

Universidade Estadual Paulista “Júlio de Mesquita Filho”  
Faculdade de Engenharia de Ilha Solteira  
Departamento de Engenharia Elétrica

“Classificação de sinais acústicos utilizando a transformada  
wavelet discreta e a decomposição de modo empírico: aplicações  
na área de alimentos”

Marcelo Moreira Tiago  
Engenheiro Eletricista

Ilha Solteira- SP  
Dezembro/2011

## PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

“Classificação de sinais acústicos utilizando a transformada wavelet discreta e a decomposição de modo empírico: aplicações na área de alimentos”

**Marcelo Moreira Tiago**

**Orientador:** Prof. Dr. Ricardo Tokio Higuti

Dissertação apresentada à Faculdade de Engenharia - UNESP - Campus de Ilha Solteira, para obtenção do título de Mestre em Engenharia Elétrica. Área de Conhecimento: Automação.

Ilha Solteira- SP  
Dezembro/2011

## FICHA CATALOGRÁFICA

Elaborada pela Seção Técnica de Aquisição e Tratamento da Informação  
Serviço Técnico de Biblioteca e Documentação da UNESP - Ilha Solteira.

Tiago, Marcelo Moreira

T551c      Classificação de sinais acústicos utilizando a transformada wavelet discreta e a decomposição de modo empírico: aplicações na área de alimentos / Marcelo Moreira  
Tiago . -- Ilha Solteira: [s.n.], 2011  
104 f.: il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2011

Orientador: Ricardo Tokio Higuti  
Inclui bibliografia

1. Transformada wavelet discreta. 2. Decomposição de modo empírico. 3. Classificação de sinais acústicos. 4. Wavelets (Matemática).



**UNIVERSIDADE ESTADUAL PAULISTA**  
CAMPUS DE ILHA SOLTEIRA  
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA

### **CERTIFICADO DE APROVAÇÃO**

**TÍTULO:** Classificação de sinais acústicos utilizando a transformada wavelet discreta e a decomposição de modo empírico: aplicações na área de alimentos

**AUTOR:** MARCELO MOREIRA TIAGO

**ORIENTADOR:** Prof. Dr. RICARDO TOKIO HIGUTI

Aprovado como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica ,  
Área: AUTOMAÇÃO, pela Comissão Examinadora:

Prof. Dr. RICARDO TOKIO HIGUTI

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

Prof. Dr. FRANCISCO VILLARREAL ALVARADO

Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira

Prof. Dr. WASHINGTON LUIZ BARROS MELO

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária

Data da realização: 07 de dezembro de 2011.

*“Onde há uma vontade forte, não pode haver grandes dificuldades.”*

**Nicolau Maquiavel**

## AGRADECIMENTOS

Agradeço a Deus, por prover tudo o que tenho necessitado ao longo desses anos e por cuidar de minha família durante minha ausência.

À minha família, que acreditou em mim quando nem eu mesmo acreditava e que lutou comigo durante todos esses anos.

À minha namorada Divane, por toda paciência e carinho ao longo desses anos.

Ao professor Tokio, por toda a credibilidade e paciência que tem me concedido desde o segundo ano da graduação.

Ao professor Villarreal, por toda a ajuda no estudo das wavelets. Obrigado Pancho!

Ao professor Kitano, que revisou detalhadamente o estudo especial que foi a base para o desenvolvimento desse trabalho.

Ao professor Aparecido, por contribuir com sugestões valiosas durante sua revisão do trabalho.

À INOVUS indústria de máquinas automáticas, por todo o apoio financeiro e tecnológico ao longo do desenvolvimento desse projeto.

Ao Engenheiro Everaldo por todos os ensinamentos, desafios propostos e momentos de descontração ao longo desses anos.

À Fundação CAPES, pelo apoio financeiro durante o desenvolvimento das atividades de mestrado.

*A mi director en Madrid, Óscar Martínez Graullera, por su fraternal acogida y su colaboración durante los meses de trabajo en CSIC. ¡Gracias Óscar!*

*A Fundación Carolina, por la beca que me ha permitido estudiar en Madrid.*

E por último, mas não menos importantes, aos amigos Aline, Galeti, Paula, Rodrigo, Vander e William, não só pelas contribuições para o trabalho, mas também por todo o companheirismo e momentos de descontração ao longo desses anos.

## RESUMO

Um dos setores de grande importância na indústria frigorífica é o responsável pelo esquartejamento de aves, no qual peças inteiras são separadas em partes menores para comercialização. O processo de esquartejamento pode ser feito de forma automática, através de máquinas de corte, ou por trabalhadores, que cortam as aves utilizando uma serra circular. Por ser um trabalho manual e envolver uma lâmina de corte, a periculosidade desse tipo de trabalho é alta, de maneira que mesmo com o uso de uma luva de aço inox como equipamento de proteção, costumam ocorrer acidentes que podem variar desde pequenos cortes até amputação de parte da mão do trabalhador atingido. Neste trabalho, é apresentado um método de análise de sinais para evitar que esse tipo de acidente ocorra. Esse sistema baseia-se na análise dos sinais acústicos envolvidos gerados durante esse processo e são utilizados para desligar o motor que impulsiona a serra e acionar um sistema de frenagem em casos quando houver a ocorrência de acidentes. O problema é abordado utilizando inicialmente um filtro digital e, posteriormente, com as técnicas de análise multirresolução apresentadas pelas wavelets. Além disso, empregou-se também a decomposição de modo empírico, que também realiza uma análise multirresolução dos sinais decompondo os mesmos em funções de modo intrínseco. Visando detectar o maior número possível de toques suaves de luva na serra sem que cortes de ossos de frango fossem confundidos com toques de luva, o sistema apresentou um índice de acertos de aproximadamente 70%, havendo a ocorrência de apenas 2% de falsos positivos. Além desse problema, abordou-se o caso de detecção de trinca em ovos, no qual o objetivo era separar ovos trincados de ovos inteiros utilizando um sistema barato e eficiente. Para tanto, utilizando uma solenoide como fonte de excitação mecânica, foram adquiridos os sinais gerados após pequenas pancadas de uma ponteira plástica em ovos e esses sinais foram utilizados como fonte de informação para o processo classificatório. As mesmas técnicas de processamento utilizadas para resolver o problema do esquartejamento de aves foram utilizadas para resolver o problema de classificação de ovos, bastando apenas efetuar pequenas adaptações nas mesmas. Utilizando a metodologia proposta, foi possível detectar aproximadamente 80% dos ovos trincados sem que ovos inteiros fossem erroneamente classificados como trincados.

**Palavras chaves:** Transformada wavelet discreta. Decomposição de modo empírico. Classificação de sinais acústicos.

## ABSTRACT

One of the most important sectors in the meatpacking industry is chicken quartering, where whole pieces are cut into smaller ones. The quartering process can be done by automatic machines or by manually cutting the chickens using a circular saw. The manual technique imposes physical risks for the workers, which wear protective stainless steel gloves. Small injuries or, in the worst case, amputation of part of the hand can occur in the event of an accident. In this work, we propose a methodology to prevent this type of accident, which is based on the analysis of the acoustic signals generated during this process. In the event of an accident, the saw touches the metal glove, the acoustic signals are processed and used to turn off the engine that drives the saw and trigger a braking system. The problem is firstly analyzed using a digital filter and then with multiresolution techniques by wavelet analysis. In addition, the empirical mode decomposition technique is also employed, which also performs multiresolution analysis of signals. These three techniques are implemented and compared. The method presented a 70% of successful detection of light touches of saw/glove and 2% of false positives, when a normal cut operation is detected as a saw/glove touch, in general occurring when cutting specific parts of bone. Besides this problem, the case of eggshell crack detection is studied, where the goal was to separate cracked eggs from intact eggs using an inexpensive and efficient system. A solenoid was used as a source of mechanical excitation and the resulting acoustic signals were acquired and processed. The same signal processing techniques were employed and compared, with small changes in parameters. As a result, it was possible to detect 80% of cracked eggs and 100% of intact eggs. The multiresolution technique using wavelets resulted in better results for both problems, in terms of detection of accidents/cracks and false positives.

**Keywords:** Discrete wavelet transform. Empirical mode decomposition. Acoustic signal classification.

## LISTA DE SÍMBOLOS

$\hat{a}_x$	Versor na direção $x$ .
$\hat{a}_y$	Versor na direção $y$ .
$\oplus$	Operador soma direta.
$\Phi(\omega)$	Transformada de Fourier da função $\phi(t)$ .
$\phi_{s,k}(t)$	Função de escala.
$\Psi(\omega)$	Transformada de Fourier da função $\psi(t)$ .
$\psi(t)$	Função de wavelet.
$\varepsilon$	Erro médio quadrático.
$\vec{F}$	Vetor $\vec{F}$ .
$\vec{V}_a$	Vetor $\vec{V}_a$ .
$\vec{V}_b$	Vetor $\vec{V}_b$ .
$\vec{V}_e$	Vetor de erro.
$c_n$	Constantes de aproximação.
$cA$	Coefficientes de aproximação.
$cD$	Coefficientes de detalhe.
$D(u, v)$	Transformada wavelet discreta de $d(t)$ .
$f_a(t)$	Função $f_a(t)$ .
$f_b(t)$	Função $f_b(t)$ .
$f_e(t)$	Função de erro.
$g_n(t)$	Funções ortogonais.
$k$	Índice de translação.
$k_{ab}$	Constante entre $[0, 1]$ .
$L^2\mathbb{R}$	Conjunto de funções quadraticamente integráveis de energia finita.
$N$	Número de pontos do sinal.

$s$	Fator de escala.
$t_1, t_2$	Instantes de tempo.
$u$	Fator de escala para sinais discretos.
$v$	Índice de translação para sinais discretos.
$V_s$	Subespaço.
$W(s, k)$	Transformada wavelet de $w(t)$ .
$W_s$	Subespaço.
$x_0$	Componente do vetor $\vec{F}$ na direção $x$ .
$y_0$	Componente do vetor $\vec{F}$ na direção $y$ .

## LISTA DE FIGURAS

1	Semelhança entre vetores. . . . .	21
2	Vetores no plano $xy$ . . . . .	24
3	Resposta em frequência dos filtros utilizados para análise multirresolução. . . . .	28
4	Banda de frequências entre $V_s$ e $V_{s-1}$ . . . . .	29
5	Composição do sinal $f(t)$ a partir dos subespaços $V_0$ e $V_{-1}$ . . . . .	30
6	Processo evolutivo da análise de sinais. . . . .	31
7	Formas de onda de um sinal senoidal e uma wavelet. . . . .	32
8	Família wavelet de Haar. . . . .	34
9	Família wavelet de Daubechies ( $db4$ ). . . . .	35
10	Família wavelet de symlets ( $sym3$ ). . . . .	36
11	Família wavelet de coiflets ( $coif3$ ). . . . .	37
12	Família wavelet bi-ortogonal ( $bior1.3$ ). . . . .	38
13	Resposta em frequência do banco de filtros da família bi-ortogonal ( $bior1.3$ ). . . . .	38
14	Família wavelet de Meyer. . . . .	40
15	Família wavelet de Haar. . . . .	40
16	Transformada de Fourier de uma wavelet. . . . .	42
17	Função wavelet $\psi(t)$ $db6$ . . . . .	42
18	Análise espectral das funções $\phi(t)$ e $\psi(t)$ . . . . .	43
19	Banco de filtros de análise. . . . .	46
20	Frequência de corte do banco de filtros da família $db4$ . . . . .	46
21	Banco de filtros de síntese. . . . .	47
22	Resposta em frequência de um banco de filtros. . . . .	48
23	Fluxograma do processo utilizado para o cálculo da EMD. . . . .	52
24	Procedimento para cálculo da EMD. . . . .	53
25	Decomposição de um sinal em IMFs. . . . .	54
26	Análise espectral das IMF's. . . . .	54

