo, o valor do parâmetro C selecionado neste caso foi 10.

A relevância das variáveis para a técnica C -SVC linear, calculada segundo o método descrito na Seção 4.5, é mostrada na Figura 5.8.




Figura 5.8: Relevância das variáveis (técnica C -SVC linear / pré-processamento especialista).

A Figura 5.8 mostra, de forma análoga ao caso da técnica PLS-DA, que os

parâmetros de EA derivados no domínio da frequência (Tabela 2.4) foram nitidamente as variáveis mais relevantes no caso da técnica C -SVC linear, sendo que as maiores relevâncias foram da frequência ponderada e das potências parciais 4, 3, 2 e 1. Dentre os parâmetros derivados de EA no domínio do tempo, os que figuraram como variáveis mais relevantes foram as frequências média, de reverberação e inicial e entre as menos relevantes temos a contagem e mais uma vez a amplitude.

A Figura 5.9 mostra, para a técnica C -SVC radial (Subseção 2.3.2 e Seção 4.6), a variação do índice SP com o parâmetro de regularização C e com o hiperparâmetro γ durante o ajuste destes parâmetros.

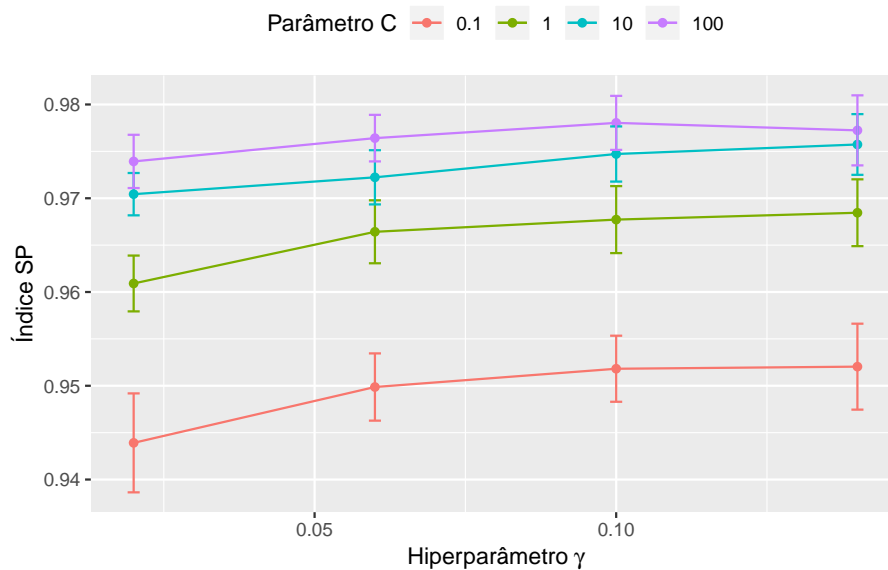


Figura 5.9: Variação do índice SP com o parâmetro de regularização C e com o hiperparâmetro γ (técnica C -SVC radial / pré-processamento especialista).

A Figura 5.9 mostra que, de uma forma geral, o aumento da regularização leva a um melhor desempenho, porém a partir de uma determinada faixa, os incrementos de desempenho vão se reduzindo até ficarem praticamente nulos. Embora o desempenho seja virtualmente idêntico para valores do parâmetro C na faixa entre 10 e 100, em função do critério adotado para seleção do melhor modelo, o valor do parâmetro C selecionado neste caso foi 100. A variação do desempenho com o hiperparâmetro γ dentro das especificações da grelha e para valores constantes do parâmetro C foi bem menor. Segundo o critério adotado para seleção do melhor modelo, o valor do hiperparâmetro γ selecionado neste caso foi 0,10. A combinação destes dois valores para estes parâmetros ajustáveis resultou em um modelo com o índice SP na faixa de 0,97 e 0,98.

A relevância das variáveis para a técnica C -SVC radial, calculada segundo o método descrito na Seção 4.5, é mostrada na Figura 5.10.




Figura 5.10: Relevância das variáveis (técnica *C-SVC* radial / pré-processamento especialista).

A Figura 5.10 mostra, de forma análoga aos casos das técnicas PLS-DA e *C-SVC* linear, que os parâmetros de EA derivados no domínio da frequência foram nitidamente as variáveis mais relevantes também no caso da técnica *C-SVC* radial, sendo que as maiores relevâncias foram das potências parciais 4, 3, 1 e 2, da frequência ponderada e da frequência centróide. Dentre os parâmetros de EA derivados no domínio do tempo, a energia absoluta foi a variável mais relevante e entre as menos relevantes temos o tempo de subida e a contagem, sendo a amplitude neste caso uma variável confundidora (relevância negativa). Por fim, um comportamento anômalo associado as maiores barras de erro das potências parciais 1 e 2 e da frequência ponderada também é observado. Entretanto, a análise deste comportamento não foi priorizada devido ao grande número de resultados a serem analisados.

A Figura 5.11 mostra, para a técnica GBM (Subseção 2.3.3 e Seção 4.6), a variação do índice *SP* com o número de iterações de melhoramento e com a profundidade máxima durante o ajuste destes parâmetros. A inserção abaixo das curvas mostra a variação em uma escala expandida do índice *SP*, pois excluiu as 20 primeiras iterações de melhoramento, bem como a curva correspondente aos valores de menor profundidade máxima.

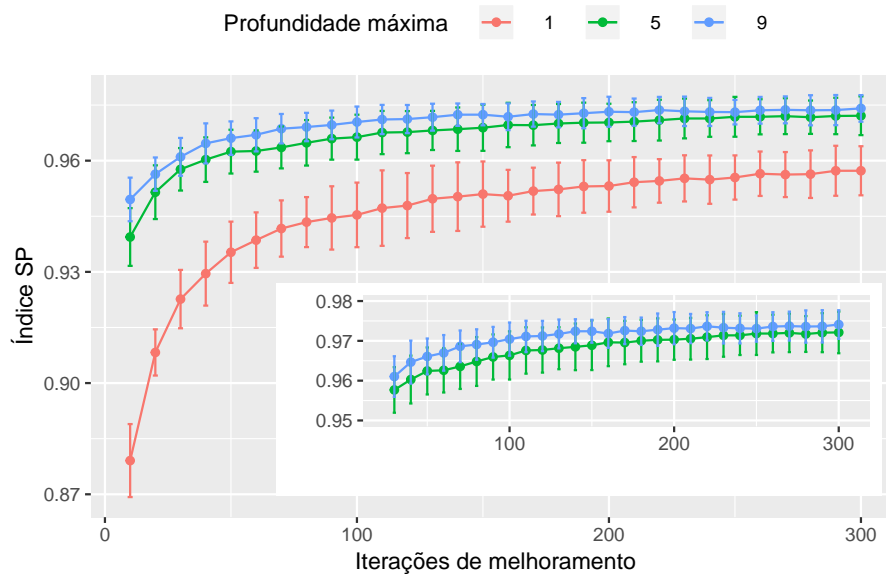


Figura 5.11: Variação do índice SP com o número de iterações de melhoramento e com a profundidade máxima (técnica GBM / pré-processamento especialista).

O parâmetro profundidade máxima desempenha um papel regularizante na técnica GBM, assim como o parâmetro C nas técnicas C -SVC linear e radial. Analogamente à técnica C -SVC radial, a Figura 5.11 mostra que, de uma forma geral, o aumento da regularização leva a um melhor desempenho, porém a partir de uma determinada faixa de valores, os ganhos de desempenho vão se reduzido até não serem mais significativos. Embora o ganho de desempenho seja praticamente o mesmo para valores de profundidade máxima na faixa entre 5 e 9, em função do critério adotado para seleção do melhor modelo, o valor selecionado para a profundidade máxima neste caso foi 9. Já em relação ao número de iterações de melhoramento, analisando a inserção da Figura 5.11 podemos verificar que o menor número de iterações de melhoramento para manter o índice SP na região de 0,97 é 30. Entretanto, em função do critério adotado para seleção do melhor modelo, o número de iterações de melhoramento selecionado foi 300. O ajuste dos parâmetros nestes valores leva a um modelo com o índice SP na mesma faixa de desempenho do melhor modelo da técnica C -SVC radial, ou seja, na faixa de 0,97 e 0,98.

A relevância das variáveis para a técnica GBM, calculada segundo o método descrito na Seção 4.5, é mostrada na Figura 5.12.




Figura 5.12: Relevância das variáveis (técnica GBM / pré-processamento especialista).

A Figura 5.12 mostra, mais uma vez, o comportamento recorrente da relevância dos parâmetros de EA derivados no domínio da frequência. Entretanto, cabe ressaltar aqui dois aspectos importantes neste caso. Primeiro, que cinco dos seis parâmetros de EA derivados no domínio da frequência tem máxima e igual relevância. Segundo, que os parâmetros de EA derivados no domínio do tempo possuem relevâncias significativamente menores, sendo que alguns, como a contagem e a amplitude, figuram como variáveis confundidoras (relevância negativa).

A Figura 5.13 mostra, para a técnica MLP (Subseção 2.3.4 e Seção 4.6), a variação do índice SP com o número de neurônios na camada escondida e com o decaimento durante o ajuste destes parâmetros.

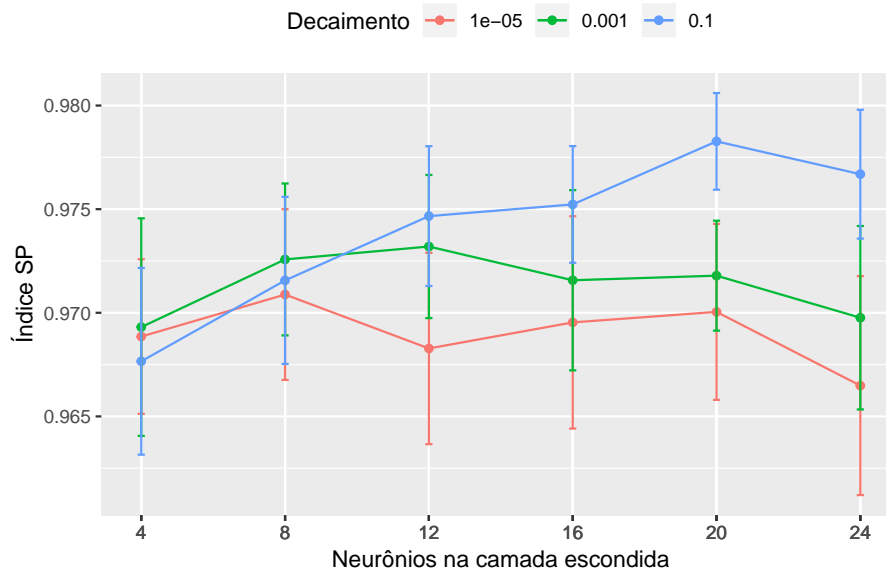


Figura 5.13: Variação do índice SP com o número de neurônios na camada escondida e com o decaimento (técnica MLP / pré-processamento especialista).

Na implementação da técnica MLP aqui utilizada (Seção 4.6) e conforme descrito na Seção 2.3.4, o parâmetro decaimento controla o impacto na função objetivo do termo de regularização, o qual visa reduzir o sobre-ajuste. A Figura 5.13 mostra que, no caso em questão, a seleção de valores inferiores a 0,1 para este parâmetro é incapaz de prevenir o sobre-ajuste na medida em que se aumenta a complexidade do MLP. Também pode-se observar, no caso de uma regularização adequada, que 20 neurônios na camada escondida fornecem o melhor desempenho, com um índice SP na faixa de 0,98.

A relevância das variáveis para a técnica MLP, calculada segundo o método descrito na Seção 4.5, é mostrada na Figura 5.14.




Figura 5.14: Relevância das variáveis (técnica MLP / pré-processamento especialista).

De uma forma geral, a relevância das variáveis da técnica MLP é semelhante a da técnica *C-SVC* radial, sobretudo com relação aos parâmetros derivados de EA no domínio da frequência. Já com relação aos parâmetros derivados de EA no domínio do tempo, as variáveis mais relevantes neste caso são o ângulo de descida e a energia absoluta, enquanto as de menor relevância são novamente a contagem e a amplitude. Finalmente, o mesmo comportamento anômalo observado na relevância das variáveis da técnica *C-SVC* radial, porém associado apenas à variável potência parcial 1, também é observado neste caso. Da mesma forma que no caso anterior, uma análise mais aprofundada deste comportamento não foi possível.

A relevância agregada das variáveis para todas as técnicas, calculada segundo o método descrito na Seção 4.5, é mostrada na Figura 5.15.




Figura 5.15: Relevância agregada das variáveis (todas as técnicas / pré-processamento especialista).

Como uma decorrência natural dos resultados apresentados anteriormente, o conjunto de variáveis mais relevantes considerando todas as técnicas é formado por praticamente todos os parâmetros derivados de EA no domínio da frequência. A exceção explicável é para a frequência de pico, uma vez que o sensor de EA utilizado nas simulações é o mais comum e do tipo ressonante. Conforme mostra a Figura A.3, uma vez que o sensor é ressonante, o espectro de potência do sinal de EA possui um pico na região de ressonância do sensor, que neste caso é em torno de 150 kHz (Figura 3.6), o que faz com que a potência de pico tenha um baixo poder discriminante e relevância. De uma forma agregada, as duas variáveis mais relevantes são a potência parcial 4 e 3, as quais correspondem as regiões de alta frequência do espectro de potência do sinal de EA. Este resultado, conforme apresentado na Seção 2.4, encontra-se em concordância com os obtidos por MATERO *et al.* [12], HANSULD *et al.* [15], HIRAJIMA e TSUNEKAWA [96], NORDON *et al.* [99], JIANG *et al.* [103], CARSON *et al.* [105]. Por outro lado, também observa-se que, embora com menor relevância, vários parâmetros derivados de EA no domínio do tempo aparecem praticamente em um bloco logo atrás do conjunto de maior relevância. Por último, como variáveis menos relevantes de forma agregada, figuram a duração, o tempo de subida, a contagem e a amplitude. Conforme a visão geral fornecida na Seção 2.4, este comportamento contradiz de certa forma os resultados obtidos por HU *et al.* [16].

A Tabela 5.6 resume os valores de sintonia dos parâmetros ajustáveis para os modelos selecionados de todas as técnicas avaliadas.

Tabela 5.6: Valores de sintonia dos parâmetros ajustáveis (modelos selecionados / abordagem baseada em parâmetros).

Técnica	Parâmetro	Valor
PLS-DA	Número de estruturas latentes	17
C -SVC linear	Parâmetro C	10^1
C -SVC radial	Parâmetro C	10^2
	Hiperparâmetro γ	0,10
GBM	Iterações de melhoramento	9
	Profundidade máxima	300
MLP	Decaimento	10^{-1}
	Número de neurônios na camada escondida	20

O desempenho dos modelos selecionados de cada técnica de classificação avaliado nos conjuntos de teste da validação cruzada é resumido na Figura 5.16.




Figura 5.16: Desempenho dos modelos selecionados (todas as técnicas / pré-processamento especialista).

A Figura 5.16 revela claramente dois agrupamentos. Um formado pela técnica PLS-DA que apresentou o menor desempenho na faixa de 0,90 e 0,92 de índice SP e o outro formado pelas demais técnicas com desempenhos de índice SP superiores a 0,95. Entretanto, dentro do grupo de melhor desempenho podemos ver que as técnicas MLP e C -SVC radial apresentaram os melhores desempenhos, seguidas das técnicas GBM e C -SVC linear. Com o objetivo de facilitar a comparação, a Figura 5.17 mostra as diferenças de desempenho dos modelos selecionados para cada par de técnicas de classificação avaliadas nos conjuntos de teste da validação cruzada.




Figura 5.17: Diferenças de desempenho entre os modelos selecionados (todas as técnicas / pré-processamento especialista).

Analisando a Figura 5.17 verificamos que as técnicas MLP e *C-SVC* radial apresentam desempenhos virtualmente idênticos e superiores ao da técnica *C-SVC* linear. Entretanto, em função dos intervalos de confiança de 95%, o mesmo não pode ser afirmado com relação à técnica GBM.

Sendo assim, um teste de postos com sinais de Wilcoxon (Seção 4.5) foi realizado para afastar ou não a hipótese de superioridade das técnicas MLP e *C-SVC* radial sobre a técnica GBM. O resultado do teste forneceu um valor p de 7×10^{-3} para a hipótese nula de que o desempenho da técnica GBM é igual ao da técnica MLP ou da técnica *C-SVC* radial em ambos os casos.

Desta forma, podemos afirmar com um nível de confiança de 95% que as duas técnicas que apresentaram o melhor desempenho para a abordagem baseada em parâmetros foram a técnica MLP e a técnica *C-SVC* radial.

A Tabela 5.7 mostra as estatísticas da distribuição do índice *SP* nos conjuntos de teste da validação cruzada para os modelos selecionados de cada técnica de classificação. Para facilitar a interpretação, os melhores valores de cada estatística foram sublinhados.

Apesar de apresentarem desempenhos virtualmente idênticos, analisando a distribuição do índice *SP* nos conjuntos de teste da validação cruzada para estas duas técnicas mostrada na Figura 5.18, verificamos que a distribuição dos desempenhos da técnica MLP é mais uniforme. Este critério foi utilizado para definir a combinação técnica MLP e pré-processamento especialista como a abordagem baseada em parâmetros que apresentou o melhor desempenho.

Tabela 5.7: Estatísticas da distribuição do índice SP (todas as técnicas / pré-processamento especialista).

Técnica	Estatísticas					
	Mín.	1º Qu.	Mediana	Média	3º Qu.	Máx.
MLP	0,975	0,976	0,978	0,978	0,980	0,981
C-SVC Radial	0,973	0,977	0,978	0,978	0,979	0,983
GBM	0,968	0,972	0,975	0,974	0,976	0,979
C-SVC Linear	0,955	0,958	0,964	0,963	0,967	0,971
PLS-DA	0,899	0,905	0,911	0,911	0,917	0,921




Figura 5.18: Distribuição do índice SP (técnicas selecionadas / pré-processamento especialista).

Com o objetivo de verificar o quanto de informação é agregada pela incorporação dos parâmetros derivados de EA do domínio da frequência ao conjunto de parâmetros derivados de EA do domínio do tempo, os desempenhos do melhor modelo da técnica MLP usando diferentes conjuntos de parâmetros de EA são mostrados na Figura 5.19. No topo temos o desempenho usando todos os parâmetros derivados de EA e abaixo o desempenho usando somente parâmetros derivados de EA do domínio do tempo.




Figura 5.19: Desempenhos de diferentes conjuntos de parâmetros de EA (técnica MLP / pré-processamento especialista).

A Figura 5.19 mostra de forma nítida que de fato há um ganho significativo de desempenho pela incorporação dos parâmetros derivados de EA do domínio da frequência ao conjunto de parâmetros derivados de EA do domínio do tempo, embora a informação contida nestes não seja de forma alguma desprezível, como poderia se concluir preliminarmente apenas avaliando os gráficos de relevância e relevância agregada das variáveis apresentados anteriormente.

5.4 Abordagem baseada em formas de onda

Os resultados da abordagem baseada em formas de onda introduzida na Subseção 2.2.3 e implementada segundo o método descrito na Seção 4.7 são apresentados a seguir. Em função dos resultados obtidos pela abordagem baseada em parâmetros, que mostraram a superioridade de desempenho das técnicas MLP e *C-SVC* radial, apenas duas variantes foram avaliadas neste caso. As variantes consistem da combinação destas duas técnicas de IC com o pré-processamento estatístico (Subseção 4.4.2). A Tabela 5.8 fornece as faixas adotadas para especificação das grelhas na sintonia dos parâmetros ajustáveis, sendo fixado em 10 o número de *folds* do método de validação cruzada.

A Figura 5.20 mostra o comportamento típico do erro de reconstrução e da energia com os componentes principais dos conjuntos de treinamento da validação cruzada.

Tabela 5.8: Especificação das grelhas (abordagem baseada em formas de onda).

Técnica	Parâmetro	Mínimo	Máximo	Incremento
<i>C</i> -SVC radial	Parâmetro <i>C</i>	10^{-1}	10^2	$\times 10$
	Hiperparâmetro γ	10^{-3}	10^{-1}	$\times 10$
MLP	Decaimento	10^{-5}	10^{-1}	$\times 10^2$
	Número de neurônios na camada escondida	8	24	$\times 4$

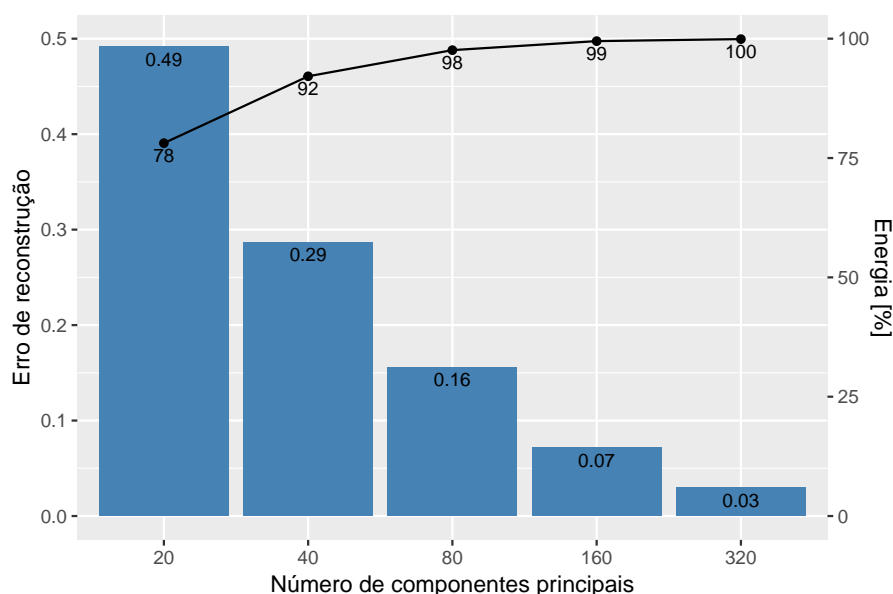


Figura 5.20: Comportamento típico do erro de reconstrução e da energia com os componentes principais (pré-processamento estatístico).

Conforme podemos observar na Figura 5.20, fixando-se o limiar de energia em 99% obtém-se uma redução de dimensionalidade de 2.224, que é o tamanho das janelas dos sinais de EA detectados e sincronizados, para cerca de 160, ou seja, uma compactação de aproximadamente 93%. Este resultado corrobora para a afirmação de que, embora as formas de onda dos eventos de EA apresentem elevada dimensão, as variáveis brutas⁶ possuem elevada colinearidade, a qual deve ser superada através do emprego de métodos de redução de dimensionalidade conforme mencionado no Tópico 2.2.3.

A Figura 5.21 mostra, para a técnica *C*-SVC radial, a variação do índice *SP* com o parâmetro de regularização *C* e com o hiperparâmetro γ durante o ajuste destes parâmetros. A inserção abaixo das curvas mostra a variação em uma escala expandida do índice *SP*, pois excluiu os menores valores do parâmetro de regularização *C*, bem como o maior valor do hiperparâmetro γ .

⁶No caso, as amplitudes de cada amostra de tempo.




Figura 5.21: Variação do índice SP com o parâmetro de regularização C e com o hiperparâmetro γ (técnica C -SVC radial / pré-processamento estatístico).

Analisando a Figura 5.21, verificamos que a medida em que se diminui a largura das funções RBF, dado que o hiperparâmetro γ representa o inverso deste valor, observa-se uma redução do desempenho nos conjuntos de teste, a qual é mais pronunciada quando há menos regularização, como é o caso da curva que corresponde ao valor do parâmetro C igual a 0,1. O lado esquerdo da Figura 5.21 mostra claramente a redução dos ganhos de desempenho, pela redução do sobre-ajuste, na medida em que se aumenta o parâmetro C em três ordens de grandeza. A inserção mostra claramente que a sintonia do parâmetro C em 100 e do hiperparâmetro γ em 0,001 fornece o modelo de maior desempenho da técnica C -SVC radial neste caso.