27	Trabalhador operando um sistema de esquartejamento de aves. . . . .	58
28	Luva utilizada durante o processo de esquartejamento de aves. . . . .	59
29	Equipamento utilizado durante o processo de esquartejamento de aves. . . . .	59
30	Resposta em frequência do microfone utilizado. . . . .	60
31	Sinais provenientes da operação de esquartejamento de aves. . . . .	61
32	Análise espectral dos sinais gerados durante o esquartejamento de aves - análise inicial. . . . .	62
33	Resposta em frequência do filtro utilizado para separar os sinais provenientes do esquartejamento de aves. . . . .	62
34	Energia dos sinais individuais. . . . .	63
35	Energia calculada a partir do sinal filtrado - análise inicial. . . . .	64
36	Energia calculada a partir do sinal filtrado - corte de ossos. . . . .	64
37	Análise espectral dos sinais gerados durante o esquartejamento de aves - corte de ossos. . . . .	65
38	Banco de filtros utilizado durante o processo de classificação. . . . .	66
39	Energia calculada a partir do resultado da DWT. . . . .	67
40	Energia calculada a partir do resultado da DWT - corte de ossos. . . . .	68
41	Energia calculada utilizando cinco decomposições. . . . .	70
42	Análise inicial utilizando IMFs. . . . .	72
43	Análise espectral dos sinais provenientes das IMFs. . . . .	73
44	Resposta em frequência dos filtro utilizados para separar os sinais a partir das IMFs. . . . .	74
45	Energia calculada a partir das IMFs. . . . .	76
46	Energia calculada a partir das IMFs - corte de ossos. . . . .	77
47	Equipamento utilizado durante o processo de classificação de ovos. . . . .	80
48	Solenoide utilizada para excitar mecanicamente os ovos. . . . .	80
49	Sinais característicos do processo de classificação de ovos. . . . .	81
50	Análise espectral dos sinais gerados durante o processo de classificação de ovos. . . . .	82
51	Resposta em frequência do filtro utilizado para classificar os ovos. . . . .	83

52	Energia dos sinais individuais - caso A. . . . .	83
53	Energia calculada a partir do sinal filtrado - caso A. . . . .	85
54	Energia calculada a partir do sinal filtrado - caso B. . . . .	86
55	Análise espectral dos sinais gerados durante o processo de classificação de ovos - caso B. . . . .	86
56	Energia dos sinais individuais - caso B. . . . .	87
57	Energia calculada a partir das decomposições - análise inicial. . . . .	88
58	Análise espectral da aproximação A3. . . . .	89
59	Resposta em frequência do filtro utilizado para separar os sinais da aproximação A3. . . . .	90
60	Energia calculada a partir das decomposições - caso A. . . . .	90
61	Energia calculada a partir das decomposições - caso B. . . . .	91
62	Resposta em frequência do filtro utilizado para separar os sinais da aproximação A2. . . . .	92
63	Energia calculada a partir das IMFs - caso A. . . . .	94
64	Energia calculada a partir das IMFs - caso B. . . . .	95

## LISTA DE TABELAS

1	Características do microfone utilizado. . . . .	60
2	Detecção com filtro passa-faixas. . . . .	65
3	Detecção de acidentes utilizando três decomposições. . . . .	69
4	Detecção de acidentes utilizando cinco decomposições. . . . .	71
5	Detecção de acidentes utilizando EMD. . . . .	75
6	Lógica utilizada para classificar ovos. . . . .	85
7	Resultado para ovos brancos - filtragem. . . . .	87
8	Resultado para ovos marrons - filtragem. . . . .	87
9	Lógica utilizada para classificar ovos. . . . .	89
10	Classificação de ovos brancos utilizando a DWT. . . . .	91
11	Classificação de ovos marrons utilizando a DWT. . . . .	92
12	Classificação de ovos brancos utilizando EMD. . . . .	95
13	Classificação de ovos marrons utilizando EMD. . . . .	96

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>16</b>
1.1	Revisão Bibliográfica	17
1.2	Objetivos	20
1.3	Organização do trabalho	20
<b>2</b>	<b>CONCEITOS MATEMÁTICOS</b>	<b>21</b>
2.1	Representações envolvendo vetores e sinais	21
2.2	Aproximação de uma função através de um conjunto de funções ortogonais	23
2.2.1	<i>Conjunto ortogonal de vetores</i>	23
2.2.2	<i>Representação de sinais através de um conjunto ortogonal de sinais</i>	25
2.3	Comentários	26
<b>3</b>	<b>TRANSFORMADA WAVELET</b>	<b>27</b>
3.1	Análise multirresolução	27
3.2	Representação de funções através de subespaços	28
3.3	Transformada wavelet contínua	31
3.4	Famílias de wavelets	33
3.4.1	<i>Família Haar</i>	34
3.4.2	<i>Família Daubechies</i>	35
3.4.3	<i>Família Symlets</i>	36
3.4.4	<i>Família Coiflets</i>	37
3.4.5	<i>Família Bi-ortogonal</i>	37
3.4.6	<i>Família Meyer</i>	39
3.5	Escalonamento e deslocamento da função wavelet	40
3.6	Procedimento para cálculo da transformada wavelet	41
3.7	Análise espectral de uma wavelet	41
3.8	Transformada wavelet discreta	43

<b>3.9</b>	<b>Implementação através de bancos de filtros . . . . .</b>	<b>45</b>
<b>3.10</b>	<b>Comentários . . . . .</b>	<b>49</b>
<b>4</b>	<b>DECOMPOSIÇÃO DE MODO EMPÍRICO . . . . .</b>	<b>50</b>
<b>4.1</b>	<b>Conceitos iniciais . . . . .</b>	<b>50</b>
<b>4.2</b>	<b>Procedimento para cálculo da EMD . . . . .</b>	<b>50</b>
<b>4.3</b>	<b>Algoritmo para o cálculo da EMD . . . . .</b>	<b>51</b>
<b>4.4</b>	<b>Características do processo de decomposição de modo empírico . . . . .</b>	<b>55</b>
<b>4.5</b>	<b>Interpretação das IMFs . . . . .</b>	<b>56</b>
<b>4.6</b>	<b>Comentários . . . . .</b>	<b>57</b>
<b>5</b>	<b>SISTEMA DE PROTEÇÃO CONTRA ACIDENTES DURANTE O ESQUARTEJA- MENTO DE AVES . . . . .</b>	<b>58</b>
<b>5.1</b>	<b>Descrição do problema . . . . .</b>	<b>58</b>
<b>5.2</b>	<b>Classificação dos sinais utilizando um filtro passa-faixas . . . . .</b>	<b>61</b>
<b>5.3</b>	<b>Classificação dos sinais utilizando a DWT . . . . .</b>	<b>66</b>
<b>5.4</b>	<b>Classificação dos sinais utilizando a EMD . . . . .</b>	<b>72</b>
<b>5.5</b>	<b>Comentários . . . . .</b>	<b>77</b>
<b>6</b>	<b>SISTEMA DE DETECÇÃO DE TRINCA EM OVOS . . . . .</b>	<b>79</b>
<b>6.1</b>	<b>Descrição do problema . . . . .</b>	<b>79</b>
<b>6.2</b>	<b>Classificação dos sinais utilizando um filtro passa-faixas . . . . .</b>	<b>82</b>
<b>6.3</b>	<b>Classificação dos sinais utilizando a DWT . . . . .</b>	<b>88</b>
<b>6.4</b>	<b>Classificação dos sinais utilizando a EMD . . . . .</b>	<b>93</b>
<b>6.5</b>	<b>Comentários . . . . .</b>	<b>96</b>
<b>7</b>	<b>CONCLUSÕES . . . . .</b>	<b>98</b>
<b>7.1</b>	<b>Trabalhos Futuros . . . . .</b>	<b>99</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>100</b>

# 1 INTRODUÇÃO

Na indústria frigorífica, um dos grandes desafios para as equipes responsáveis pela engenharia de segurança está relacionada ao processo de esquartejamento de aves. Esse processo, em alguns casos, é feito utilizando máquinas automáticas, o que reduz o risco de acidentes. Porém, parte dos frigoríficos prefere manter trabalhadores para a realização desse processo. Essa opção é feita devido à sensibilidade do operador, que é capaz de se adaptar aos vários tamanhos e pesos das aves que serão esquartejadas, algo que não ocorre com as máquinas automáticas, que apresentam restrições com relação ao peso e ao tamanho das aves.

Esse trabalho é feito utilizando uma serra circular, capaz de cortar desde partes de carne até os ossos mais grossos das aves. Como forma de proteção, utiliza-se apenas uma luva de aço-inoxidável. Essa luva, em caso de acidentes, não apresenta resistência suficiente para evitar que parte da mão do trabalhador envolvido seja cortada ou até mesmo amputada, dependendo da forma que esse acidente ocorra.

Dessa forma, surge a necessidade de se desenvolver um equipamento de proteção capaz de acionar um dispositivo de frenagem nos instantes em que houver um toque acidental entre a luva e a serra, evitando assim a ocorrência de acidentes.

A partir das informações contidas nos sons gerados durante o processo de esquartejamento, a proposta deste trabalho é a de caracterizar os eventos em função do som gerado. Dessa forma, pretende-se diferenciar o som gerado pelo corte de aves daquele gerado por um toque acidental de luva na serra, de tal forma que caso ocorra um toque de luva, o motor utilizado para impulsionar a serra seja desligado e um sistema de frenagem seja acionado num tempo rápido o suficiente para evitar que a luva seja cortada e, por conseguinte, que a mão do trabalhador seja atingida.

Para tanto, utilizou-se um sistema de aquisição baseado num microfone de eletreto e numa placa de som de um microcomputador. Os sinais adquiridos através desse sistema foram utilizados como base para uma etapa posterior de processamento, onde foram testadas várias técnicas com o intuito de se detectar a ocorrência de acidentes sem que eventuais cortes de aves fossem erroneamente classificados como toques de luva (falsos positivos).

Outro desafio enfrentado pela indústria alimentícia diz respeito à classificação de ovos, no qual ovos trincados devem ser separados de ovos inteiros. Trata-se de um problema já abordado por algumas empresas do setor avícola, que desenvolveram máquinas automáticas utilizadas por grandes produtores para a separação dos ovos.

O problema é que estas máquinas não são fabricadas no Brasil e, conseqüentemente, apresentam um custo muito elevado, limitando o acesso das mesmas aos grandes produtores. Como

solução, os pequenos produtores utilizam trabalhadores para a realização dessa classificação. Para tanto, um sistema de iluminação é colocado abaixo de uma esteira mecânica utilizada para transportar os ovos. Os ovos, postos contra a luz, são observados por estes trabalhadores, que com uma garra retiram aqueles que apresentam trincas. A eficiência desse tipo de sistema passa a depender da habilidade do operador de identificar ou não os ovos trincados, de forma que distrações durante o processo podem resultar em baixos índices de aproveitamento.

Dessa forma, é proposta a análise da viabilidade de um sistema de classificação de ovos de baixo custo baseado na detecção de parâmetros provenientes de sinais acústicos obtidos a partir de um sistema de excitação mecânico.

Para esse trabalho, utilizou-se um sistema mecânico constituído por uma solenoide e uma ponteira plástica responsável por produzir uma excitação mecânica nos ovos avaliados. Sendo assim, a partir do som gerado por essas pancadas e utilizando técnicas de processamento de sinais, o sistema classifica os ovos como inteiros ou trincados.

No decorrer do trabalho são descritos com mais detalhes os problemas abordados, bem como as soluções propostas para cada caso.

## 1.1 Revisão Bibliográfica

A classificação de materiais é uma tarefa de grande importância na indústria. Essa classificação pode ser algo simples como, por exemplo, separar materiais em função de seu peso, ou pode ser algo mais complicado como, por exemplo, distinguir ovos trincados de ovos em bom estado, como proposto por Eissa (2009).

Uma das técnicas empregadas para caracterizar materiais é a do impacto acústico, que utiliza o som gerado por uma excitação mecânica para classificar os mesmos. Dentre os exemplos de utilização dessa técnica para classificar materiais, pode-se citar a classificação de peras em relação ao seu grau de rigidez, conforme proposto por Gomez, Wang e Pereira (2005).

Há ainda casos nos quais é avaliado o grau de maturação de frutas. Um exemplo é a técnica da avaliação da consistência de tomates estocados em depósitos, que foi proposta por Schotte, Belie e Baerdemaeker (1999) e também por Mizrach (2007).

A mesma ideia foi utilizada por Diezma-Iglesias, Ruiz-Altisent e Barreiro (2004) para avaliar a qualidade interna de melancias sem sementes, e também por Yamamoto, Iwamoto e Haginuma (1980) para avaliar a qualidade da região interna de melancias e maçãs.

No trabalho apresentado por Conde et al. (2008), utilizou-se essa técnica para detectar trincas na região interna de queijos do tipo Manchego. A ideia também é aplicável na área da construção civil, como apresentado por Ito e Uomoto (1997), que utilizaram a técnica do impacto acústico para avaliar a qualidade de vigas de concreto.

Durante o processo de análise através do impacto acústico, o som produzido pelo impacto mecânico é capturado utilizando um microfone e um sistema de aquisição de dados. Esses dados, por sua vez, são processados a fim de se extrair a informação desejada.

Um dos meios para se classificar os sinais é através da análise de Fourier, como proposto por Wang, Jiang e Yu (2004), que utilizaram essa técnica de processamento para analisar as propriedades físicas de ovos.