Já em relação à segunda variante estudada da abordagem baseada em formas de onda, a Figura 5.22 mostra a variação do índice SP com o número de neurônios na camada escondida e com o decaimento durante o ajuste destes parâmetros. A inserção abaixo das curvas mostra a variação em uma escala expandida do índice SP , pois excluiu os dois valores de menor decaimento.




Figura 5.22: Variação do índice SP com o número de neurônios na camada escondida e com o decaimento (técnica MLP / pré-processamento estatístico).

A inserção da Figura 5.22 mostra que o modelo da técnica MLP que obteve o maior desempenho neste caso é aquele ajustado com um decaimento de 0,1 e 24 neurônios na camada escondida (índice SP na faixa de 0,93). O efeito de uma regularização inadequada pode ser observado nas elevadas barras de erro das curvas com menores valores de decaimento, sobretudo no caso específico da curva correspondente ao valor de decaimento de 0,001 quando o MLP possui 20 neurônios na camada escondida. Este resultado, somado aos outros obtidos anteriormente, corrobora para reafirmar a grande importância da sintonia adequada da regularização das diversas técnicas de IC.

A variação do índice SP nos conjuntos de teste da validação cruzada para os melhores modelos de cada técnica de classificação avaliada é mostrada na Figura 5.23, onde cada linha colorida representa um conjunto de teste da validação cruzada.




Figura 5.23: Variação do índice SP (técnicas MLP e C -SVC radial / pré-processamento estatístico).

A Figura 5.23 mostra o comportamento distinto e bastante variado do desempenho dos conjuntos de teste para cada uma das duas técnicas, os quais apresentam várias inversões de desempenho. Além disso, também é possível observar que, no caso das especificações de grelha adotadas (Tabela 5.8), o modelo selecionado da técnica C -SVC radial apresentou um desempenho superior aquele da técnica MLP. É importante mencionar, que este resultado não pode ser encarado de forma absoluta, uma vez que a inserção da Figura 5.22 indica que ainda haveria espaço para ganhos de desempenho da técnica MLP, caso a especificação máxima para o número de neurônios na camada escondida fosse aumentada. Entretanto, dada a forma suave observada como se dá este aumento de desempenho, optou-se aqui por não se investigar esta hipótese de forma mais objetiva.

Os valores de sintonia dos parâmetros ajustáveis para os modelos selecionados das duas técnicas avaliadas são mostrados na Tabela 5.9.

Tabela 5.9: Valores de sintonia dos parâmetros ajustáveis (modelos selecionados / abordagem baseada em formas de onda).

Técnica	Parâmetro	Valor
C -SVC radial	Parâmetro C	10^2
	Hiperparâmetro γ	10^{-3}
MLP	Decaimento	10^{-1}
	Número de neurônios na camada escondida	24

O desempenho dos melhores modelos de cada técnica de classificação avaliado nos conjuntos de teste da validação cruzada é resumido na Figura 5.24.




Figura 5.24: Desempenho dos modelos selecionados (técnicas MLP e *C*-SVC radial / pré-processamento estatístico).

A Figura 5.24 comprova a hipótese de que o modelo selecionado da técnica *C*-SVC radial apresenta, neste caso específico, um desempenho superior aquele da técnica MLP e também afasta a hipótese de que os mesmos não sejam estatisticamente distintos. Esta afirmação encontra suporte na Figura 5.25 que apresenta a distribuição do índice *SP* nos conjuntos de teste da validação cruzada para os modelos selecionados de ambas as técnicas.




Figura 5.25: Distribuição do índice SP (técnicas MLP e C -SVC radial / pré-processamento estatístico).

5.5 Abordagem proposta

Os desempenhos das variantes selecionadas das duas abordagens estudadas são mostrados na Figura 5.26. No topo temos o desempenho da variante selecionada referente à abordagem baseada em parâmetros e abaixo o daquela referente à abordagem baseada em formas de onda.




Figura 5.26: Desempenhos das variantes selecionadas (abordagens estudadas).

Analisando a Figura 5.26 verificamos que os resultados obtidos até aqui indicam

que a abordagem baseada em parâmetros apresenta um desempenho superior ao da abordagem baseada em formas de onda. Entretanto, esta afirmação não pode também ser encarada de forma absoluta e incontestável, uma vez que diversas limitações e dificuldades ao longo do desenvolvimento deste estudo impediram que a abordagem baseada em formas de onda fosse melhor trabalhada, como por exemplo no tocante ao método de redução de dimensionalidade. Por outro lado, este resultado reforça a hipótese levantada na Seção 1.1 de que abordagens híbridas que combinam o conhecimento especialista de EA com técnicas de IC são promissoras no contexto da caracterização de tamanhos de partículas sólidas.

Desta forma, a abordagem aqui proposta é aquela que utiliza o pré-processamento especialista para extração de características e a técnica MLP para classificação, dado que esta foi a abordagem que apresentou o melhor desempenho dentre todas as estudadas conforme mostra a Figura 5.26.

A Figura 5.27 mostra o desempenho da abordagem proposta na previsão do teor de finos a partir dos sinais de EA, conforme o método descrito na Seção 4.7, e sem re-treinamento, uma vez que o modelo da abordagem proposta é de classificação e o problema neste caso é de regressão. Para facilitar a interpretação, a Tabela 5.10 resume as principais estatísticas das distribuições dos desvios.




Figura 5.27: Desempenho na previsão de finos (abordagem proposta).

Tabela 5.10: Estatísticas das distribuições dos desvios (abordagem proposta).

Teor de finos [%m]	Estatísticas [%m]					
	Mín.	Média	Mediana	Máx.	Desvio padrão	Desvio méd. abs.
11,6	-1,96	-0.93	-0.83	-0.16	0.44	0.42
25,8	-1,65	-0.53	-0.57	0.19	0.42	0.37
34,3	-1,55	-0.38	-0.35	0.38	0.49	0.67
43,9	-1,96	-0.29	-0.46	0.59	0.61	0.82
67,6	-1,07	0.16	0.24	1.18	0.48	0.42

Os resultados apresentados na Tabela 5.10 indicam que a abordagem proposta apresenta, em toda a faixa de teor de finos avaliada, um desvio médio absoluto inferior a 1%*m*. Este resultado encontra-se em linha com aqueles recentemente obtidos por NSUGBE *et al.* [122] (Seção 2.4), embora uma comparação absoluta não possa ser realizada dado que as aplicações e os métodos utilizados são diferentes, mas, principalmente, pelo fato de que os dados utilizados em NSUGBE *et al.* [122] não são facilmente reproduzíveis.

5.6 Abordagem de referência

A seguir são apresentados os resultados da abordagem de referência implementada segundo o método descrito na Seção 4.8. A Tabela 5.11 fornece as faixas adotadas para especificação da grelha dos parâmetros ajustáveis, sendo fixado em 10 o número de *folds* do método de validação cruzada.

Técnica	Parâmetro	Mínimo	Máximo	Incremento
MLP	Decaimento	10^{-1}	10	$\times 10$
	Número de neurônios na camada escondida	2	32	$\times 2$

Tabela 5.11: Especificação da grelha (abordagem de referência).

Uma vez que a abordagem de referência é formulada como regressão, a figura de mérito de desempenho para o ajuste dos parâmetros da técnica MLP não é mais o índice *SP* (Equação 4.4) e sim o *RMSE* (Equação 4.6). A Figura 5.28 mostra a variação desta figura de mérito com o número de neurônios na camada escondida e com o decaimento durante o ajuste destes parâmetros.




Figura 5.28: Variação do $RMSE$ com o número de neurônios na camada escondida e com o decaimento (abordagem de referência).

Segundo o critério de seleção do modelo com o melhor desempenho, o modelo selecionado neste caso é o MLP com 16 neurônios na camada escondida e decaimento igual a 1. O desempenho deste modelo na previsão do teor de finos, avaliado nos conjuntos de teste da validação cruzada, é mostrado na Figura 5.29. Mais uma vez, para facilitar a interpretação, a Tabela 5.12 resume as principais estatísticas das distribuições dos desvios.




Figura 5.29: Desempenho na previsão do teor de finos (abordagem de referência).

A Tabela 5.12 mostra as estatísticas das distribuições dos desvios.

Tabela 5.12: Estatísticas das distribuições dos desvios (abordagem de referência).

Teor de finos [%m]	Estatísticas [%m]					
	Mín.	Média	Mediana	Máx.	Desvio padrão	Desvio méd. abs.
11,6	-7,19	-1,13	-1,28	4,03	3,34	3,57
25,8	-10,30	0,67	0,19	10,92	4,92	4,51
34,3	-10,58	-0,12	-0,03	10,71	5,46	5,34
43,9	-11,56	0,06	0,12	13,85	5,99	4,87
67,6	-1,06	3,02	2,51	10,81	2,82	2,31

Os resultados apresentados na Tabela 5.12 indicam que a abordagem de referência apresenta, em toda a faixa de teor de finos avaliada, um desvio médio absoluto inferior a 6%_m. Este resultado também encontra-se em linha com aqueles recentemente obtidos por NSUGBE *et al.* [122] (Seção 2.4), embora seja muito inferior aquele obtido originalmente por BASTARI *et al.* [14] que chegaram a obter desvios médios absolutos da ordem de 0,04 a 0,73%_m dependendo da classe de tamanhos de partículas. Novamente, uma comparação justa também não pode ser realizada pelo fato de que os dados utilizados em BASTARI *et al.* [14] são ainda mais difíceis de serem reproduzidos e também por que, por estar fora do escopo do presente trabalho, nenhum esforço adicional foi realizado para o ajuste do método de transformada de pacotes *wavelet*.

Capítulo 6

Conclusões

A adequada caracterização de tamanhos de partículas sólidas resulta em ganhos significativos no controle dos processos e na qualidade dos produtos. A utilização da EA para esta tarefa oferece uma série de vantagens interessantes como: não-invasividade, baixo custo e resposta rápida. Entretanto, apesar de apresentar um conjunto bastante interessante de características e do esforço de diversos pesquisadores ao longo de quatro décadas, esta abordagem, que também tem incorporado a utilização de técnicas de IC, ainda é considerada imatura.

Neste contexto, o presente estudo realizou uma investigação procurando atacar alguns desafios e lacunas que contribuem para este quadro atual e que foram revelados através de uma revisão dos principais trabalhos publicados na área como, por exemplo:

- a ausência de dados bem caracterizados e reproduzíveis para o desenvolvimento e validação de diferentes combinações de abordagens de EA e técnicas de IC;
- a indisponibilidade de ferramentas de simulação de fácil uso, acesso e que permitam o estudo da influência dos principais elementos da cadeia de medição na geração dos sinais de EA;
- a reconhecida dificuldade de interpretação e análise dos sinais de EA devido, principalmente, a sua elevada dimensionalidade, e;
- a não incorporação do conhecimento especialista de EA associado a outros contextos como, por exemplo, o dos ensaios não-destrutivos.

Especificamente, em uma primeira etapa, foi desenvolvida uma modelagem bastante geral para simular a cadeia de medição de EA, que é relativamente simples e adequada ao contexto.

Dos resultados obtidos nesta primeira etapa, pode-se concluir que:

- a abordagem analítica introduzida para a modelagem da propagação e baseada na teoria das ondas de Lamb (LAMB [126]) é adequada ao contexto;
- a modelagem da propagação utilizada por CARSON *et al.* [100, 105, 108, 109] é inadequada e não deve ser utilizada, pois não representa o fenômeno da propagação de forma adequada neste contexto, e;
- o simulador disponibilizado é muito mais simples e prático do que a alternativa apresentada por WATSON *et al.* [19] e TRAMONTANA *et al.* [20], pois não requer aquisição de licenças caras, é intuitivo e computacionalmente menos intensivo.

Uma segunda etapa incluiu o desenvolvimento e a validação de abordagens que incorporaram quatro técnicas de IC combinadas a dois pré-processamentos inéditos neste contexto. Ao contrário da abordagem corrente na literatura de caracterização de tamanhos de partículas sólidas usando EA e IC que consome os sinais de EA em janelas de tamanho fixo, os pré-processamentos aqui propostos introduzem uma etapa de detecção de eventos (*hits*), a qual possui uma longa tradição de uso no contexto da EA associado aos ensaios não-destrutivos.