A mesma técnica foi empregada por Eissa (2009), que a utilizou para classificar ovos como bons ou trincados de acordo com o som gerado durante o impacto de um pequeno martelo plástico; e também por Conde et al. (2008), que a utilizaram para detectar trincas no interior de queijos do tipo Manchego.

Nesse método, inicialmente realiza-se uma análise espectral a fim de se localizar regiões do espectro capazes de distinguir sinais provenientes de materiais com características físicas diferentes. Posteriormente, utilizam-se filtros digitais com faixa de passagem localizada na região do espectro onde os sinais são separáveis, de tal forma que seja possível classificar os materiais através da análise do som proveniente do impacto acústico.

Outro método baseia-se na análise multirresolução proporcionada pela transformada wavelet discreta - DWT (do inglês, *Discrete Wavelet Transform*). Essa foi a técnica proposta por Seki, Shin e Tabaru (2004) para se extrair características relacionadas à qualidade de pneus.

O mesmo método foi utilizado por Luk et al. (2010) para inspecionar a qualidade da fixação de azulejos em paredes. Já no trabalho proposto por Istrate et al. (2006), utilizou-se essa técnica para extrair características de sinais acústicos do ambiente a fim de realizar uma telemonitoração, identificando-se possíveis complicações médicas de um paciente em tratamento residencial em função dos sons que o mesmo produz ao longo de suas atividades diárias.

No método proposto pela DWT, o sinal é decomposto em coeficientes de aproximação e detalhes. Trata-se de uma decomposição multi-nível, ou seja, são gerados coeficientes diferentes para cada um dos níveis de decomposição utilizado. A ideia é decompor o sinal utilizando famílias de wavelets, de modo que seja possível extrair características suficientes para distinguir sinais.

No trabalho apresentado por Javidan (2010), a transformada wavelet é utilizada para classificar sinais adquiridos utilizando um sonar, com o objetivo de determinar as características do leito dos mares. Já o trabalho proposto por Averbuch et al. (2009) utiliza a transformada wavelet para detectar a chegada de veículos através do som gerado pelos mesmos, de forma que o som gerado pelos carros possa ser separado dos demais sons presentes no ambiente.

O trabalho apresentado por Wang et al. (2008) propõe a utilização da transformada wavelet para a extração de características de sinais acústicos. Essa técnica também foi utilizada por

Degang, Kai e Haifeng (2007), que utilizaram a técnica para extrair informações provenientes dos sons gerados por tanques, helicópteros e caminhões a fim de identificar os mesmos.

Essa técnica também foi utilizada por He, Wang e Wu (2010) para detectar possíveis problemas em sistemas mecânicos a partir do som gerado durante seu funcionamento. Ademais, trabalhos como o proposto por Kumar et al. (2007) e por Zin et al. (2003) utilizaram a decomposição wavelet para extrair informações de sinais referentes a exames de eletrocardiograma.

Um terceiro e relativamente novo método faz uso da chamada decomposição de modo empírico - EMD (do inglês, *Empirical Mode Decomposition*). O mesmo método foi utilizado por Zhidong, Zhijin e Yuquan (2005) para analisar as características dos sons gerados ao longo do processo de batimento cardíaco e por Yang e Tang (2008) para extrair informações provenientes de exames de eletrocardiograma. Essa técnica foi apresentada por Huang et al. (1998) e baseia-se numa decomposição empírica do sinal original em um conjunto de funções denominadas funções de modo intrínseco - IMF (do inglês, *Intrinsic Mode Function*).

O algoritmo utilizado para realizar essa decomposição é apresentado por Zeiler et al. (2010), que descreve de forma geral os conceitos introdutórios necessários para se iniciar o estudo dessa técnica, exemplificando seu uso com algumas aplicações, tais como extração de ruído e separação de sinais. Já o trabalho apresentado por Zheng, Yi-lin e Ping (2010) apresenta uma variação desse algoritmo, que adapta algumas partes do mesmo para aumentar seu desempenho durante a análise de sinais acústicos.

Por ser um método empírico, ele permite que as bases utilizadas para decompor o sinal sejam estabelecidas em função do próprio sinal, permitindo assim uma avaliação mais minuciosa de características que possivelmente não seriam detectadas utilizando um conjunto de bases pré-estabelecidas.

Essa técnica foi utilizada por Li et al. (2008) para separar um sinal acústico e suas interferências em diferentes funções de modo intrínseco. A mesma técnica foi utilizada por Hu et al. (2008), onde a decomposição de modo empírico foi utilizada como ferramenta para detectar a presença de veículos submarinos.

O método da decomposição empírica também tem sido muito utilizado em aplicações médicas. É o caso do trabalho proposto por Boutana, Benidir e Barkat (2010), que utiliza a técnica para separar sinais cardíacos gerados pela pulsação das válvulas e pelo miocárdio, e do trabalho proposto por Arafat e Hasan (2009), que utiliza a técnica da decomposição de modo empírico para extrair características de sinais cardíacos do tipo complexo QRS.

Ha ainda outros casos, como por exemplo o apresentado por Charleston-Villalobos, Aljama-Corrales e Gonzalez-Camarena (2006), nos quais essa técnica é utilizada para realizar a análise de sons pulmonares para detectar sinais que podem ou não ser indicadores de complicações médicas.

## 1.2 Objetivos

O objetivo deste trabalho é desenvolver técnicas de classificação de sinais acústicos que possam ser utilizadas na indústria de alimentos, analisando o desempenho destas quando aplicadas à dois problemas de grande importância industrial: a detecção de trinca em ovos e a proteção de trabalhadores durante o processo de esquartejamento de aves.

## 1.3 Organização do trabalho

No capítulo 2 são apresentados os conceitos matemáticos utilizados no processo de representação de sinais através de uma base ortogonal, de modo que o valor do erro gerado ao relacionar o sinal à sua representação seja o menor possível.

O capítulo 3 apresenta uma introdução à transformada wavelet e sua versão discreta, abordando desde as principais famílias de wavelets até as técnicas de implementação dessa técnica.

No capítulo 4, é apresentada a técnica da decomposição de modo empírico, que propõe a decomposição de um sinal através de uma base gerada empiricamente.

O capítulo 5 descreve o problema enfrentado durante o processo de esquartejamento de aves, apresentado as metodologias propostas e os resultados obtidos durante essa análise.

Já o capítulo 6 apresenta o problema da classificação de ovos, onde a proposta é a de separar os ovos inteiros dos ovos trincados. São descritas as características do processo e as técnicas utilizadas ao longo de sua abordagem.

Por fim, as conclusões e comentários finais são apresentados no capítulo 7.

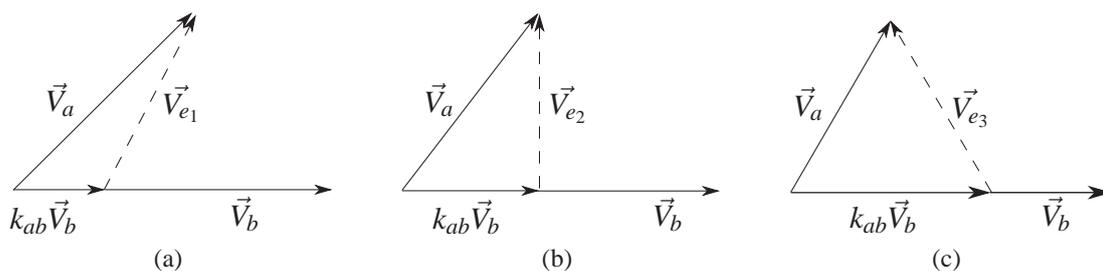
## 2 CONCEITOS MATEMÁTICOS

Neste capítulo serão apresentados algumas notações e resultados matemáticos necessários para o estudo da transformada wavelet e da decomposição de modo empírico. Os conceitos serão abordados de maneira sucinta, tendo como objetivo descrever as ferramentas utilizadas para se realizar a análise multirresolução de sinais.

### 2.1 Representações envolvendo vetores e sinais

Uma das maneiras de se representar sinais variáveis no tempo é através de uma analogia envolvendo a representação de vetores no espaço físico e suas projeções. A Figura 1 apresenta dois vetores,  $\vec{V}_a$  e  $\vec{V}_b$  e um vetor de erro  $\vec{V}_e$ , que se relacionam conforme a equação (1) (LATHI, 1987).

Figura 1 - Semelhança entre vetores.



Fonte: Adaptado de Lathi (1987).

$$\vec{V}_a = k_{ab}\vec{V}_b + \vec{V}_e, \quad (1)$$

sendo  $k_{ab}$  uma constante entre  $[0, 1]$ .

Da Figura 1, nota-se que a constante  $k_{ab}\vec{V}_b$  corresponde à componente de  $\vec{V}_a$  na direção  $\vec{V}_b$ . Em cada uma das representações, o vetor  $\vec{V}_a$  é representado em termos do vetor  $k_{ab}\vec{V}_b$  mais um outro vetor, chamado de vetor erro.

Por inspeção, é possível notar que o vetor  $\vec{V}_e$  é mínimo na Figura 1(b), quando  $k_{ab}\vec{V}_b$  representa a projeção ortogonal de  $\vec{V}_a$  na direção  $\vec{V}_b$ . Dessa forma, a escolha da constante  $k_{ab}$  deve ser feita de modo a garantir o menor comprimento possível do vetor de erro  $\vec{V}_e$ , garantindo dessa forma uma melhor representação.

Quanto maior a componente de um vetor na direção do outro, menor será o vetor de erro. Devido a isso, a constante  $k_{ab}$  pode ser vista como um índice de semelhança entre os vetores

de  $\vec{V}_a$  e  $\vec{V}_b$ . Essa relação é mostrada a partir da definição do produto escalar entre dois vetores, conforme apresenta a equação (2) (LATHI, 1987):

$$k_{ab} = \frac{\vec{V}_a \cdot \vec{V}_b}{\|\vec{V}_b\|^2} = \frac{\vec{V}_a \cdot \vec{V}_b}{\vec{V}_b \cdot \vec{V}_b}, \quad (2)$$

sendo  $\vec{V}_a \cdot \vec{V}_b$  o produto escalar dos vetores  $\vec{V}_a$  e  $\vec{V}_b$ ; e  $\|\vec{V}_b\|^2$  a norma do vetor  $\vec{V}_b$ .

Verifica-se que o fator  $k_{ab} = 0$  indica que os vetores  $\vec{V}_a$  e  $\vec{V}_b$  são perpendiculares entre si, ou seja, não há componentes de  $\vec{V}_a$  na direção de  $\vec{V}_b$ . Esses vetores são chamados de vetores ortogonais e têm como principal característica serem independentes um do outro.

Esse mesmo conceito pode ser utilizado para a análise de sinais, sendo um sinal uma função do tempo. Dessa forma, usando um produto escalar, é possível determinar o grau de semelhança entre duas funções  $f_a(t)$  e  $f_b(t)$  através de um fator  $k_{ab}$  de maneira análoga à proposta pela equação (1).

Para tanto, consideram-se duas funções  $f_a(t)$  e  $f_b(t)$  sobre as quais deseja-se estabelecer o grau de semelhança através de um fator  $k_{ab}$  num determinado intervalo ( $t_1 \leq t \leq t_2$ ,  $t_1 < t_2$ ), de forma que se possa estabelecer a relação  $f_a \cong k_{ab}f_b$ .

Essa representação exige que a constante  $k_{ab}$  seja escolhida de tal forma que a o erro entre a função original e a função aproximada seja o menor possível no intervalo ( $t_1 \leq t \leq t_2$ ). O erro entre a função original e sua representação pode ser expressado através da função de erro  $f_e(t)$ , conforme apresentado na equação (3) (LATHI, 1987):

$$f_e(t) = f_a(t) - k_{ab}f_b(t). \quad (3)$$

Uma das formas de se minimizar a função erro é através da minimização da função de erro médio quadrático  $\varepsilon : \mathbb{R} \rightarrow \mathbb{R}$ , conforme definido pela equação (4):

$$\varepsilon(k_{ab}) = \frac{1}{t_2 - t_1} \int_{t_1}^{t_2} f_e^2(t) dt. \quad (4)$$

Sendo assim, é necessário estabelecer um valor de  $k_{ab}$  capaz de satisfazer a condição definida na equação (5):

$$\frac{d\varepsilon}{dk_{ab}} = 0. \quad (5)$$

Relacionando as equações (3), (4) e (5), obtém-se a equação (6):

$$\frac{1}{t_2 - t_1} \left[ \int_{t_1}^{t_2} \frac{d}{dk_{ab}} f_a^2(t) dt - 2 \int_{t_1}^{t_2} f_a(t) f_b(t) dt + 2k_{ab} \int_{t_1}^{t_2} f_b^2(t) dt \right] = 0. \quad (6)$$

Da equação (6), nota-se que  $f_a(t)$  não depende da constante  $k_{ab}$ , de maneira que a primeira integral dessa equação é nula. Rearranjando a equação (6), obtém-se a equação (7):

$$k_{ab} = \frac{\int_{t_1}^{t_2} f_a(t) f_b(t) dt}{\int_{t_1}^{t_2} f_b^2(t) dt}. \quad (7)$$

Nota-se que há uma semelhança entre a equação (2) para vetores e a equação (7) para sinais. Fazendo uma analogia com vetores, tem-se que o sinal  $k_{ab} f_b(t)$  representa a componente do sinal  $f_a(t)$  na direção do sinal  $f_b(t)$ . Se  $k_{ab} = 0$ , então o sinal  $f_a(t)$  não contém nenhum componente do sinal  $f_b(t)$ , ou seja, os dois sinais são ortogonais no intervalo  $(t_1, t_2)$  (LATHI, 1987).

## 2.2 Aproximação de uma função através de um conjunto de funções ortogonais

Nessa seção será abordada a expansão de trechos de funções em séries de funções ortogonais, fazendo, para tanto, uma analogia entre vetores e sinais.

### 2.2.1 Conjunto ortogonal de vetores

Um vetor  $\vec{F}$  num plano  $xy$ , com versores  $\hat{a}_x$  e  $\hat{a}_y$ , pode ser representado em função de suas componentes  $x_0$  e  $y_0$ , conforme apresentado na equação (8) (LATHI, 1987):

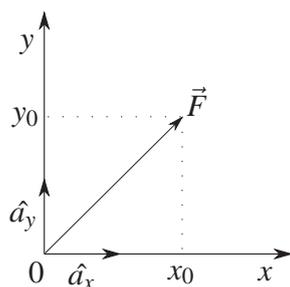
$$\vec{F} = x_0 \hat{a}_x + y_0 \hat{a}_y. \quad (8)$$

A Figura 2 apresenta um vetor  $\vec{F}$  num plano  $xy$ . Nota-se que os versores são ortogonais entre si, ou seja, o produto escalar  $\hat{a}_x \hat{a}_y = 0$  para  $x \neq y$ .

Generalizando esta ideia e considerando um espaço de dimensão  $n$ , a representação de um vetor  $\vec{F}$  exigiria um conjunto de  $n$  vetores ortogonais entre si  $\vec{x}_1 \dots \vec{x}_n$ . A equação (9) ilustra a representação do vetor  $\vec{F}$ :

$$\vec{F} = c_1 \hat{x}_1 + c_2 \hat{x}_2 + \dots + c_n \hat{x}_n. \quad (9)$$

Devido à condição de ortogonalidade, o produto escalar entre dois vetores  $\hat{x}_r$  e  $\hat{x}_p$ ,  $r \neq p$ , deve ser zero e o produto escalar de qualquer vetor com ele mesmo tem de resultar num escalar

Figura 2 - Vetores no plano  $xy$ .

Fonte: Adaptado de Lathi (1987).

não nulo. Da equação (9), têm-se que  $c_1, \dots, c_n$  representam as magnitudes das componentes do vetor  $\vec{F}$  nas direções dos vetores  $\hat{x}_1, \dots, \hat{x}_n$  (LATHI, 1987).

Calculando-se o produto escalar entre os dois membros da equação (9) com um vetor  $\hat{x}_r$ , chega-se à equação (10):

$$\vec{F} \cdot \hat{x}_r = c_1 \hat{x}_1 \cdot \hat{x}_r + c_2 \hat{x}_2 \cdot \hat{x}_r + \dots + c_n \hat{x}_n \cdot \hat{x}_r. \quad (10)$$

Da equação (10), têm-se que todos os termos na forma  $c_j \hat{x}_j \cdot \hat{x}_r$  para os quais  $j \neq r$  são nulos (condição de ortogonalidade). Fazendo as simplificações, chega-se na equação (11):

$$\vec{F} \cdot \hat{x}_r = c_r \hat{x}_r \cdot \hat{x}_r = c_r. \quad (11)$$

O conjunto de vetores  $\hat{x}_1, \hat{x}_2, \dots, \hat{x}_n$  é chamado de conjunto ortogonal. Em geral, o produto  $\hat{x}_m \cdot \hat{x}_r$  pode assumir um valor indicado por  $k_m$ , conforme é apresentado na equação (12):

$$\hat{x}_m \cdot \hat{x}_r = \begin{cases} 0, & m \neq r \\ k_m, & m = r \end{cases}. \quad (12)$$

Quando  $k_m$  é igual a unidade, o conjunto recebe o nome de conjunto ortonormal. Re-arranjando a equação (11), obtém-se a equação (13), que permite calcular as constantes que representam as magnitudes do vetor  $\vec{F}$  nas direções dos vetores envolvidos:

$$c_r = \frac{\vec{F} \cdot \hat{x}_r}{\hat{x}_r \cdot \hat{x}_r}. \quad (13)$$

Desta forma:

$$\vec{F} = \frac{\vec{F} \cdot \hat{x}_1}{\hat{x}_1 \cdot \hat{x}_1} \hat{x}_1 + \frac{\vec{F} \cdot \hat{x}_2}{\hat{x}_2 \cdot \hat{x}_2} \hat{x}_2 + \dots + \frac{\vec{F} \cdot \hat{x}_n}{\hat{x}_n \cdot \hat{x}_n} \hat{x}_n. \quad (14)$$

### 2.2.2 Representação de sinais através de um conjunto ortogonal de sinais

Considere-se um conjunto de  $n$  funções  $g_1(t), g_2(t), \dots, g_n(t)$  definidas num intervalo ( $t_1 < t < t_2$ ) e ortogonais entre si, conforme apresenta a equação (15):

$$\int_{t_1}^{t_2} g_j(t)g_k(t)dt = 0 \quad j \neq k. \quad (15)$$

Considere-se também a relação proposta pela equação (16):

$$\int_{t_1}^{t_2} g_j^2(t)dt = k_j \neq 0. \quad (16)$$

Uma função qualquer  $f(t)$ , definida e contínua num intervalo ( $t_1, t_2$ ), pode ser representada pela combinação linear de  $n$  funções ortogonais entre si  $g_1(t), g_2(t), \dots, g_n(t)$ , ( $t_1 < t < t_2$ ), conforme apresentado na equação (17) (LATHI, 1987):

$$f(t) \cong c_1g_1(t) + c_2g_2(t) + \dots + c_n g_n(t) = \sum_{j=1}^n c_j g_j(t). \quad (17)$$

Para um melhor resultado nas aproximações, é preciso encontrar valores apropriados para as constantes  $c_1, c_2, \dots, c_n$  de modo a minimizar o erro médio quadrático  $\varepsilon$ . Dessa forma, considere-se a função de erro  $f_e(t)$  definida em ( $t_1, t_2$ ) pela equação (18):

$$f_e(t) = f(t) - \sum_{j=1}^n c_j g_j(t). \quad (18)$$

A partir da equação (4) e utilizando a expressão apresentada em (18), é possível calcular o valor do erro médio quadrático  $\varepsilon : \mathbb{R}_n \rightarrow \mathbb{R}$ , conforme apresenta a equação (19) (LATHI, 1987):

$$\varepsilon(c_1, \dots, c_n) = \frac{1}{t_2 - t_1} \int_{t_1}^{t_2} \left[ f(t) - \sum_{j=1}^n c_j g_j(t) \right]^2 dt. \quad (19)$$

Observando o resultado apresentado em (19), fica claro que  $\varepsilon$  é função de  $c_1, c_2, \dots, c_n$  e que, para minimizar  $\varepsilon$ , é necessário que:

$$\frac{\partial \varepsilon}{\partial c_1} = \frac{\partial \varepsilon}{\partial c_2} = \dots = \frac{\partial \varepsilon}{\partial c_j} = \dots = \frac{\partial \varepsilon}{\partial c_n} = 0. \quad (20)$$

Considere-se a equação (21):

$$\frac{\partial \varepsilon}{\partial c_j} = 0. \quad (21)$$

Admitindo que o intervalo  $(t_1, t_2)$  é dado, a equação (21) pode ser reescrita conforme apresentado em (22):

$$\frac{\partial}{\partial c_j} \left\{ \int_{t_1}^{t_2} \left[ f(t) - \sum_{j=1}^n c_j g_j(t) \right]^2 dt \right\} = 0. \quad (22)$$

Ao expandir o integrando, nota-se que os termos resultantes de produto cruzado do tipo  $\int g_j(t)g_k(t)dt$  são zero devido à ortogonalidade. Ademais, a derivada de todos os termos que não contém  $c_j$  em relação à  $c_j$  também é nula. O resultado dessa simplificação é apresentado na equação (23):

$$2 \int_{t_1}^{t_2} f(t)g_j(t)dt = 2c_j(t) \int_{t_1}^{t_2} g_j^2(t)dt. \quad (23)$$

Dessa forma, é possível calcular as constantes que representam as amplitudes da função  $f(t)$  na direção das funções  $g_1(t), g_2(t), \dots, g_n(t)$  através da relação apresentada na equação (24):

$$c_j = \frac{\int_{t_1}^{t_2} f(t)g_j(t)dt}{\int_{t_1}^{t_2} g_j^2(t)dt} = \frac{1}{k_j} \int_{t_1}^{t_2} f(t)g_j(t)dt. \quad (24)$$

Esse resultado indica que, dado um conjunto de  $n$  funções ortogonais entre si num intervalo  $(t_1, t_2)$ , é possível representar uma função arbitrária  $f(t)$  nesse intervalo através da combinação linear das funções ortogonais entre si, conforme (17) (LATHI, 1987).

## 2.3 Comentários

Neste capítulo, foram introduzidos os conceitos necessários para se representar uma função qualquer através de um conjunto de  $n$  funções ortogonais entre si ponderadas através de constantes de aproximação. Ademais, foram abordados os critérios utilizados para se definir essas constantes de aproximação, buscando assim garantir que o erro resultante da representação de um sinal por intermédio de um conjunto de funções ortogonais seja o menor possível. Este tema será abordado nos capítulos 3 e 4, onde serão apresentados os critérios utilizados para se realizar a análise multirresolução de sinais através da transformada wavelet discreta e da decomposição de modo empírico.

## 3 TRANSFORMADA WAVELET

Neste capítulo será feita uma introdução sobre a transformada wavelet. Para tanto, serão abordados os princípios da análise multirresolução, uma introdução à transformada wavelet contínua e, finalizando, a abordagem proposta por Mallat e Daubechies para a utilização da transformada wavelet discreta através de bancos de filtros.

A abordagem será voltada às aplicações relacionadas ao processamento digital de sinais, não havendo portanto uma abordagem matemática mais detalhada. Entretanto, uma análise matemática mais completa pode ser encontrada em (DAUBECHIES, 1992).

### 3.1 Análise multirresolução

Escalas são frequentemente utilizadas para representar elementos da natureza. Essa prática é utilizada em mapas e desenhos técnicos mecânicos por exemplo, permitindo que sejam analisadas desde as características mais grosseiras até os mais específicos detalhes.

A representação matemática dessas escalas é o objetivo de estudo da análise multirresolução, que nada mais é do que uma técnica que visa formalizar as variações de escala para que a representação das características dos elementos físicos seja feita da melhor forma possível.

É possível relacionar esse conceito de escala ao conceito da frequência de amostragem baseando-se no critério proposto por Nyquist, que estabelece que um sinal cuja frequência máxima é  $f_a$  deve ser amostrado a uma frequência mínima  $f_s = 2f_a$ . Isto pois, para se representar um sinal de frequência máxima de  $f_a = 1kHz$ , utiliza-se uma frequência de amostragem diferente da que é utilizada para se representar um sinal cuja frequência máxima é  $f_a = 100kHz$ , ou seja, é necessário alterar a “escala” que será utilizada para representar um sinal de acordo com suas características (GOMES; VELHO; GOLDENSTEIN, 1997).