A introdução da detecção de eventos no pré-processamento permitiu uma nova formulação para o problema, a qual consiste na classificação direta de cada evento em uma classe de tamanho de partícula. Esta nova formulação é diferente da usual adotada na literatura (BASTARI *et al.* [14], ROSSETTI *et al.* [17]), a qual utiliza regressão para mapear os sinais de EA nas quantidades associadas a cada uma das classes de tamanhos de partículas, ou seja, na DTP do material analisado¹. Esta mudança de paradigma resulta em uma vantagem inovadora das abordagens desenvolvidas, uma vez que não há necessidade de re-treinamento dos classificadores no caso de alteração do diâmetro representativo do teor de finos.

Além disso, o pré-processamento especialista proposto aqui incorpora, também de forma inédita neste contexto, a redução de dimensionalidade dos sinais de EA através de uma extração de características que utiliza, mais uma vez, o conhecimento especialista de EA desenvolvido no contexto dos ensaios não-destrutivos. Já o segundo pré-processamento supera a questão de redução de dimensionalidade através da sincronização dos eventos de EA detectados e posterior compactação utilizando PCA, ou seja, realiza uma extração de características estatísticas.

De forma análoga, a partir dos resultados obtidos nesta segunda etapa, pode-se concluir que:

¹É importante observar que ambas as abordagens desenvolvidas e de referência se restringem a materiais de composição química homogênea.

- na abordagem baseada em parâmetros, das cinco variantes desenvolvidas, a que apresentou o melhor desempenho segundo os critérios adotados foi aquela que faz uso da técnica MLP, embora a técnica *C-SVC* radial tenha apresentado desempenho virtualmente idêntico;
- o desempenho da técnica GBM, embora estatisticamente menor, ficou muito próximo do das técnicas MLP e *C-SVC* radial;
- a análise de relevância das variáveis mostrou que todas as técnicas indicam os parâmetros derivados de EA no domínio da frequência como as variáveis mais relevantes, o que encontra-se em linha com a literatura (MATERO *et al.* [12], HANSULD *et al.* [15], HIRAJIMA e TSUNEKAWA [96], NORDON *et al.* [99], JIANG *et al.* [103], CARSON *et al.* [105]);
- a comparação entre os desempenhos do conjunto completo de parâmetros derivados de EA com o conjunto de parâmetros derivados de EA no domínio do tempo mostrou que estes, apesar de menos relevantes, não podem ser desprezados e contribuem com parcela significativa para o desempenho;
- na abordagem baseada em formas de onda, das duas variantes estudadas, a que apresentou o melhor desempenho segundo os critérios adotados foi aquela que faz uso da técnica *C-SVC* radial;
- a comparação entre os desempenhos das variantes selecionadas de cada uma das duas abordagens estudadas mostrou que o melhor desempenho é alcançado pela abordagem baseada em parâmetros que faz uso da técnica MLP;
- a abordagem proposta apresentou um desvio médio absoluto inferior a 1% na previsão do teor de finos, estando este valor em linha com resultados recentemente publicados por NSUGBE *et al.* [122], e;
- a abordagem de referência adotada apresentou um desempenho bem inferior ao resultados originais (BASTARI *et al.* [14]), alcançando um desvio médio absoluto inferior a 6% na previsão do teor de finos.

Além disso, embora o resultado da comparação entre a abordagem baseada em parâmetros e a baseada em formas de onda não possa ser encarado de forma incontestável, dado que esta última não foi explorada de forma tão intensa, o resultado obtido aqui sustenta a hipótese de que abordagens híbridas que combinam o conhecimento especialista com técnicas de IC são bastante promissoras no contexto da caracterização de tamanhos de partículas usando EA e não devem ser desprezadas.

Por fim, apesar de não ser uma conclusão direta dos resultados, é importante deixar registrado que a ausência de dados reprodutíveis e bem caracterizados impede

a realização de comparações justas entre as diferentes abordagens publicadas na literatura para caracterização de tamanhos de partículas usando EA e IC.

6.1 Perspectivas e trabalhos futuros

Os resultados obtidos até então são bastante promissores e oferecem diversas oportunidades de trabalhos futuros e, possivelmente, até mesmo o desenvolvimento de um produto para uso industrial.

Dentre várias destas oportunidades, podemos citar algumas que surgiram naturalmente ao longo deste trabalho, mas que por limitações de tempo e/ou escopo não foram exploradas. No que tange a IC, podemos citar:

- a exploração mais intensiva da abordagem baseada em formas de onda;
- a avaliação de outros métodos de extração de características para o pré-processamento estatístico como, por exemplo, a EEMD (AN *et al.* [18]);
- a avaliação de outros métodos de sintonia dos parâmetros ajustáveis como, por exemplo, a busca aleatória (BERGSTRA e BENGIO [203]), e;
- a avaliação de outras técnicas de IC como, por exemplo, os comitês (*ensembles*) de classificadores e o aprendizado profundo.

Enquanto, no que tange a EA, temos:

- a avaliação e possível incorporação de outros parâmetros derivados de EA no domínio da frequência (Tabela 2.4);
- o desenvolvimento de métodos que permitam a sintonia dos parâmetros do detector de eventos de EA clássico baseado em limiar, e;
- a avaliação de outros métodos para a detecção dos eventos de EA.

Além disso, cabe também ressaltar a necessidade da validação experimental da abordagem proposta tanto para os casos de materiais de composição química homogênea como para aqueles de composição química heterogênea (misturas).

Referências Bibliográficas

- [1] COCCO, R., ISSANGYA, A., KARRI, S. B. R., et al. “Small-scale particle interactions are having significant effects on global fluidized bed behavior”, *KONA Powder and Particle Journal*, v. 34, n. 0, pp. 155–167, 2017. doi: 10.14356/kona.2017021.
- [2] MERKUS, H. G. *Particle Size Measurements: Fundamentals, Practice, Quality*. Particle Technology Series. Springer Netherlands, 2009.
- [3] ROSSETTI, D., SQUARTINI, S., COLLURA, S., et al. “Power plant condition monitoring by means of coal powder granulometry classification”, *Measurement: Journal of the International Measurement Confederation*, v. 123, pp. 39–47, 2018. doi: 10.1016/j.measurement.2018.03.028.
- [4] REDMAN, T., O’GRADY, D. “Improve products and processes with inline particle analysis”, *Chemical Engineering Progress*, v. 113, n. 8, pp. 47–55, 2017.
- [5] LEACH, M. F., RUBIN, G. A., WILLIAMS, J. C. “Particle size determination from acoustic emissions”, *Powder Technology*, v. 16, n. 2, pp. 153–158, 1977. doi: 10.1016/0032-5910(77)87001-0.
- [6] BOUCHARD, J. G., PAYNE, P. A., SZYSZKO, S. “Non-invasive measurement of process states using acoustic emission techniques coupled with advanced signal processing”, *Transactions of the Institution of Chemical Engineers*, v. 72, n. A, pp. 20–25, 1994.
- [7] CHEN, X., CHEN, D. “Measuring average particle size for fluidized bed reactors by employing acoustic emission signals and neural networks”, *Chemical Engineering and Technology*, v. 31, n. 1, pp. 95–102, 2008. doi: 10.1002/ceat.200700176.
- [8] PAPP, M. K., PUJARA, C. P., PINAL, R. “Monitoring of high-shear granulation using acoustic emission: Predicting granule properties”, *Journal of Pharmaceutical Innovation*, v. 3, n. 2, pp. 113–122, 2008. doi: 10.1007/s12247-008-9030-6.

- [9] CAO, Y., WANG, J. D., HE, Y., et al. “Agglomeration detection based on attractor comparison in horizontal stirred bed reactors by acoustic emission sensors”, *AIChE Journal*, v. 55, n. 12, pp. 3099–3108, 2009. doi: 10.1002/aic.11935.
- [10] HE, Y., WANG, J. D., CAO, Y., et al. “Resolution of structure characteristics of AE signals in multiphase flow system - From data to information”, *AIChE Journal*, v. 55, n. 10, pp. 2563–2577, 2009. doi: 10.1002/aic.11878.
- [11] REN, C. J., WANG, J. D., SONG, D., et al. “Determination of particle size distribution by multi-scale analysis of acoustic emission signals in gas-solid fluidized bed”, *Journal of Zhejiang University SCIENCE A*, v. 12, n. 4, pp. 260–267, 2011. doi: 10.1631/jzus.A1000396.
- [12] MATERO, S., POUTIAINEN, S., LESKINEN, J., et al. “The feasibility of using acoustic emissions for monitoring of fluidized bed granulation”, *Chemometrics and Intelligent Laboratory Systems*, v. 97, n. 1, pp. 75–81, 2009. doi: 10.1016/j.chemolab.2008.11.001.
- [13] MATERO, S., POUTIAINEN, S., LESKINEN, J., et al. “Estimation of granule size distribution for batch fluidized bed granulation process using acoustic emission and N-way PLS”, *Journal of Chemometrics*, v. 24, n. 7-8, pp. 464–471, 2010. doi: 10.1002/cem.1269.
- [14] BASTARI, A., CRISTALLI, C., MORLACCHI, R., et al. “Acoustic emissions for particle sizing of powders through signal processing techniques”, *Mechanical Systems and Signal Processing*, v. 25, n. 3, pp. 901–916, 2011. doi: 10.1016/j.ymsp.2010.08.019.
- [15] HANSULD, E. M., BRIENS, L., SAYANI, A., et al. “An investigation of the relationship between acoustic emissions and particle size”, *Powder Technology*, v. 219, pp. 111–117, 2012. doi: 10.1016/j.powtec.2011.12.025.
- [16] HU, Y., WANG, L., HUANG, X., et al. “On-line Sizing of Pneumatically Conveyed Particles Through Acoustic Emission Detection and Signal Analysis”, *IEEE Transactions on Instrumentation and Measurement*, v. 64, n. 5, pp. 1100–1109, 2015. doi: 10.1109/TIM.2014.2355653.
- [17] ROSSETTI, D., SQUARTINI, S., COLLURA, S. “Machine learning techniques for the estimation of particle size distribution in industrial plants”, *Smart Innovation, Systems and Technologies*, v. 54, pp. 335–343, 2016. doi: 10.1007/978-3-319-33747-0_33.

- [18] AN, L., LIU, W., JI, Y., et al. “Detection of pneumatic conveying by acoustic emissions”, *Applied Sciences*, v. 9, n. 3, 2019. doi: 10.3390/app9030501.
- [19] WATSON, N. J., POVEY, M. J. W., REYNOLDS, G. K., et al. “Acoustic emission monitoring from a lab scale high shear granulator - A novel approach”, *International Journal of Pharmaceutics*, v. 465, n. 1-2, pp. 262–274, 2014. doi: 10.1016/j.ijpharm.2014.01.032.
- [20] TRAMONTANA, M., GACHAGAN, A., NORDON, A., et al. “System modelling and device development for passive acoustic monitoring of a particulate-liquid process”, *Sensors and Actuators, A: Physical*, v. 228, pp. 159–169, 2015. doi: 10.1016/j.sna.2015.03.022.
- [21] ALLEN, T. *Powder Sampling and Particle Size Determination*. Amsterdam, Elsevier, 2003. doi: 10.1016/B978-044451564-3/50001-2.
- [22] TROTTIER, R. “Size Measurement of Particles”. In: *Kirk-Othmer Encyclopedia of Chemical Technology*, pp. 1–25, John Wiley & Sons, Inc, 2015. doi: 10.1002/0471238961.1909260520181520.a01.pub3.
- [23] JILLAVENKATESA, A., DAPKUNAS, S. J., SIEN H. LUM, L., et al. *Particle Size Characterization*. Recommended practice guide 960-1, National Institute of Standards and Technology, Washington, 2001.
- [24] SOARES, S. D. *Correlações entre emissão acústica de defeitos e parâmetros de mecânica da fratura na avaliação da integridade de equipamentos pressurizados*. Tese de Doutorado, COPPE/UFRJ/PEE, Rio de Janeiro, 2008.
- [25] ABNT. *Ensaio não destrutivo – Ensaio de emissão acústica (EA) – Terminologia*. Norma, Associação Brasileira de Normas Técnicas, Rio de Janeiro, Brasil, 2012.
- [26] BEATTIE, A. G. *Acoustic Emission Non-Destructive Testing of Structures using Source Location Techniques*. In: Report SAND2013-7779, Sandia National Laboratories, 2013.
- [27] BRUNNER, A. J., BARBEZAT, M. “Acoustic emission leak testing of pipes for pressurized gas using active fiber composite elements as sensors”, *Journal of Acoustic Emission*, v. 25, pp. 42–51, 2007.
- [28] SOHAIB, M., ISLAM, M., KIM, J., et al. “Leakage Detection of a Spherical Water Storage Tank in a Chemical Industry Using Acoustic Emissions”, *Applied Sciences*, v. 9, n. 1, pp. 196, 2019.