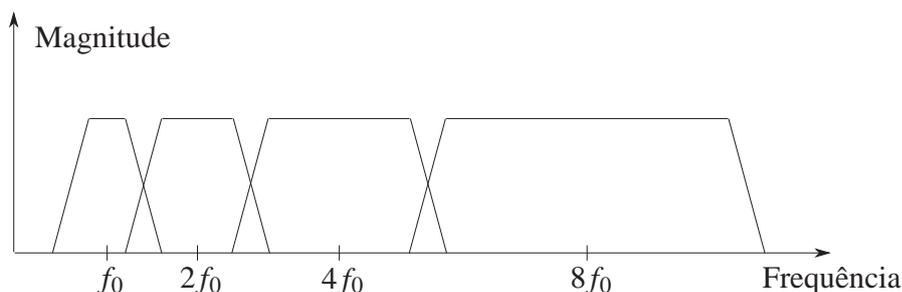
Em geral, o processo de amostragem dos sinais é feito utilizando uma escala fixa, ou seja, uma frequência de amostragem pré-estabelecida. Dessa forma, ao visualizar a informação contida nos sinais após o processo de amostragem utilizando processos clássicos como a análise de Fourier, por exemplo, será possível verificar os componentes desse sinal sob um único ponto de vista, que é o definido a partir da escala adotada.

Surge então a análise multirresolução, que tem como principal característica a possibilidade de se variar a escala utilizada para caracterizar os sinais. Dessa forma, alterando-se as resoluções tanto no tempo quanto na frequência, torna-se possível identificar características que antes não eram verificáveis.

A implementação desta ferramenta pode ser feita utilizando um banco de filtros, de modo

que um sinal qualquer possa ser analisado utilizando um conjunto de filtros digitais. A proposta é utilizar um banco de filtros com uma largura de banda ajustada em função de uma frequência central estabelecida, permitindo assim que informações anteriormente descartadas possam ser utilizadas num processo de classificação de sinais. Essa afirmação é ilustrada na Figura 3, que apresenta o comportamento da resposta em frequência de um banco de filtros utilizados na transformada wavelet.

Figura 3 - Resposta em frequência dos filtros utilizados para análise multirresolução.



Fonte: Adaptado de Rioul e Vetterli (1991).

Dessa forma, essa análise torna-se bastante eficiente para caracterizar sinais constituídos por elementos de baixa frequência e longa duração somados a elementos de alta frequência e curta duração, casos frequentemente encontrados em aplicações práticas.

### 3.2 Representação de funções através de subespaços

A proposta de um espaço de escala é a de representar uma função qualquer através de um somatório de subespaços, sendo esses subespaços compostos por funções cujos detalhes possam ser representados numa determinada escala. A fim de permitir que esta escala fosse utilizada em sistemas digitais, sua representação é feita em geral utilizando-se potências de dois ( $2^s$ ), sendo  $s$  um número inteiro utilizado para definir a escala adotada.

Para cada inteiro  $s$ , dada a função  $\phi(t)$ , a criação de um espaço de escala é feita com o auxílio de um subespaço  $V_s \subset L^2\mathbb{R}$ , sendo  $L^2\mathbb{R}$  o conjunto de funções quadraticamente integráveis de energia finita. Esse conceito é aplicado utilizando um conjunto de funções  $\phi(t) \in L^2\mathbb{R}$  que constituem uma base ortonormal de  $V_s$ , conforme é apresentado na equação (25) (GOMES; VELHO; GOLDENSTEIN, 1997):

$$\phi_{s,k}(t) = 2^{-s/2}\phi(2^{-s}t - k), \quad s, k \in \mathbb{R}, \quad (25)$$

sendo  $s$  o fator de escala,  $k$  o índice de translação da função e  $\phi(t)$  uma função de modulação.

A função  $\phi_{s,k}(t)$  representa uma versão escalonada e transladada da função original  $\phi(t)$ .

Sendo assim, utilizando a formula apresentada em (25), é possível representar uma função qualquer de energia finita  $f(t)$  através de um somatório de funções  $\phi_{s,k}(t)$ , conforme é apresentado na equação (26):

$$f(t) \cong \sum_k c_k \phi_{s,k}(t), \quad (26)$$

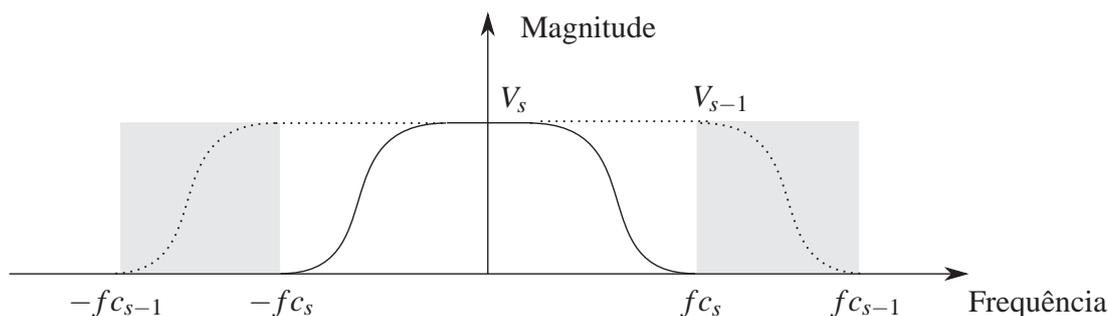
sendo  $c_k$  as constantes de aproximação que minimizam o valor da função de erro.

À medida que a escala  $s$  diminui, a largura de  $\phi_{s,k}(t)$  diminui, aumentando com isso a frequência de resolução do sinal. Ademais, nota-se que os detalhes do sinal presentes na escala  $2^s$  estarão presentes na escala  $2^{s-1}$ , de modo que  $V_s \subset V_{s-1}$ . Devido a isso, a função  $\phi_{s,k}(t)$  é chamada de *função de escala*.

Fazendo uma analogia com processamento de sinais, é possível utilizar um conjunto de filtros para decompor um sinal original, com banda de frequências  $\omega$ , em vários sinais com banda de frequências distintas, de tal modo que o sinal original possa ser recuperado a partir dos sinais decompostos.

Em linguagem matemática, essa banda de frequências recebe o nome de subespaço. A visualização desses subespaços pode ser facilitada com o auxílio da análise de Fourier, conforme apresenta a Figura 4. Da figura, nota-se que é possível fazer uma analogia entre a projeção ortogonal de uma função  $f(t) \in L^2\mathbb{R}$  e a resposta em frequência definida por um filtro passa-baixas (GOMES; VELHO; GOLDENSTEIN, 1997).

Figura 4 - Banda de frequências entre  $V_s$  e  $V_{s-1}$ .



Fonte: Adaptado de Gomes, Velho e Goldenstein (1997).

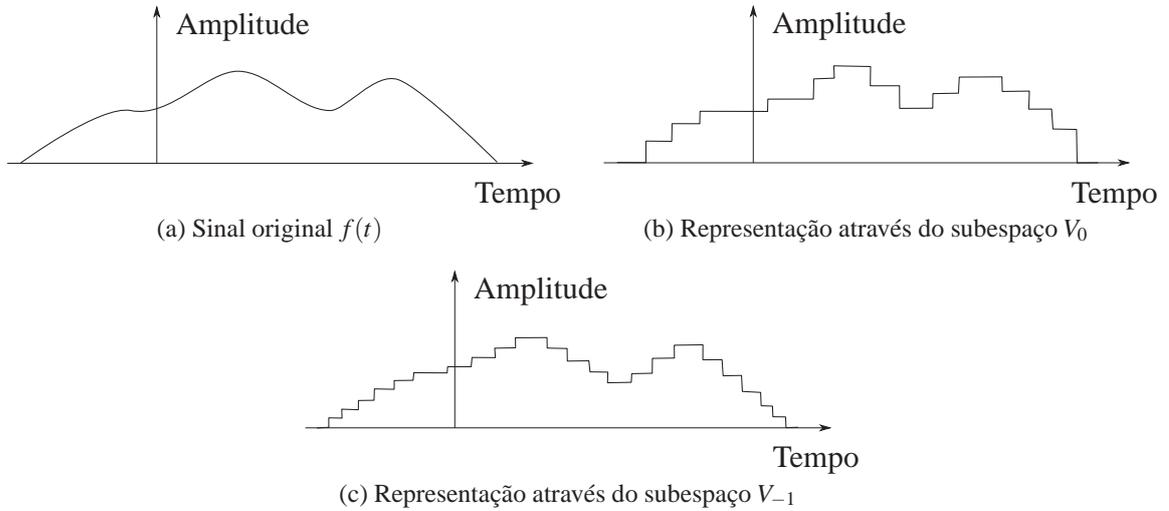
Considerando a frequência de corte do filtro como  $fc_s$ , verifica-se que cada subespaço  $V_s$  é composto por funções com banda entre  $[-fc_s, fc_s]$ . Dessa forma, na passagem do subespaço  $V_s$  para  $V_{s-1}$ , a escala é reduzida de  $2^s$  para  $2^{s-1}$ , aumentando portanto a banda do sinal para  $[-fc_{s-1}, fc_{s-1}]$ , como apresentado na Figura 4.

Dessa forma, torna-se possível fazer uma analogia entre a escala utilizada para analisar os sinais e a resposta em frequência de um filtro passa-baixas. Do ponto de vista de processamento

de sinais, isso quer dizer que a função de escala  $\phi(t)$  pode ser representada através da função de transferência de um filtro passa-baixas.

Isso, na prática, quer dizer que é possível recuperar um sinal  $f(t) \in L^2\mathbb{R}$  a partir do somatório das funções ortogonais que representam o subespaço  $V_s$  com as funções ortogonais que representam os detalhes de frequência mais elevada. A Figura 5 ilustra um sinal  $f(t)$  e sua representação nos espaços de escala  $V_0$  e  $V_{-1}$ .

Figura 5 - Composição do sinal  $f(t)$  a partir dos subespaços  $V_0$  e  $V_{-1}$ .



Fonte: Adaptado de Gomes, Velho e Goldenstein (1997).

Analisando novamente a Figura 4, nota-se que é possível obter o subespaço  $V_{s-1}$  a partir de  $V_s$  acrescentando todas as funções de  $L^2\mathbb{R}$  com frequências situadas na banda  $[fc_s, fc_{s-1}]$ . Sendo assim, é possível recompor o sinal original a partir da soma de suas componentes de baixa frequência com suas componentes de frequência mais elevada. Se o subespaço limitado por essa banda de frequências for indicado por  $W_s$ , é possível expressar o subespaço  $V_{s-1}$  conforme apresentado na equação (27):

$$V_{s-1} = V_s \oplus W_s, \quad s, k \in \mathbb{N}, \quad (27)$$

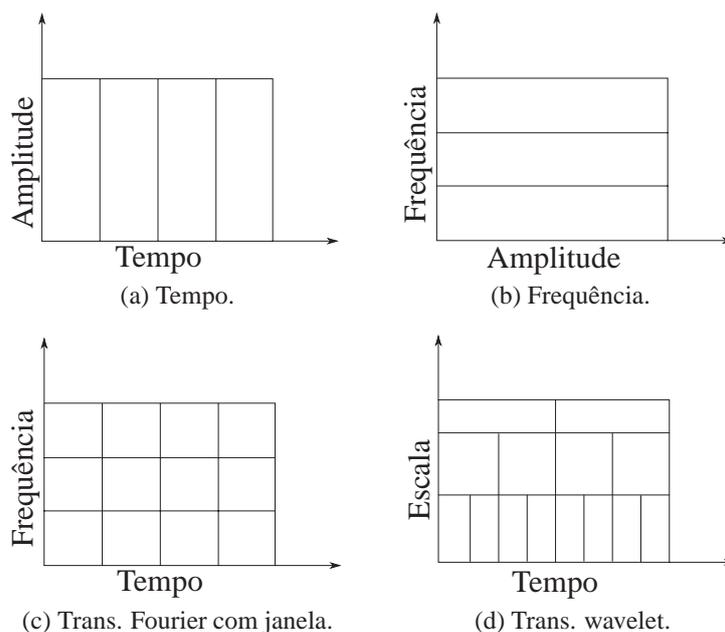
sendo  $\oplus$  a soma direta dos subespaços  $V_s$  e  $W_s$ .

Essa equação indica que  $W_s$  é ortogonal a  $V_s$ , pois a soma direta desses dois subespaços gera o subespaço  $V_{s-1}$ . Na prática, a equação (27) indica que o subespaço  $W_s$  contém os detalhes do sinal representado na escala adotada por  $V_s$ . Ademais, verifica-se que uma representação ideal de um sinal amostrado exigiria a soma direta de infinitos subespaços, de modo a garantir que todo o espectro de frequências estivesse sendo representado.

### 3.3 Transformada wavelet contínua

A transformada wavelet é uma técnica que tem como finalidade relacionar tempo e escala. Essa transformada compõe uma das etapas do processo evolutivo da análise de sinais, conforme apresenta a Figura 6.

Figura 6 - Processo evolutivo da análise de sinais.



Fonte: Adaptado de Misiti et al. (1996).

A análise de sinais iniciou-se com a representação dos sinais no domínio do tempo (Figura 6(a)), evoluiu para a representação dos sinais no domínio da frequência (Figura 6(b)), passou a relacionar o tempo à frequência (Figura 6(c)) e finalmente, utilizou-se de uma escala para representar os sinais (Figura 6(d)), sendo este o propósito da transformada wavelet.

A limitação da transformada de Fourier com janela está no fato dela utilizar uma escala fixa. Dessa forma, características do sinal que apresentarem tamanho inferior ao tamanho da janela adotado serão perdidas.

Já a transformada wavelet apresenta como principal vantagem o fato de não utilizar uma escala fixa na análise dos sinais, evitando dessa forma um comprometimento com uma escala específica. Dessa forma, é possível utilizar escalas maiores para analisar sinais de baixa frequência e escalas menores para analisar sinais de alta frequência.

A transformada wavelet contínua (CWT, do inglês *continuous wavelet transform*) baseia-se nos conceitos descritos durante a abordagem da análise multirresolução. Para tanto, dada uma função  $\psi(t)$ , inicialmente define-se um conjunto de funções ortogonais  $\psi(t)$  que sera usada

como base ortogonal para a representação de sinais, conforme apresentado na equação (28) (RIOUL; VETTERLI, 1991):

$$\psi_{s,k}(t) = \frac{1}{\sqrt{|s|}} \psi\left(\frac{t-k}{s}\right), \quad s, k \in \mathbb{R}, \quad (28)$$

sendo  $s$  o fator de escala,  $k$  o índice de translação da função,  $1/\sqrt{|s|}$  um fator utilizado para normalizar a energia da função e  $\psi(t)$  uma função de modulação dada.

A proposta da transformada wavelet contínua é a de representar um sinal qualquer  $w(t)$  através de versões escalonadas e transladadas ( $\psi_{s,k}(t)$ ) da função  $\psi(t)$  que, como visto anteriormente, deve constituir uma base ortogonal de funções.

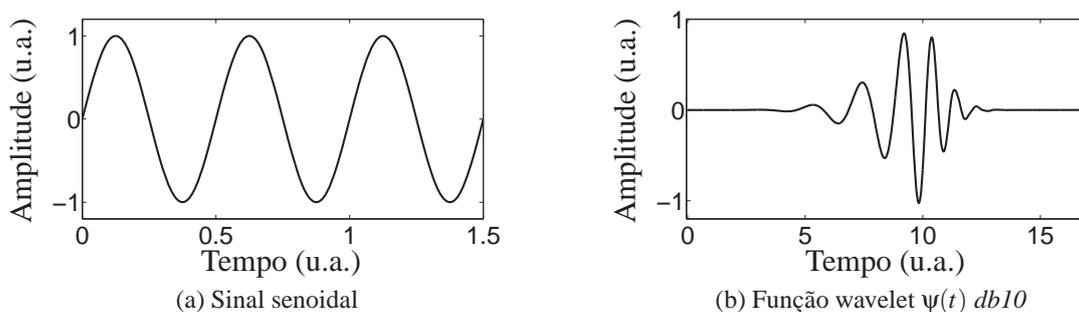
A partir dessas informações, a transformada wavelet contínua de  $w(t)$  pode ser definida de acordo com a equação (29) (RIOUL; VETTERLI, 1991):

$$W(s, k) = \int_{-\infty}^{+\infty} w(t) \psi_{s,k}(t) dt, \quad s, k \in \mathbb{R}. \quad (29)$$

A função  $\psi(t)$ , que é usada como base durante esse processo de decomposição, recebe o nome de função de wavelet. Por convenção, a função de wavelet utilizada durante a primeira etapa da decomposição recebe o nome de wavelet-mãe. Já suas versões escalonadas e transladadas, embora apresentem as mesmas características, passam a ser chamadas de wavelets-filhas. Esse conjunto formado por wavelets-mães e wavelets-filhas é comumente referenciado como família de wavelets (RIOUL; VETTERLI, 1991).

Comparando a transformada wavelet à transformada de Fourier, verifica-se que as senóides que são a base da transformada de Fourier não têm duração finita, são suaves e previsíveis. Em contrapartida, as wavelets apresentam duração finita, são irregulares e podem ser assimétricas. A Figura 7 apresenta um exemplo das bases utilizadas para a decomposição dos sinais realizada pela análise de Fourier e pela análise wavelet.

Figura 7 - Formas de onda de um sinal senoidal e uma wavelet.



Fonte: Elaboração do próprio autor.

Essa característica permite que a transformada wavelet tenha como propriedade uma boa localização no tempo, diferentemente do que ocorre com a transformada de Fourier. A análise de Fourier propõe a decomposição dos sinais de interesse em elementos senoidais. De modo análogo, a análise wavelet propõe a decomposição dos sinais através de versões escalonadas e deslocadas da família wavelet adotada para a realização da decomposição, a chamada wavelet-mãe.

A análise wavelet torna-se interessante para casos onde o sinal a ser analisado não apresenta características uniformes. Sendo assim, os resultados utilizando uma decomposição através de formas de onda senoidais não seriam tão bons quanto os obtidos utilizando formas de onda irregulares e de curta duração, capazes de extrair uma quantidade maior de informação do sinal, como proposto através da utilização de famílias de wavelets.

A análise wavelet resulta num conjunto de coeficientes que indicam o grau de semelhança entre o sinal original e as funções wavelets utilizadas como base no processo de decomposição.

### 3.4 Famílias de wavelets

Até aqui foram apresentadas algumas das principais características para a realização da análise multirresolução utilizando a transformada wavelet. Como já mencionado, um fator primordial para o sucesso da utilização da análise wavelet é justamente a escolha da família adequada, também chamada de wavelet-mãe.

Não há um consenso a respeito da metodologia empregada para a escolha da família de wavelets em relação à sua aplicação, de modo que cabe ao usuário escolher de maneira empírica a família mais adequada para a solução do seu problema.

O processo de escolha da família pode ser bastante complexo, haja vista o grande número de variações de cada uma das wavelets-mães. Em geral, as famílias Daubechies e Symlets são as mais utilizadas, o que não quer dizer que outras famílias não apresentem bons resultados.

Para que uma função qualquer seja definida como uma família de wavelets, algumas condições devem ser atendidas. São elas (SILVA, 2008):

- $\psi(t) \in L^2(\mathbb{R})$ , ou seja, a função deve pertencer ao espaço de funções quadraticamente integráveis. Isso quer dizer que a função  $\psi(t)$  deve apresentar energia finita, como definido pela equação (30) (DAUBECHIES, 1992):

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty; \quad (30)$$

- A transformada de Fourier de  $\psi(t)$ , denotada por  $\Psi(\omega)$ , deve satisfazer a uma condição definida por Daubechies (1992) como condição de admissibilidade, conforme apresenta

a equação (31):

$$\int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty. \quad (31)$$

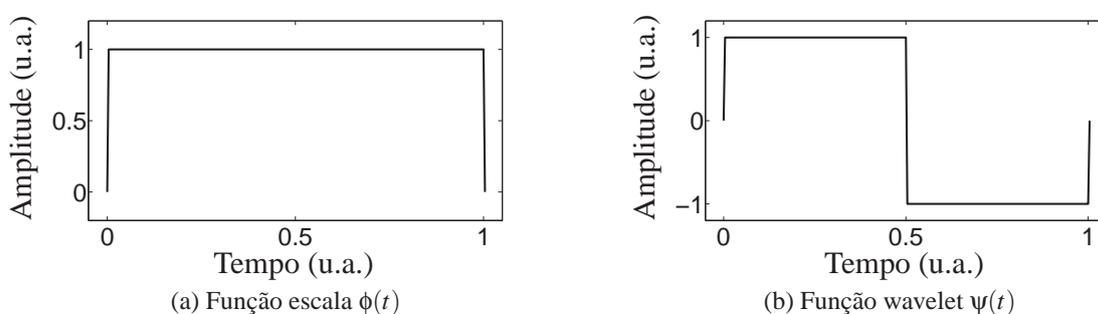
A equação (31) implica que o somatório das áreas de uma função wavelet no domínio do tempo deve ser nulo, ou seja, as áreas negativas anulam as positivas no gráfico de uma função wavelet.

As famílias de wavelets são constituídas por formas de onda que apresentam um decaimento rápido e de curta duração, por isso a utilização do termo wavelets, que faz menção a uma “onda pequena”. Na sequência, serão descritas as características de algumas das famílias de wavelets mais usuais.

### 3.4.1 Família Haar

As wavelets de Haar constituem a primeira família de wavelets, desenvolvida por Alfred Haar em 1909. É uma família de wavelets descontínua e se assemelha a uma função degrau unitário. Um esboço de suas funções de escala e de wavelet é apresentado na Figura 8.

Figura 8 - Família wavelet de Haar.



Fonte: Elaboração do próprio autor.

Suas funções de escala  $\phi(t)$  e wavelet  $\psi(t)$  são definidas pelas equações (32) e (33), respectivamente:

$$\phi(t) = \begin{cases} 1, & t \in [0, 1] \\ 0, & t \notin [0, 1] \end{cases}, \quad (32)$$

$$\psi(t) = \begin{cases} 1, & t \in [0, 0.5] \\ -1, & t \in [0.5, 1] \\ 0, & t \notin [0, 1] \end{cases}. \quad (33)$$

As funções wavelet de Haar não são continuamente diferenciáveis. Dessa forma, é possível que haja uma descontinuidade durante seu processo de decomposição utilizando essa família, fazendo com que a reconstrução do sinal original a partir das decomposições não seja perfeita.

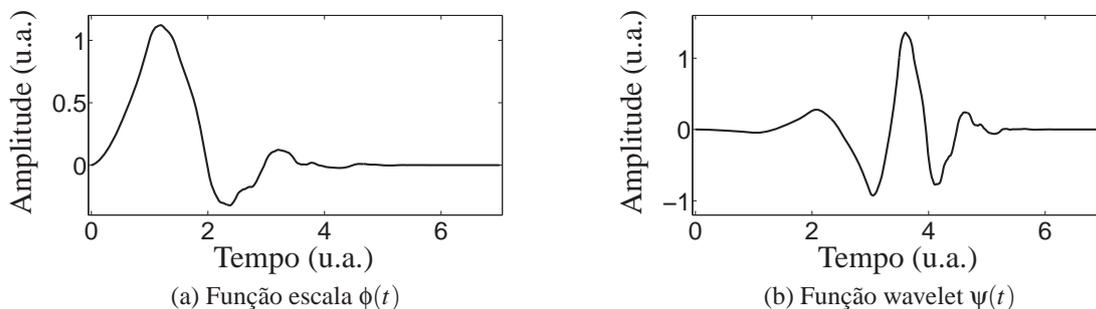
Embora essa possa ser uma característica que limite as aplicações das wavelets de Haar, essa propriedade é bastante explorada para analisar sinais que apresentam transições súbitas.

### 3.4.2 Família Daubechies

As wavelets desenvolvidas por Ingrid Daubechies constituem uma família de wavelets ortonormais de suporte compacto. A expressão suporte compacto refere-se ao fato da função estar definida apenas num intervalo fechado, de modo que os valores fora desse intervalo sejam nulos (DAUBECHIES, 1992).

O tamanho do suporte compacto utilizado para a construção da família Daubechies pode variar. Devido a isso, as wavelets de Daubechies são divididas em subgrupos, comumente expressos por  $dbN$ , onde  $N$  faz menção ao número de *vanishing moments* apresentados pela função. A Figura 9 ilustra as funções de escala e de wavelet para a família  $db4$ .

Figura 9 - Família wavelet de Daubechies ( $db4$ ).



Fonte: Elaboração do próprio autor.

A expressão *vanishing moments* provém da análise dos coeficientes da família de wavelets através da transformada Z. Esse termo refere-se ao número de zeros que a função apresenta em  $\omega = \pi$  no plano Z. Sendo assim,  $N$  *vanishing moments* representa  $N$  zeros em  $\pi$

Teoricamente, é possível representar qualquer sinal polinomial cuja ordem não seja superior a  $N - 1$  utilizando uma função de wavelets com  $N$  *vanishing moments*. Sendo assim, teoricamente, o aumento do número de *vanishing moments* permite à família de wavelets representar sinais mais complicados. Devido a essa característica, o termo  $N$  também é chamado de acurácia da família de wavelets (STRANG; NGUYEN, 1997).

É frequente a utilização da expressão “ordem da família” para expressar o número de *vanishing moments* apresentados pela função. Para o exemplo mencionado, a designação seria

família Daubechies de quarta ordem (DAUBECHIES, 1992).