- [29] BENABDALLAH, H., AGUILAR, D. “Acoustic emission and its relationship with friction and wear for sliding contact”, *Tribology Transactions*, v. 51, n. 6, pp. 738–747, 2008.
- [30] MOSER, D., GÜLDEMEISTER, N., WÜNNEMANN, K., et al. “Acoustic emission analysis of experimental impact processes in comparison to ultrasound measurements and numerical modeling”, *Journal of Acoustic Emission*, v. 31, n. 1, pp. 50–66, 2013.
- [31] ALFAYEZ, L., MBA, D., DYSON, G. “The application of acoustic emission for detecting incipient cavitation and the best efficiency point of a 60 kW centrifugal pump: case study”, *Ndt & E International*, v. 38, n. 5, pp. 354–358, 2005.
- [32] SAWADA, T., GOHSHI, Y., ABE, C., et al. “Acoustic emission from phase transition of some chemicals”, *Analytical Chemistry*, v. 57, n. 8, pp. 1743–1745, 1985.
- [33] BUILO, S. I., KUZNETSOV, D. M. “Acoustic-emission testing and diagnostics of the kinetics of physicochemical processes in liquid media”, *Russian Journal of Nondestructive Testing*, v. 46, n. 9, pp. 684–689, 2010.
- [34] SERRIS, E., CAMEIRAO, A., GRUY, F. “Monitoring industrial crystallization using acoustic emission”, *Journal of Acoustic Emission*, v. 33, pp. S233–S233, 2016.
- [35] BELCHAMBER, R., BETTERIDGE, D., COLLINS, M., et al. “Quantitative study of acoustic emission from a model chemical process”, *Analytical Chemistry*, v. 58, n. 8, pp. 1873–1877, 1986.
- [36] WADE, A. P. “Acoustic emission: is industry listening?” *Chemometrics and Intelligent Laboratory Systems*, v. 8, n. 3, pp. 305–310, 1990.
- [37] WENTZELL, P. D., VANSLYKE, S. J., BATEMAN, K. P. “Evaluation of acoustic emission as a means of quantitative chemical analysis”, *Analytica chimica acta*, v. 246, n. 1, pp. 43–53, 1991.
- [38] VAN DIJCK, G., VAN HULLE, M. M. “Information theory filters for wavelet packet coefficient selection with application to corrosion type identification from acoustic emission signals”, *Sensors*, v. 11, n. 6, pp. 5695–5715, 2011.
- [39] KOCUR, G. K. *Time reverse modeling of acoustic emissions in structural concrete*. D.Sc. thesis, ETH Zurich, 2012.

- [40] GAUTSCHI, G. *Piezoelectric Sensorics: Force Strain Pressure Acceleration and Acoustic Emission Sensors Materials and Amplifiers*. Springer, 2002.
- [41] SAFARI, A., AKDOGAN, E. *Piezoelectric and Acoustic Materials for Transducer Applications*. Springer, 2008.
- [42] PROCTOR, T. M. “An improved piezoelectric acoustic emission transducer”, *The Journal of the Acoustical Society of America*, v. 71, n. 5, pp. 1163–1168, 1982. doi: 10.1121/1.387763.
- [43] BUTTLE, D. J., SCRUBY, C. B. “Characterization of fatigue of aluminum alloys by acoustic emission. Part I”, *Journal of Acoustic Emission*, v. 9, pp. 243–254, 1990.
- [44] EVANS, M. J. *The Use of Diffuse Field Measurements for Acoustic Emission*. Ph.D. dissertation, Imperial College, London, Reino Unido, 1997.
- [45] MCLASKEY, G. C., GLASER, S. D. “Acoustic Emission Sensor Calibration for Absolute Source Measurements”, *Journal of Nondestructive Evaluation*, v. 31, n. 2, pp. 157–168, 2012. ISSN: 1573-4862. doi: 10.1007/s10921-012-0131-2.
- [46] UNNPORSSON, R. “Hit detection and determination in AE bursts”. In: Sikorski, W. (Ed.), *Acoustic Emission - Research and Applications*, InTech, cap. 1, pp. 1–20, 2013. doi: 10.5772/54754.
- [47] VALLEN. “AMSY-6 System Description”. 2015.
- [48] ONO, K. “Acoustic Emission”. In: Rossing, T. D. (Ed.), *Springer Handbook of Acoustics*, 2 ed., cap. 30, Heidelberg, Springer, 2014.
- [49] SAUSE, M. *Identification of failure mechanisms in hybrid materials utilizing pattern recognition techniques applied to acoustic emission signals*. Tese de Doutorado, Univeristy of Augsburg, 2010.
- [50] ASTM. *Standard terminology for nondestructive examinations. Technical Standard*, ASTM International, West Conshohocken, EUA, 2010.
- [51] SCRUBY, C. B. “Quantitative acoustic emission techniques”. In: Sharpe, R. S. (Ed.), *Research Techniques in Non-destructive Testing Vol VIII*, cap. 4, pp. 141–210, London, Academic Press, 1985.
- [52] SACHSE, W., KIM, K. “Quantitative acoustic emission and failure mechanics of composite materials”, *Ultrasonics*, v. 25, n. 4, pp. 195 – 203, 1987. doi: 10.1016/0041-624X(87)90033-3.

- [53] GROSSE, C. U., OHTSU, M. *Acoustic Emission Testing*. 1 ed. Berlin, Springer-Verlag, 2008.
- [54] POMPONI, E., VINOGRADOV, A. “A real-time approach to acoustic emission clustering”, *Mechanical Systems and Signal Processing*, v. 40, n. 2, pp. 791 – 804, 2013. doi: 10.1016/j.ymssp.2013.03.017.
- [55] RAMASSO, E., PLACET, V., BOUBAKAR, M. L. “Unsupervised consensus clustering of acoustic emission time-series for robust damage sequence estimation in composites”, *IEEE Transactions on Instrumentation and Measurement*, v. 64, n. 12, pp. 3297–3307, 2015.
- [56] AGLETDINOV, E., POMPONI, E., MERSON, D., et al. “A novel Bayesian approach to acoustic emission data analysis”, *Ultrasonics*, v. 72, pp. 89 – 94, 2016. doi: 10.1016/j.ultras.2016.07.014.
- [57] CUNHA, C., S. LUNA, A., C.G. OLIVEIRA, R., et al. “Predicting the properties of biodiesel and its blends using mid-FT-IR spectroscopy and first-order multivariate calibration”, *Fuel*, v. 204, pp. 185–194, 09 2017. doi: 10.1016/j.fuel.2017.05.057.
- [58] KE, G., MENG, Q., FINLEY, T., et al. “LightGBM: A Highly Efficient Gradient Boosting Decision Tree”. In: Guyon, I., Luxburg, U. V., Bengio, S., et al. (Eds.), *Advances in Neural Information Processing Systems 30*, Curran Associates, pp. 3146–3154, 2017.
- [59] LONG, P. M., SERVEDIO, R. A. “Random classification noise defeats all convex potential boosters”, *Machine learning*, v. 78, n. 3, pp. 287–304, 2010.
- [60] GÓMEZ-RÍOS, A., LUENGO, J., HERRERA, F. “A Study on the Noise Label Influence in Boosting Algorithms: AdaBoost, GBM and XGBoost”. In: Martínez de Pisón, F. J., Urraca, R., Quintián, H., et al. (Eds.), *Hybrid Artificial Intelligent Systems*, pp. 268–280, Cham, 2017. Springer. doi: 10.1007/978-3-319-59650-1_23.
- [61] HASTIE, T., TIBSHIRANI, R., FRIEDMAN, J. *The Elements of Statistical Learning*. Springer, 2009. doi: 10.1007/978-0-387-84858-7.
- [62] WOLD, S., SJÖSTRÖM, M., ERIKSSON, L. “PLS-regression: a basic tool of chemometrics”, *Chemometrics and Intelligent Laboratory Systems*, v. 58, n. 2, pp. 109 – 130, 2001. doi: 10.1016/S0169-7439(01)00155-1.

- [63] ABDI, H. “Partial least squares regression and projection on latent structure regression (PLS Regression)”, *Wiley Interdisciplinary Reviews: Computational Statistics*, v. 2, n. 1, pp. 97–106, 2010. doi: 10.1002/wics.51.
- [64] ERIKSSON, L., TRYGG, J., WOLD, S. “A chemometrics toolbox based on projections and latent variables”, *Journal of Chemometrics*, v. 28, n. 5, pp. 332–346, 2014. doi: 10.1002/cem.2581.
- [65] HALSTENSEN, M., KAKU, B., AMUNDSEN, L., et al. “Online estimation of wax deposition thickness in single-phase sub-sea pipelines based on acoustic chemometrics : A feasibility study”, *Fuel*, v. 105, pp. 718–727, 2013. doi: 10.1016/j.fuel.2012.10.004.
- [66] ANDERSEN, A. H., RAYENS, W. S., LIU, Y., et al. “Partial least squares for discrimination in fMRI data”, *Magnetic Resonance Imaging*, v. 30, n. 3, pp. 446–452, apr 2012. doi: 10.1016/j.mri.2011.11.001.
- [67] PEARSON, K. “LIII. On lines and planes of closest fit to systems of points in space”, *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, v. 2, n. 11, pp. 559–572, 1901.
- [68] BARROS, A. S., RUTLEDGE, D. N. “Genetic algorithm applied to the selection of principal components”, *Chemometrics and Intelligent Laboratory Systems*, v. 40, n. 1, pp. 65–81, 1998. doi: [http://dx.doi.org/10.1016/S0169-7439\(98\)00002-1](http://dx.doi.org/10.1016/S0169-7439(98)00002-1).
- [69] WOLD, S., ALBANO, C., DUNN, W., et al. “Pattern recognition: Finding and using regularities in multivariate data”. In: Martens, H., Russwurm Jr, H. (Eds.), *IUFOST Conference in Food Research and Data Analysis*, pp. 147–188. FAO of the UN, 1983.
- [70] MEVIK, B.-H., WEHRENS, R. “The pls Package: Principal Component and Partial Least Squares Regression in R”, *Journal of Statistical Software*, v. 18, n. 1, pp. 1–23, 2007. doi: 10.18637/jss.v018.i02.
- [71] BISHOP, C. M. *Neural Networks for Pattern Recognition*. New York, Oxford University Press, 1995.
- [72] VAPNIK, V. N. *The Nature of Statistical Learning Theory*. New York, Springer, 1995.
- [73] BOSER, B. E., GUYON, I. M., VAPNIK, V. N. “A training algorithm for optimal margin classifiers”. In: *Proceedings of the Fifth Annual Workshop on Computational Learning Theory*, pp. 144–152. ACM, 1992.