O índice  $N$  também é utilizado para expressar o tamanho do suporte da função, ou seja, o intervalo para o qual a função está definida. Para o caso da família Daubechies, tanto a função escala  $\phi(t)$  quanto a função wavelet  $\psi(t)$  apresenta suporte  $2N - 1$ . É possível verificar essa afirmação através da Figura 9, onde é possível verificar graficamente que a família  $db4$  está definida no intervalo  $[0, 7]$ .

Um detalhe importante da família Daubechies é que a família  $db1$  é equivalente a família de wavelets de Haar, que apresenta suporte  $[0, 1]$  e possui apenas 1 *vanishing moment*.

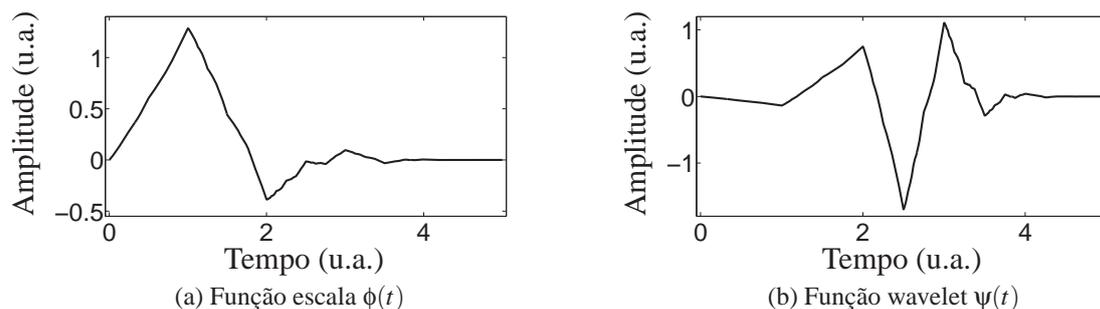
O procedimento de cálculo para a obtenção das funções  $\phi(t)$  e  $\psi(t)$  da família Daubechies não será abordado nesse trabalho devido à sua complexidade matemática, entretanto, ele pode ser encontrado em (DAUBECHIES, 1992).

### 3.4.3 Família Symlets

A família symlets foi desenvolvida por Daubechies (1992) com o propósito de criar uma família com maiores características de simetria do que a família Daubechies, por isso o nome symlets (do inglês, *symmetric wavelet*).

É uma família que apresenta características semelhantes as da família Daubechies, como suporte compacto e diferenciabilidade. A Figura 10 ilustra as funções de escala e de wavelet para a família  $sym3$ .

Figura 10 - Família wavelet de symlets ( $sym3$ ).



Fonte: Elaboração do próprio autor.

Em geral, essa família é identificada pela expressão  $symN$ , onde  $N$  indica o número de *vanishing moments* apresentados pela função. Ademais, assim como no caso da família Daubechies, também é usada a expressão família symlet de ordem  $N$ .

O suporte dessa família também é definido pela relação  $2N - 1$ , conforme pode ser verificado na Figura 10. O procedimento para cálculo das funções de escala e de wavelets da família

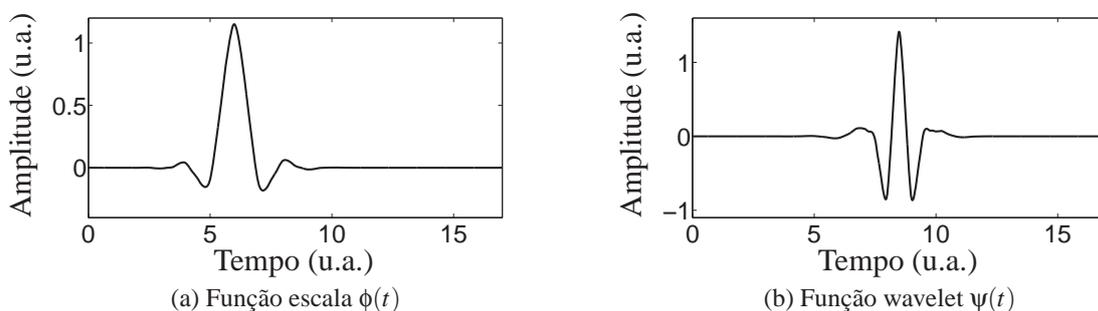
symlets não será apresentado nesse trabalho, mas pode ser encontrado em (DAUBECHIES, 1992).

### 3.4.4 Família Coiflets

A família wavelet de Coiflets também foi desenvolvida por Daubechies (1992) a pedido de Ronald R. Coifman. É usualmente identificada pela notação  $coifN$ . Ademais, assim como no caso das famílias de Daubechies, também é usada a expressão família Coiflet de ordem  $N$ .

A Figura 11 apresenta o comportamento da família  $coif3$ :

Figura 11 - Família wavelet de coiflets ( $coif3$ ).



Fonte: Elaboração do próprio autor.

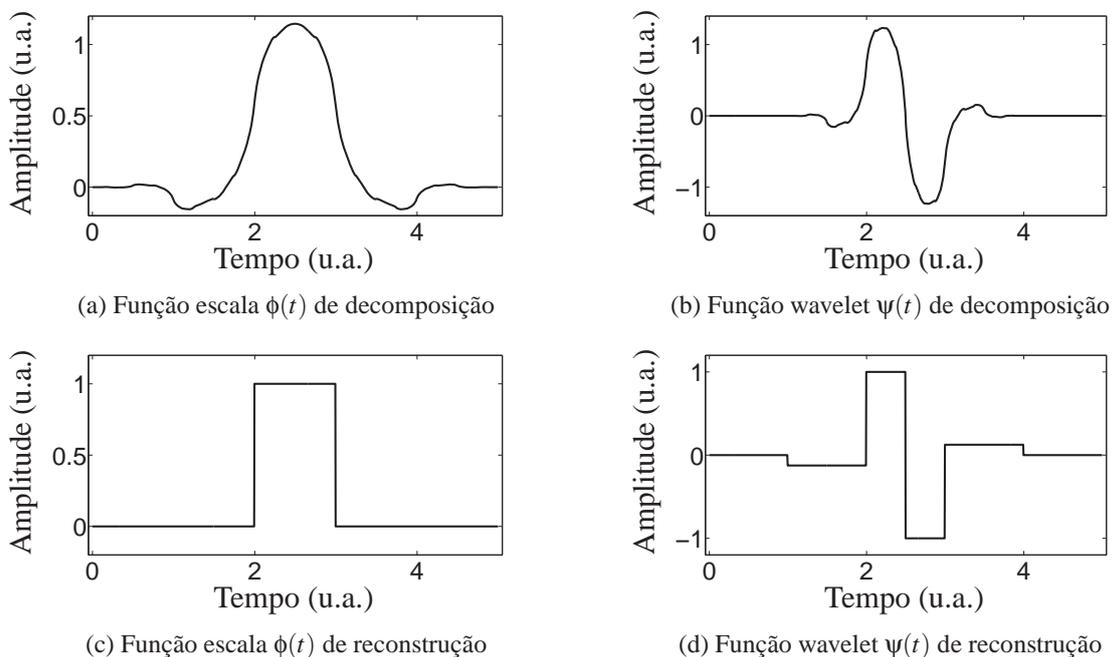
Uma das características da família Coiflets é o fato da mesma apresentar um número de *vanishing moments* para a função de escala. Dessa forma, o número de *vanishing moments* da função  $\phi(t)$  é definido por  $2N - 1$ , enquanto o número de *vanishing moments* da função  $\psi(t)$  é definido por  $2N$ .

Também é uma característica dessa família apresentar um grau de simetria maior do que o encontrado na família Daubechies, e um suporte definido pela relação  $6N - 1$ . O procedimento para o cálculo de suas funções de wavelet e de escala pode ser encontrado em (DAUBECHIES, 1992).

### 3.4.5 Família Bi-ortogonal

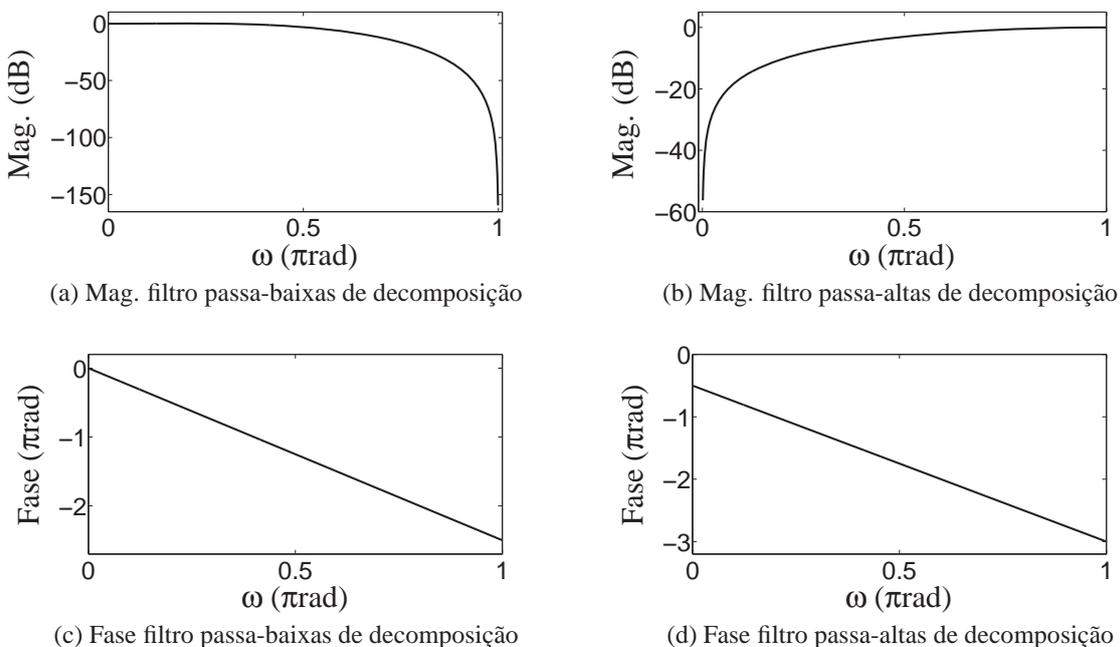
A Figura 12 apresenta o comportamento das funções de escala e de wavelets da família bi-ortogonal 1.3, e as características de magnitude e fase dos filtros utilizados para implementar essa família são mostradas na Figura 13, que apresenta a resposta de magnitude e fase de um filtro passa-baixas (Figuras 13(a) e 13(c)) e um passa-altas (Figuras 13(b) e 13(d)) utilizados para implementar a família bi-ortogonal bior1.3.

Figura 12 - Família wavelet bi-ortogonal (*bior1.3*).



Fonte: Elaboração do próprio autor.

Figura 13 - Resposta em frequência do banco de filtros da família bi-ortogonal (*bior1.3*).



Fonte: Elaboração do próprio autor.

A família de wavelets bi-ortogonal apresenta como principal característica a propriedade

de fase linear, muito utilizada em operações envolvendo compressão de imagem, onde o sinal decomposto deve ser reconstruído (BURRUS; GOPINATH; GUO, 1997).

A principal desvantagem dessa família é a necessidade de duas wavelets distintas para a realização de todo o procedimento: uma para o processo de decomposição e outra para o processo de reconstrução (DAUBECHIES, 1992).

Assim como no caso da família de Daubechies, a família bi-ortogonal apresenta um grande número de variações, e é comumente expressa como *bior Nr.Nd*, onde *Nr* indica a wavelet utilizada para a reconstrução e *Nd* a wavelet utilizada para decomposição. O processo de cálculo para suas funções de wavelet e de escala pode ser encontrado em (STRANG; NGUYEN, 1997).