- [74] CORTES, C., VAPNIK, V. “Support-vector networks”, *Machine Learning*, v. 20, n. 3, pp. 273–297, 1995.
- [75] PLATT, J. C. “Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods”. In: *Advances in Large Margin Classifiers*, pp. 61–74, Cambridge, 1999. MIT Press.
- [76] FRIEDMAN, J. H. “Greedy function approximation: A gradient boosting machine”, *Annals of Statistics*, v. 29, n. 5, pp. 1189–1232, 2001.
- [77] FRIEDMAN, J. H. “Stochastic gradient boosting”, *Computational Statistics and Data Analysis*, v. 38, n. 4, pp. 367–378, 2002.
- [78] FRIEDMAN, J. H. “Additive logistic Regression: A statistical view of boosting”, *Annals of Statistics*, v. 28, n. 2, pp. 337–374, 2000.
- [79] CYBENKO, G. “Approximation by superpositions of a sigmoidal function”, *Mathematics of Control, Signals and Systems*, v. 2, n. 4, pp. 303–314, 1989. doi: 10.1007/BF02551274.
- [80] ROSENBLATT, F. *Principles of Neurodynamics*. Washington DC, Spartan Books, 1962.
- [81] RUMELHART, D., MCCLELLAND, J. E. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Volume 1: Foundations*. Cambridge, MIT Press, 1986.
- [82] VENABLES, W. N., RIPLEY, B. D. *Modern Applied Statistics with S*. 4 ed. New York, Springer, 2002.
- [83] DEBYE, P. “Näherungsformeln für die Zylinderfunktionen für große Werte des Arguments und unbeschränkt veränderliche Werte des Index”, *Mathematische Annalen*, v. 67, n. 4, pp. 535–558, 1909. doi: 10.1007/BF01450097.
- [84] HAGAN, M. T., MENHAJ, M. B. “Training feedforward networks with the Marquardt algorithm”, *IEEE Transactions on Neural Networks*, v. 5, n. 6, pp. 989–993, 1994. doi: 10.1109/72.329697.
- [85] LEVENBERG, K. “A method for the solution of certain non-linear problems in least squares”, *Quarterly of Applied Mathematics*, v. 2, n. 2, pp. 164–168, 1944.
- [86] LEACH, M. F., RUBIN, G. A., WILLIAMS, J. C. “Particle size distribution characterization from acoustic emissions”, *Powder Technology*, v. 19, n. 2, pp. 157–167, 1978. doi: 10.1016/0032-5910(78)80024-2.

- [87] LEACH, M. F., RUBIN, G. A. “Size analysis of particles of irregular shape from their acoustic emissions”, *Powder Technology*, v. 21, n. 2, pp. 263–267, 1978. doi: 10.1016/0032-5910(78)80094-1.
- [88] LEACH, M. F., RUBIN, G. A., WILLIAMS, J. C. “Analysis of Gaussian size distribution of rigid particles from their acoustic emission”, *Powder Technology*, v. 19, n. 2, pp. 189–195, 1978. doi: 10.1016/0032-5910(78)80027-8.
- [89] LEACH, M. F., RUBIN, G. A., WILLIAMS, J. C. “Analysis of polydisperse systems of rigid particles from acoustic emissions”, *Powder Technology*, v. 19, n. 2, pp. 169–176, 1978. doi: 10.1016/0032-5910(78)80025-4.
- [90] ARRINGTON, M. “The use of acoustic emission instrumentation to monitor powder flows”, *NDT International*, v. 14, n. 1, pp. 3–8, 1981. doi: 10.1016/0308-9126(81)90056-0.
- [91] KWAN, H. W., LEACH, M. F. “Characterization of cylindrical particles from their acoustic emission”, *Ultrasonics*, v. 23, n. 5, pp. 233–238, 1985. doi: 10.1016/0041-624X(85)90019-8.
- [92] BUTTLE, D. J., MARTIN, S. R., SCRUBY, C. B. “Particle sizing by quantitative acoustic emission”, *Research in Nondestructive Evaluation*, v. 3, n. 1, pp. 1–26, 1991. doi: 10.1007/BF01606508.
- [93] HERTZ, H. *Miscellaneous Papers*. London, Macmillan, 1896.
- [94] RUMELHART, D. E., HINTON, G. E., WILLIAMS, R. J. *Learning internal representations by error propagation*. Relatório técnico, California Univ San Diego La Jolla Inst for Cognitive Science, 1985.
- [95] COVER, T., HART, P. “Nearest neighbor pattern classification”, *IEEE Transactions on Information Theory*, v. 13, n. 1, pp. 21–27, 1967.
- [96] HIRAJIMA, T., TSUNEKAWA, M. “Acoustic emissions from the impact of particles and their application to on-line monitoring for zirconia micro-agglomerate production in liquids”, *Developments in Mineral Processing*, v. 13, n. C, pp. C3–8–C3–16, 2000. doi: 10.1016/S0167-4528(00)80010-1.
- [97] WHITAKER, M., BAKER, G. R., WESTRUP, J., et al. “Application of acoustic emission to the monitoring and end point determination of a high shear granulation process”, *International Journal of Pharmaceutics*, v. 205, n. 1–2, pp. 79–91, 2000. doi: 10.1016/S0378-5173(00)00479-8.

- [98] NORDON, A., WADDELL, R. J. H., BELLAMY, L. J., et al. “Monitoring of a heterogeneous reaction by acoustic emission”, *Analyst*, v. 129, pp. 463–467, 2004. doi: 10.1039/b402875a.
- [99] NORDON, A., CARELLA, Y., GACHAGAN, A., et al. “Factors affecting broadband acoustic emission measurements of a heterogeneous reaction”, *Analyst*, v. 131, n. 2, pp. 323–330, 2006. doi: 10.1039/b510922a.
- [100] CARSON, G., MULHOLLAND, A. J., NORDON, A., et al. “Particle sizing in the process industry using Hertz-Zener impact theory and acoustic emission spectra”. In: *Proceedings - IEEE Ultrasonics Symposium*, v. 1, pp. 1406–1409, 2006. doi: 10.1109/ULTSYM.2006.360.
- [101] TRAMONTANA, M., GACHAGAN, A., HAYWARD, G., et al. “Ultrasonic monitoring of heterogeneous chemical reactions”. In: *Proceedings - IEEE Ultrasonics Symposium*, v. 1, pp. 906–909, 2006. doi: 10.1109/ULTSYM.2006.243.
- [102] ZENER, C. “The Intrinsic Inelasticity of Large Plates”, *Physical Review*, v. 59, pp. 669–673, Apr 1941. doi: 10.1103/PhysRev.59.669.
- [103] JIANG, X. J., WANG, J. D., JIANG, B. B., et al. “Study of the power spectrum of acoustic emission (AE) by accelerometers in fluidized beds”, *Industrial and Engineering Chemistry Research*, v. 46, n. 21, pp. 6904–6909, 2007. doi: 10.1021/ie070457i.
- [104] LANDAU, L. D., LIFSCHITZ, E. M. *Theory of Elasticity*. 2 ed. London, Pergamon Press, 1970.
- [105] CARSON, G., MULHOLLAND, A. J., NORDON, A., et al. “Particle sizing using passive ultrasonic measurement of particle-wall impact vibrations”, *Journal of Sound and Vibration*, v. 317, n. 1-2, pp. 142–157, 2008. doi: 10.1016/j.jsv.2008.03.005.
- [106] DONOHO, D. L., JOHNSTONE, I. M. “Adapting to unknown smoothness via wavelet shrinkage”, *Journal of the American Statistical Association*, v. 90, n. 432, pp. 1200–1224, 1995.
- [107] DIKS, C., VAN ZWET, W. R., TAKENS, F., et al. “Detecting differences between delay vector distributions”, *Physical Review E*, v. 53, pp. 2169–2176, Mar 1996. doi: 10.1103/PhysRevE.53.2169.

- [108] CARSON, G., MULHOLLAND, A. J., NORDON, A., et al. “Theoretical analysis of ultrasonic vibration spectra from multiple particle-plate impacts”, *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, v. 56, n. 5, pp. 1034–1041, 2009. doi: 10.1109/TUFFFC.2009.1135.
- [109] CARSON, G., MULHOLLAND, A. J., NORDON, A., et al. “Estimating particle concentration using passive ultrasonic measurement of impact vibrations”, *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, v. 56, n. 2, pp. 345–352, 2009. doi: 10.1109/TUFFFC.2009.1043.
- [110] HURST, H. E. “Long-term storage capacity of reservoirs”, *Trans. Amer. Soc. Civil Eng.*, v. 116, pp. 770–808, 1951.
- [111] TUCKER, L. R. “Some mathematical notes on three-mode factor analysis”, *Psychometrika*, v. 31, n. 3, pp. 279–311, 1966.
- [112] BRO, R. “Multiway calibration. Multilinear PLS”, *Journal of Chemometrics*, v. 10, n. 1, pp. 47–61, 1996. doi: 10.1002/(SICI)1099-128X(199601)10:1<47::AID-CEM400>3.0.CO;2-C.
- [113] COIFMAN, R. R., WICKERHAUSER, M. V. “Entropy-based algorithms for best basis selection”, *IEEE Transactions on Information Theory*, v. 38, n. 2, pp. 713–718, 1992. doi: 10.1109/18.119732.
- [114] TRYGG, J., WOLD, S. “Orthogonal projections to latent structures (O-PLS)”, *Journal of Chemometrics*, v. 16, n. 3, pp. 119–128, 2002. doi: 10.1002/cem.695.
- [115] HANSULD, E. M. *Audible Acoustic Emissions for Monitoring High-Shear Granulation*. Tese de Doutorado, The University of Western Ontario, 2011.
- [116] CUNDALL, P. A., STRACK, O. D. L. “A discrete numerical model for granular assemblies”, *Geotechnique*, v. 29, n. 1, pp. 47–65, 1979.
- [117] HUANG, G.-B., ZHU, Q.-Y., SIEW, C.-K. “Extreme learning machine: a new learning scheme of feedforward neural networks”. In: *2004 IEEE International Joint Conference on Neural Networks*, v. 2, pp. 985–990, . doi: 10.1109/IJCNN.2004.1380068.
- [118] HUANG, G. B., ZHOU, H., DING, X., et al. “Extreme Learning Machine for Regression and Multiclass Classification”, *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, v. 42, n. 2, pp. 513–529, . doi: 10.1109/TSMCB.2011.2168604.

- [119] NSUGBE, E., STARR, A., FOOTE, P., et al. “Size Differentiation of A Continuous Stream of Particles Using Acoustic Emissions”. v. 161, 2016. doi: 10.1088/1757-899X/161/1/012090.
- [120] NSUGBE, E., STARR, A., JENNIONS, I., et al. “Particle Size Distribution Estimation of A Mixture of Regular and Irregular Sized Particles Using Acoustic Emissions”, *Procedia Manufacturing*, v. 11, pp. 2252–2259, 2017. doi: 10.1016/j.promfg.2017.07.373.
- [121] NSUGBE, E., STARR, A., JENNIONS, I., et al. “Online particle size distribution estimation of a mixture of similar sized particles with acoustic emissions”. v. 885, 2017. doi: 10.1088/1742-6596/885/1/012009.
- [122] NSUGBE, E., RUIZ-CARCE, C., STARR, A., et al. “Estimation of fine and oversize particle ratio in a heterogeneous compound with acoustic emissions”, *Sensors (Switzerland)*, v. 18, n. 3, 2018. doi: 10.3390/s18030851.
- [123] WU, Z., HUANG, N. E. “Ensemble empirical mode decomposition: a noise-assisted data analysis method”, *Advances in Adaptive Data Analysis*, v. 1, n. 01, pp. 1–41, 2009.
- [124] PROSSER, W., HAMSTAD, M., GARY, J., et al. “Finite element and plate theory modeling of acoustic emission waveforms”, *Journal of Non-destructive Evaluation*, v. 18, n. 3, pp. 83–90, 1999. doi: 10.1023/A:1021888009896.
- [125] HAMSTAD, M. A., O’GALLAGHER, A., GARY, J. “A wavelet transform applied to acoustic emission”, *Journal of Acoustic Emission*, v. 20, pp. 39–61, 2002.
- [126] LAMB, H. “On waves in an elastic plate”, *Proceedings of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, v. 93, n. 648, pp. 114–128, 1917. doi: 10.1098/rspa.1917.0008.
- [127] HAYAKAWA, H., KUNINAKA, H. “Theory of the inelastic impact of elastic materials”, *Phase Transitions*, v. 77, n. 8-10, pp. 889–909, 2004. doi: 10.1080/01411590410001690936.
- [128] ABRAMOWITZ, M. *Handbook of Mathematical Functions, With Formulas, Graphs, and Mathematical Tables*,. Dover Publications, 1974.
- [129] SMITH, G. D. *Numerical solution of partial differential equations: Finite difference methods*. 3 ed. Oxford, Clarendon Press, 1985.

- [130] FORNBERG, B. “Generation of finite-difference formulas on arbitrarily spaced grids”, *Mathematics of Computation*, v. 51, n. 184, pp. 699–706, 1988.
- [131] SAMARSKII, A. A. *The theory of difference schemes*. Marcel Dekker, 2001.
- [132] MOCZO, P., KRISTEK, J., HALADA, L. *The finite-difference method for seismologists. An introduction*. Bratislava, Comenius University, 2004.
- [133] STRIKWERDA, J. C. *Finite difference schemes and partial differential equations*. 2 ed. Philadelphia, Society for Industrial and Applied Mathematics, 2004.
- [134] SILVA, B. S. *Avaliação de operadores convolucionais na solução da equação acústica da onda*. Dissertação de mestrado, UFRJ/COPPE/PEC, Rio de Janeiro, 2014.
- [135] ZIENKIEWICZ, O. C., TAYLOR, R. L. *The Finite Element Method: Basic formulation and linear problems*. The Finite Element Method. McGraw-Hill, 1989.
- [136] COOK, R. D., MALKUS, D. S., PLESHA, M. E. *Concepts and applications of finite element analysis*. Wiley, 1989.
- [137] CHO, Y., ROSE, J. L. “A boundary element solution for a mode conversion study on the edge reflection of Lamb waves”, *The Journal of the Acoustical Society of America*, v. 99, n. 4, pp. 2097–2109, 1996.
- [138] XU, S. *The Boundary Element Method in Geophysics*. Geophysical monograph series. Society of Exploration Geophysicists, 2001.
- [139] FORNBERG, B. “The pseudospectral method: Comparisons with finite differences for the elastic wave equation”, *Geophysics*, v. 52, n. 4, pp. 483–501, 1987.
- [140] FORNBERG, B. “The pseudospectral method: Accurate representation of interfaces in elastic wave calculations”, *Geophysics*, v. 53, n. 5, pp. 625–637, 1988.
- [141] DAUDT, C. R., BRAILE, L. W., NOWACK, R. L., et al. “A comparison of finite-difference and Fourier method calculations of synthetic seismograms”, *Bulletin of the Seismological Society of America*, v. 79, n. 4, pp. 1210–1230, 1989.
- [142] TREFETHEN, L. N. *Spectral Methods in MATLAB*. Software, Environments, and Tools. Society for Industrial and Applied Mathematics, 2000.

- [143] BOYD, J. P. *Chebyshev and Fourier spectral methods*. New York, Dover Publications, 2000.
- [144] COSTA, B. “Spectral methods for partial differential equations”, *CUBO A Mathematical Journal*, v. 6, n. 4, pp. 1–32, 2004.
- [145] SHEN, J., TANG, T. *Spectral and high-order methods with applications*. Beijing, China, Science Press, 2006.
- [146] BAZÁN, F. S. V. “Chebyshev pseudospectral method for wave equation with absorbing boundary conditions that does not use a first order hyperbolic system”, *Mathematics and Computers in Simulation*, v. 80, pp. 2124–2133, 2010.
- [147] DELSANTO, P. P., WHITCOMBE, T., CHASKELIS, H. H., et al. “Connection machine simulation of ultrasonic wave propagation in materials. I: the one-dimensional case”, *Wave motion*, v. 16, n. 1, pp. 65–80, 1992.
- [148] DELSANTO, P. P., SCHECHTER, R. S., CHASKELIS, H. H., et al. “Connection machine simulation of ultrasonic wave propagation in materials. II: the two-dimensional case”, *Wave Motion*, v. 20, n. 4, pp. 295–314, 1994.
- [149] DELSANTO, P. P., SCHECHTER, R. S., MIGNOGNA, R. B. “Connection machine simulation of ultrasonic wave propagation in materials III: The three-dimensional case”, *Wave Motion*, v. 26, n. 4, pp. 329–339, 1997.
- [150] DOBIE, G., SPENCER, A., BURNHAM, K., et al. “Simulation of ultrasonic lamb wave generation, propagation and detection for a reconfigurable air coupled scanner”, *Ultrasonics*, v. 51, n. 3, pp. 258–269, 2011.
- [151] CERVENY, V. *Seismic Ray Theory*. Cambridge University Press, 2005.
- [152] DITRI, J. J., PILARSKI, B., PAVLAKOVIC, B. N., et al. “Generation of guided waves in a plate by axisymmetric normal surface loading”. In: Thompson, D. O., Chimenti, D. E. (Eds.), *Review of Progress in Quantitative Nondestructive Evaluation*, v. 13, cap. 30, pp. 133–140, New York, Plenum Press, 1994.
- [153] PAVLAKOVIC, B. N., ROSE, J. L. *The Influence of finite-size sources in acousto-ultrasonics*. Relatório Técnico NASA-CR-195374, NASA, 1994.
- [154] WILCOX, P. D. *Lamb wave inspection of large structures using permanently attached transducers*. Tese de Doutorado, Imperial College, London, 1998.

- [155] PREGO-BORGES, J. L. *Lamb: A simulation tool for air-coupled Lamb wave based ultrasonic NDE systems*. Tese de Doutorado, Polytechnic University of Catalonia, Barcelona, 2010.
- [156] GIURGIUTIU, V. *Structural health monitoring with piezoelectric wafer active sensors*. Elsevier, 2014.
- [157] ACHENBACH, J. D. *Wave Propagation in Elastic Solids*. 1 ed. Amsterdam, Elsevier, 1975.
- [158] POLLARD, H. F. *Sound Waves in Solids*. Pion, 1977.
- [159] KOLSKY, H. *Stress Waves in Solids*. Dover Publications, 2003.
- [160] GRAFF, K. F. *Wave Motion in Elastic Solids*. Dover Publications, 1991.
- [161] EINSTEIN, A. “Die Grundlage der allgemeinen Relativitätstheorie”, *Annalen der Physik*, v. 354, pp. 769–822, 1916.
- [162] BOWER, A. F. *Applied Mechanics of Solids*. CRC Press, 2009.
- [163] MALVERN, L. E. *Introduction to the Mechanics of a Continuous Medium*. 1 ed. New Jersey, Prentice-Hall, 1969.
- [164] PIESENS, R. “The Hankel transform”. In: Poularikas, A. D. (Ed.), *The Transforms and Applications Handbook*, 3 ed., cap. 9, Boca Raton, CRC Press, 2010.
- [165] VIKTOROV, I. A. *Rayleigh and Lamb Waves: Physical Theory and Applications*. New York, Plenum Press, 1967.
- [166] HASKELL, N. A. “The dispersion of surface waves on multilayered media”, *Bulletin of the Seismological Society of America*, v. 43, pp. 17–34, 1953.
- [167] KNOPOFF, L. “A matrix method for elastic wave problems”, *Bulletin of the Seismological Society of America*, v. 54, pp. 431–438, 1964.
- [168] LOWE, M. J. S. *Plate waves for the NDT of diffusion bonded titanium*. Tese de Doutorado, Imperial College, London, 1992.
- [169] PAVLAKOVIC, B. N., LOWE, M. J. S., ALLEYNE, D. N., et al. “Disperse: A general purpose program for creating dispersion curves”. In: Thompson, D. O., Chimenti, D. E. (Eds.), *Review of Progress in Quantitative Non-destructive Evaluation*, v. 16, cap. 30, pp. 185–192, New York, Plenum Press, 1997.

- [170] LOVE, A. E. H. “The small free vibrations and deformation of a thin elastic shell”, *Philosophical Transactions of the Royal Society of London. A*, v. 179, pp. 491–546, 1888.
- [171] MINDLIN, R. D. “Influence of rotatory inertia and shear on flexural motions of isotropic elastic plates”, *Journal of Applied Mechanics*, v. 18, pp. 31–38, 1951.
- [172] AGILENT. “Network Analyzer Basics”. 2004.
- [173] ASTM. *Standard method for primary calibration of acoustic emission sensors*. Standard, ASTM International, West Conshohocken, 2012.
- [174] ISO. *Methods for absolute calibration of acoustic emission transducers by the reciprocity technique*. Standard, International Organization for Standardization, Geneva, 2011.
- [175] GROSSE, C. U. *Quantitative non-destructive testing of construction materials using acoustic emission technique and ultrasound*. Tese de Doutorado, University of Stuttgart, Stuttgart, 1996.
- [176] GOUJON, L., BABOUX, J. C. “Behaviour of acoustic emission sensors using broadband calibration techniques”, *Measurement Science and Technology*, v. 14, n. 7, pp. 903, 2003.
- [177] MONNIER, T., SEYDOU, D., GODIN, N., et al. “Primary calibration of acoustic emission sensors by the method of reciprocity, theoretical and experimental considerations”, *Journal of Acoustic Emission*, v. 30, pp. 152–166, 2012.
- [178] THEOBALD, P., ZEQRIRI, B., AVISON, J. “Couplants and Their Influence on AE Sensor Sensitivity”, *Journal of Acoustic Emission*, v. 26, pp. 91–97, 2008.
- [179] PAC. “R15I-UC Data Sheet”. 2016.
- [180] POISOT, T. “The digitize package: extracting numerical data from scatterplots”, *The R Journal*, v. 3, n. 1, pp. 25–26, 2011.
- [181] R CORE TEAM. *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, 2017. Disponível em: <<https://www.R-project.org/>>.
- [182] SUEUR, J., AUBIN, T., SIMONIS, C. “Seewave: a free modular tool for sound analysis and synthesis”, *Bioacoustics*, v. 18, pp. 213–226, 2008.

- [183] LIGGES, U., KREY, S., MERSMANN, O., et al. *Analysis of Music and Speech*, 2018. Disponível em: <<https://CRAN.R-project.org/package=tuneR>>. R package version 1.3.3.
- [184] RIPLEY, B., TIERNEY, L., URBANEK, S. *Support for Parallel computation in R*, 2018. Disponível em: <<https://CRAN.R-project.org/package=parallel>>. R package version 3.4.1.
- [185] MOSER, F., JACOBS, L. J., QU, J. “Application of Finite Element Methods to Study Transient Wave Propagation in Elastic Wave Guides”. In: Thompson, Donald O. and Chimenti, D. E. (Ed.), *Review of Progress in Quantitative Nondestructive Evaluation: Volume 17A*, pp. 161–167, Boston, Springer, 1998.
- [186] ALLEYNE, D. N., CAWLEY, P. “A 2-dimensional Fourier transform method for the quantitative measurement of Lamb modes”. In: *Ultrasonics Symposium*, pp. 1143–1146. IEEE, 1990.
- [187] COOLEY, J. W., TUKEY, J. W. “An algorithm for the machine calculation of complex Fourier series”, *Mathematics of Computation*, v. 19, n. 90, pp. 297–301, 1965. doi: 10.2307/2003354.
- [188] MORHÁČ, M., KLIMAN, J., MATOUŠEK, V., et al. “Identification of peaks in multidimensional coincidence γ -ray spectra”, *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 443, n. 1, pp. 108–125, 2000.
- [189] PAC. “PocketAE & Pocket AEwin User’s Manual”. 2007.
- [190] SIMAS FILHO, E., SEIXAS, J., CALÔBA, L. “Online neural filtering operating over segmented discriminating components”. pp. 530–533, Aug 2008. doi: 10.1109/ICECS.2008.4674907.
- [191] CIODARO, T., DEVA, D., DE SEIXAS, J., et al. “Online particle detection with neural networks based on topological calorimetry information”. In: *Journal of physics: conference series*, v. 368, p. 012030. IOP Publishing, 2012.
- [192] SEIXAS, J., CALÔBA, L. “Relevance criteria for variable selection in classifier design”. In: *International Conference on Engineering Applications of Neural Networks*, pp. 451–454, London, 1996.

- [193] SUNG, A. “Ranking importance of input parameters of neural networks”, *Expert Systems with Applications*, v. 15, n. 3, pp. 405 – 411, 1998. doi: 10.1016/S0957-4174(98)00041-4.
- [194] ÉVORA, L., SEIXAS, J., KRITSKI, A. “Neural Network Models for Supporting Drug and Multidrug Resistant Tuberculosis Screening Diagnosis”, *Neurocomputing*, v. 265, n. C, pp. 116–126, 2017. doi: 10.1016/j.neucom.2016.08.151.
- [195] HSU, C.-W., CHANG, C.-C., LIN, C.-J. *A practical guide to support vector classification*. Relatório técnico, National Taiwan University, 2010.
- [196] HOLLANDER, M., WOLFE, D. A. *Nonparametric Statistical Methods*. Hoboken, Wiley, 2014.
- [197] KUHN, M., WING, J., WESTON, S., et al. *caret: Classification and Regression Training*, 2018. Disponível em: <<https://CRAN.R-project.org/package=caret>>. R package version 6.0-81.
- [198] KARATZOGLOU, A., SMOLA, A., HORNIK, K., et al. “kernlab – An S4 Package for Kernel Methods in R”, *Journal of Statistical Software*, v. 11, n. 9, pp. 1–20, 2004. Disponível em: <<http://www.jstatsoft.org/v11/i09/>>.
- [199] RIDGEWAY, G. *Generalized Boosted Regression Models*, 2017. Disponível em: <<https://CRAN.R-project.org/package=gbm>>. R package version 2.1.3.
- [200] FLETCHER, R. *Practical Methods of Optimization*. 2 ed. New York, Wiley, 1987.
- [201] COLLURA, S., POSSANZINI, D., GUALERCI, M., et al. “Coal mill performances optimization through non-invasive online coal fineness monitoring”. In: *Powergen*, Vienna, Austria, 2013.
- [202] GAO, R. X., YAN, R. *Wavelets: Theory and Applications for Manufacturing*. New York, Springer, 2010. doi: 10.1007/978-1-4419-1545-0.
- [203] BERGSTRA, J., BENGIO, Y. “Random search for hyper-parameter optimization”, *Journal of Machine Learning Research*, v. 13, pp. 281–305, Feb. 2012.

Apêndice A

Caso de uso do pacote pongaR

O pacote `pongaR` simplifica o processo de simulação de sinais de EA gerados pelo impacto de partículas sólidas em uma estrutura. O pacote oferece funções em um *workflow* padronizado para a simulação de sinais de EA, tornando-a acessível a uma ampla gama de usuários, incluindo aqueles sem muito conhecimento da linguagem R. A maioria das funções permite a paralelização de tarefas, que distribui tarefas entre vários processadores para melhorar a eficiência computacional. Além disso, o pacote `pongaR`¹ podem ser utilizadas em um *workflow* para simular os sinais de EA gerados pelo impacto de uma partícula e permite a simulação de sinais de EA em um código aberto de forma simples, porém precisa, além de facilitar a pesquisa e inovação por usuários avançados através de um código bem comentado.

A seguir é apresentado um caso de uso mostrando como as funções do pacote `pongaR` podem ser utilizadas em um *workflow* para simular os sinais de EA gerados pelo impacto de uma partícula sólida em uma estrutura do tipo placa.

Para instalar o pacote `pongaR` a partir do repositório no GitHub e carregá-lo, inicie o R e digite:

```
install.packages("devtools")
library(devtools)
install_github("gmxavier/pongaR")
library(pongaR)
```

O *workflow* de simulação é especificado através da definição da fonte de excitação, da propagação e do detector. As funções `makePlate` e `makeSphere` invocadas sem nenhum parâmetro produzem, respectivamente, uma estrutura do tipo placa e uma partícula sólida esferoidal com dados *default*.

```
plate<-makePlate()
sphere<-makeSphere()
```

A fonte de excitação associada à partícula sólida esferoidal usando o modelo de Hertz (Equação 3.11) pode ser então produzida através da função `makeSource`:

```
sourceData<-makeSource(sourceModel=
"hertz",plate=plate,sphere=sphere)
```

na sequência, a função de transferência da propagação (Equação 3.44) pode ser produzida através da função `makeMedium`:

```
mediumData<-makeMedium(plate=plate,
excitabilityData="titaniumEF")
```

A informação principal para o modelo de propagação baseado na teoria das ondas de Lamb é a função de excitabilidade (WILCOX [154]), a qual pode ser obtida através dos seguintes passos:

```
makeDD(phaseData="titanium.txt",
density=4460,longVelocity=6060,
tranVelocity=3230)
makeEF(dispersionData="titaniumDD")
```

No primeiro passo, a função `makeDD` converte o arquivo texto gerado pelo programa `Disperse` (PAVLAKOVIC *et al.* [169]) contendo as curvas de dispersão de velocidade de fase. No segundo passo, a função `makeEF` processa as curvas de dispersão convertidas para produzir as funções de excitabilidade adimensionais de cada modo de onda de Lamb. A saída destas funções pode ser trabalhada de forma a gerar as Figuras A.1 e A.2, respectivamente.

A definição do detector completa a definição do *workflow* de simulação, mas para isto é necessária a curva de calibração do sensor em uma forma legível pelo código. O pacote `digitizeR` (POISOT [180]) pode ser usado para extrair interativamente os dados numéricos da curva de calibração do sensor a partir de uma imagem digitalizada². A função `makeFR` então processa estes dados numéricos da curva digitalizada como um arquivo separado por vírgulas e salva-os internamente para uso posterior.

²A imagem digitalizada da curva de calibração do sensor pode ser obtida da sua folha de dados disponível na página do fabricante na Internet ou simplesmente digitalizada a partir da cópia física enviada juntamente com o sensor, como aquelas mostradas na Figura ??.




Figura A.1: Curvas de dispersão analíticas dos primeiros três modos simétricos (S) e anti-simétricos (A) (placa de titânio, $d = 1$ mm).




Figura A.2: Funções de excitabilidade adimensionais dos primeiros três modos simétricos (S) e anti-simétricos (A) (placa de titânio, $d = 1$ mm, fonte de excitação pontual).

```
makeFR(sensorCalib="r15iuc.csv")
```

A partir dos dados do sensor, o detector pode ser definido através da função `makeReadout`:

```
readoutData<-makeReadout(sensorName=  
"r15iuc")
```

Finalmente, o sinal de EA correspondente ao impacto da partícula sólida com a placa pode ser simulado através da função `makeSignal`:

```
signalData<-makeSignal(sourceData=  
sourceData,mediumData=mediumData,  
readoutData=readoutData)
```

O objeto `signalData` produzido pode ser ainda processado para gerar a Figura A.3, a qual também mostra alguns parâmetros de EA básicos e derivados. A partir do sinal de EA simulado, todos os parâmetros das Tabelas 2.3 e 2.4 podem ser extraídos usando a função `getFeatures`.

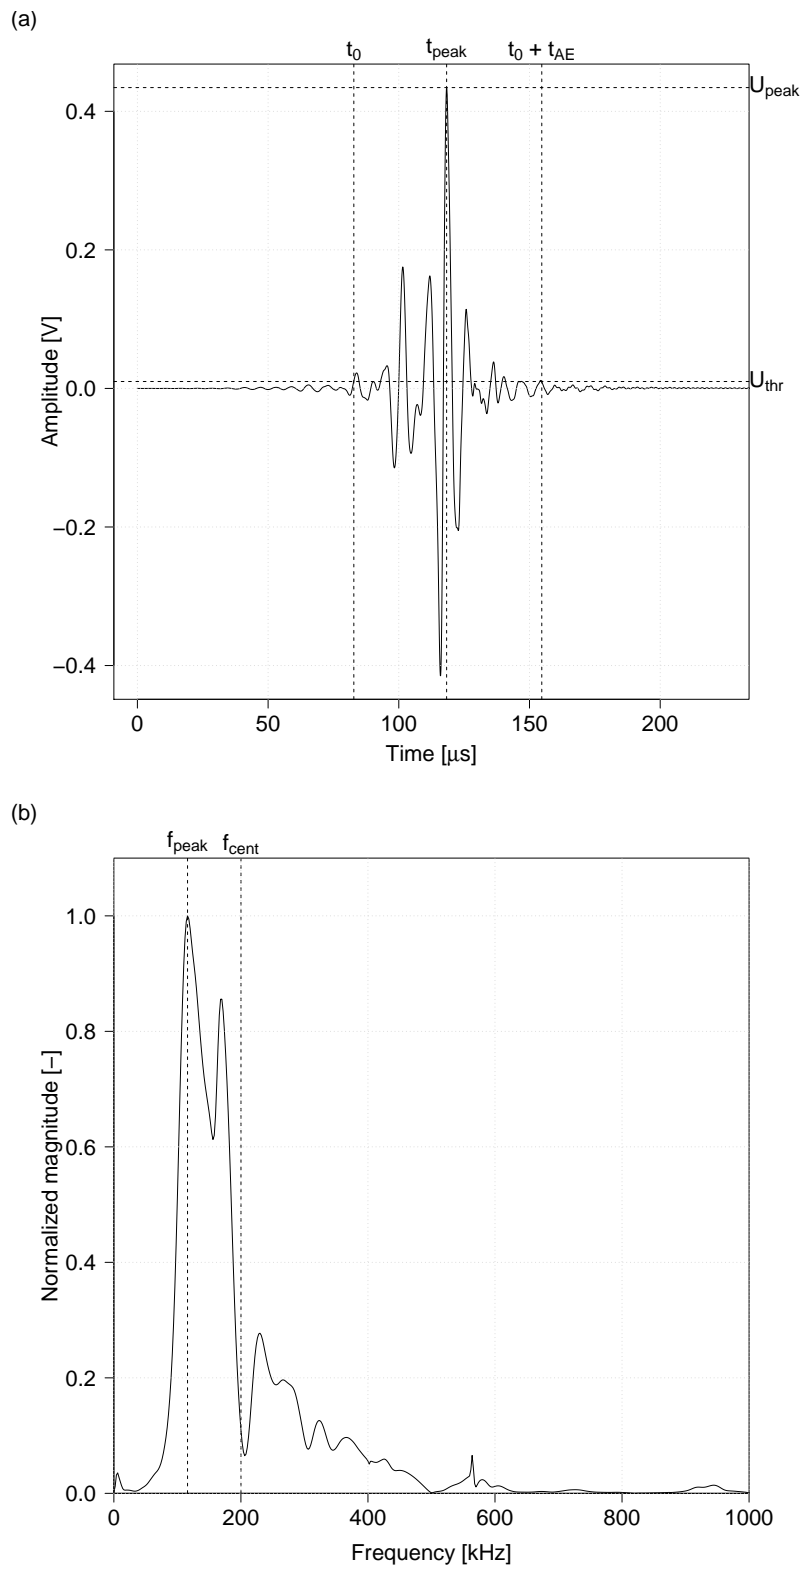


Figura A.3: Exemplo de um sinal de EA simulado (a) e seu espectro de frequência (b).

Apêndice B

Informação complementar

Parâmetro	Abreviatura	Domínio
Amplitude	amplitude	Tempo
Contagem	counts	Tempo
Duração	duration	Tempo
Tempo de subida	riseTime	Tempo
Valor quadrático médio	RMS	Tempo
Valor médio do sinal	ASL	Tempo
Frequência média	averageFreq	Tempo
Frequência de reverberação	reverbFreq	Tempo
Frequência inicial	initialFreq	Tempo
Ângulo de subida	riseAngle	Tempo
Ângulo de descida	decayAngle	Tempo
Energia absoluta	absoluteEnergy	Tempo
Frequência do pico	peakFreq	Frequência
Frequência centróide	centroidFreq	Frequência
Frequência ponderada	weightedFreq	Frequência
Potência parcial 1 $f_1 = 0$ kHz, $f_2 = 250$ kHz	pp1Freq	Frequência
Potência parcial 2 $f_1 = 250$ kHz, $f_2 = 500$ kHz	pp2Freq	Frequência
Potência parcial 3 $f_1 = 500$ kHz, $f_2 = 750$ kHz	pp3Freq	Frequência
Potência parcial 4 $f_1 = 750$ kHz, $f_2 = 1.000$ kHz	pp4Freq	Frequência

Tabela B.1: Codificação dos parâmetros derivados de EA.