### 3.4.6 Família Meyer

A família Meyer é composta por funções continuamente diferenciáveis. Sua função de escala  $\phi(t)$  e sua função de wavelet  $\psi(t)$  são definidas no domínio da frequência com o auxílio de uma função  $v(a)$ , conforme apresentado nas equações (34) e (35), respectivamente (DAUBECHIES, 1992):

$$\Phi(\omega) = \begin{cases} (2\pi)^{-1/2}, & |\omega| \leq \frac{2\pi}{3} \\ (2\pi)^{-1/2} \cos\left(\frac{\pi}{2}v\left(\frac{3}{2\pi}|\omega| - 1\right)\right), & \frac{2\pi}{3} \leq |\omega| \leq \frac{4\pi}{3} \\ 0, & |\omega| > \frac{4\pi}{3} \end{cases}, \quad (34)$$

$$\Psi(\omega) = \begin{cases} (2\pi)^{-1/2}e^{j\omega/2} \sin\left(\frac{\pi}{2}v\left(\frac{3}{2\pi}|\omega| - 1\right)\right), & \frac{2\pi}{3} \leq |\omega| \leq \frac{4\pi}{3} \\ (2\pi)^{-1/2}e^{j\omega/2} \cos\left(\frac{\pi}{2}v\left(\frac{3}{4\pi}|\omega| - 1\right)\right), & \frac{4\pi}{3} \leq |\omega| \leq \frac{8\pi}{3} \\ 0, & |\omega| \notin \left[\frac{2\pi}{3}, \frac{8\pi}{3}\right] \end{cases}, \quad (35)$$

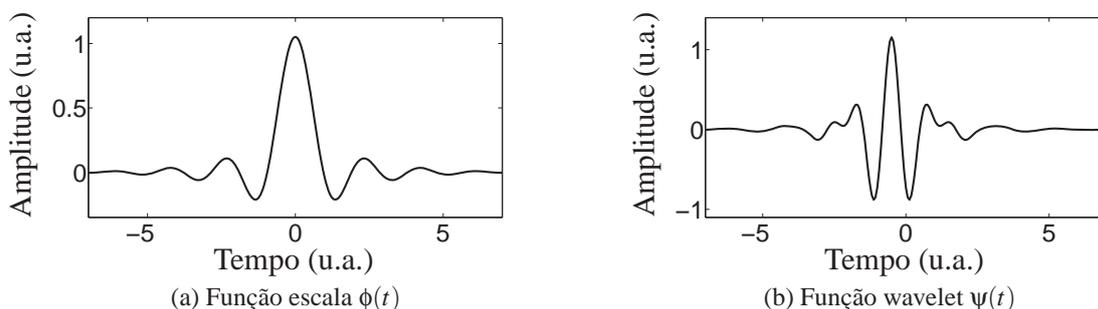
sendo a função  $v(a)$  definida pela equação (36):

$$v(a) = a^4(35 - 84a + 70a^2 - 20a^3) \quad a \in [0, 1]. \quad (36)$$

A Figura 14 apresenta as funções de escala e de wavelets da família Meyer.

Nota-se que, para variar as funções de escala e de wavelet de Meyer, basta alterar a função auxiliar  $v(a)$  utilizada para defini-las no domínio da frequência.

Figura 14 - Família wavelet de Meyer.



Fonte: Elaboração do próprio autor.

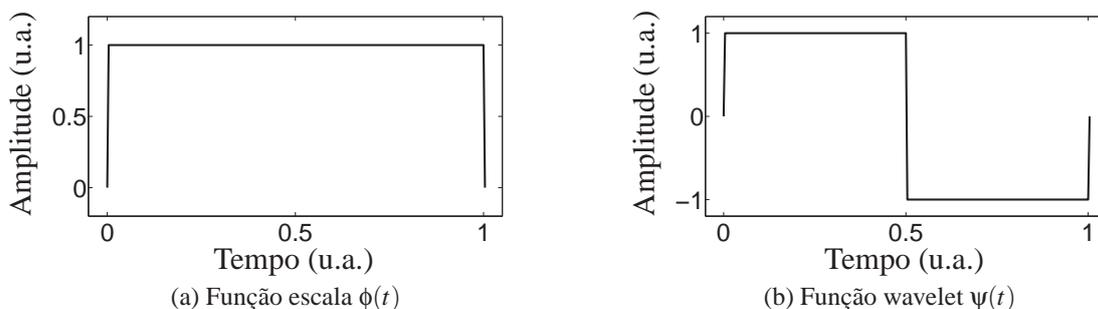
### 3.5 Escalonamento e deslocamento da função wavelet

O escalonamento de uma família de wavelets nada mais é do que uma compressão ou expansão  $\psi_{s,k}(t)$  da função  $\psi(t)$ . Esse processo é análogo ao que ocorre com sinais senoidais, ou seja, considerando um fator de escala  $s$  aplicado a uma função  $f(t) = \sin(t/s)$ , teremos uma compressão para valor de ( $s < 1$ ) e uma expansão para valores de ( $s > 1$ ).

Já o deslocamento consiste na inserção de um atraso ou avanço na função no domínio do tempo. Matematicamente, um exemplo pode ser dado através da função  $f(t) = \sin(t)$  que, ao sofrer um atraso  $k$ , passa a ser representada por  $g(t) = \sin(t - k)$ .

Os conceitos de deslocamento e escalonamento descritos anteriormente foram utilizados para se gerar uma equação que relacione as funções de wavelets às funções de escala. Essa relação permite que um sinal possa ser representado através da composição de uma aproximação mais grosseira, representada utilizando uma conjunto de funções de escala  $\phi(t)$ , e seus detalhes, representados utilizando um conjunto de funções de wavelets  $\psi(t)$ . Um exemplo dessa relação pode ser visualizado através da Figura 15.

Figura 15 - Família wavelet de Haar.



Fonte: Elaboração do próprio autor.

Da Figura 15, nota-se que é possível relacionar as funções de escala e de wavelet através da expressão apresentada em (37):

$$\psi(t) = \phi(2t) - \phi(2t - 1). \quad (37)$$

Para o caso envolvendo a família das wavelets de Haar, esta relação não apresenta grandes dificuldades. Entretanto, para casos mais complicados, como os das famílias de Daubechies e Symlets, essa relação pode ser bem difícil de se estabelecer.

### 3.6 Procedimento para cálculo da transformada wavelet

O procedimento para a realização do cálculo da transformada wavelet pode ser dividido em cinco etapas básicas, conforme apresentado na sequência.

1. Define-se uma família de wavelets que será utilizada para a análise. Em seguida, compara-se a mesma à um trecho do sinal que será analisado;
2. Calcula-se a correlação entre a wavelet-mãe utilizada e o trecho do sinal que está sendo comparado. O resultado dessa correlação definirá a escala do gráfico gerado pela análise wavelet e está diretamente relacionado ao tipo de família escolhido para a realização da análise. Dessa forma, a escolha da família é fundamental para a obtenção de resultados mais adequados;
3. Desloca-se a wavelet-mãe escolhida e repete-se os procedimentos 1 e 2, até que todo o sinal tenha sido analisado;
4. Varia-se a escala da wavelet-mãe adotada, convertendo-a dessa forma numa wavelet-filha, e repetem-se os passos de 1 a 3;
5. Repetem-se os passos de 1 a 4 para todos os níveis de escala que desejar analisar.

### 3.7 Análise espectral de uma wavelet

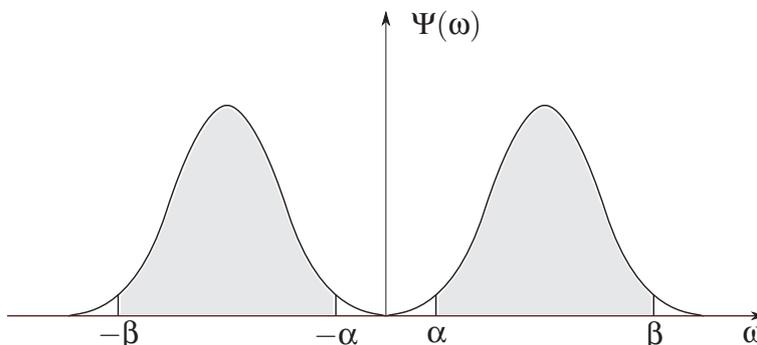
Para que uma família de wavelets seja criada, é necessário que a função de modulação  $\psi(t)$  a ser utilizada obedeça a uma condição chamada *condição de admissibilidade*, indicada pela equação (38) (STRANG; NGUYEN, 1997):

$$\lim_{\omega \rightarrow 0} \Psi(\omega) = 0, \quad (38)$$

sendo  $\Psi(\omega)$  a transformada de Fourier da função  $\psi(t)$ .

O comportamento dessa função  $\psi(t)$  é apresentado na Figura 16.

Figura 16 - Transformada de Fourier de uma wavelet.



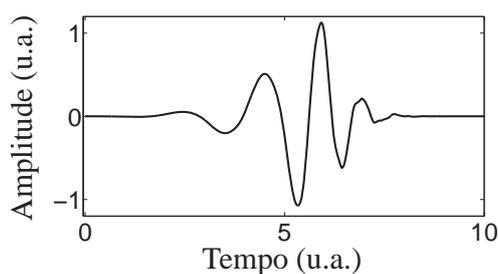
Fonte: Adaptado de Gomes, Velho e Goldenstein (1997).

Outra condição necessária para que uma função qualquer  $\psi(t)$  seja utilizada como base para a decomposição wavelet é apresentada na equação (39) (STRANG; NGUYEN, 1997):

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0. \quad (39)$$

Essa condição garante que o somatório das áreas positivas e negativas determinadas pela função  $\psi(t)$  seja nulo, o que quer dizer que a função de wavelet deve apresentar valor médio nulo. Essa afirmação pode ser verificada através da Figura 17, que apresenta uma função wavelet.

Figura 17 - Função wavelet  $\psi(t)$  db6.



Fonte: Elaboração do próprio autor.

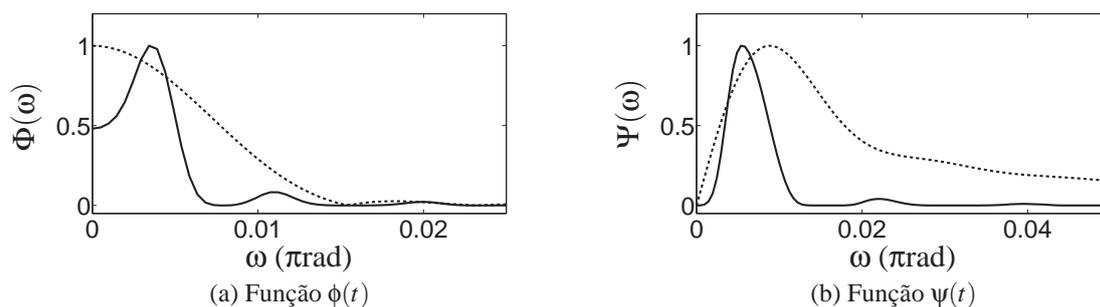
O fato da transformada de Fourier da wavelet-mãe  $\psi(t)$  não conter informações fora de uma faixa específica, delimitada por  $\alpha$  e  $\beta$  na Figura 16, permite que ela seja representada por um filtro passa-faixas.

Já a função de escala, conforme mencionado anteriormente, pode ser vista como um filtro passa-baixas, cuja banda passante pode ser maior ou menor em função do nível de detalhe que

se deseja analisar.

Essas características podem ser visualizadas através da Figura 18, que apresenta a análise espectral das funções de escala  $\phi(t)$  e das funções de wavelet  $\psi(t)$  que compõe as famílias de wavelets de Haar e Daubechies. Nessa figura, a expressão  $\Phi(\omega)$  indica a transformada de Fourier da função  $\phi(t)$ , enquanto a expressão  $\Psi(\omega)$  indica a transformada de Fourier da função  $\psi(t)$ .

Figura 18 - Análise espectral das funções  $\phi(t)$  e  $\psi(t)$ .



Legenda: - - Haar    - db6

Fonte: Elaboração do próprio autor.

Na representação apresentada na Figura 18, o termo  $\omega$  refere-se à frequência normalizada, e é definido através da relação apresentada pela equação (40):

$$\omega = \frac{2\pi f_0}{f_s}, \quad (40)$$

sendo  $f_0$  a frequência do sinal e  $f_s$  a frequência de amostragem do sinal.

Essa representação permite que todos os cálculos sofisticados abordados até então possam ser substituídos por uma simples operação de filtragem. Sendo assim, ao invés da abordagem de soma direta de subespaços, passa-se a utilizar banco de filtros para realizar a decomposição wavelet (MALLAT, 1999).

Foi justamente por conta dessa observação que a utilização da transformada wavelet em sistemas microprocessados se tornou possível, quebrando a barreira matemática que envolvia essa teoria.

### 3.8 Transformada wavelet discreta

A transformada wavelet discreta - DWT (do inglês, *discrete wavelet transform*), é o resultado da amostragem da transformada wavelet contínua. Esse processo tem como objetivo

permitir que a transformada seja implementada através da utilização de sistemas digitais.

A ideia é semelhante ao que foi proposto pela FFT na abordagem da transformada de Fourier, ou seja, amostrar o resultado da transformada de modo que, através da representação digital, seja possível visualizar as mesmas informações que seriam obtidas através da transformada em modo contínuo.

Para o processo de discretização da função de escala  $\phi_{s,k}(t)$ , os índices  $s$  e  $k \in \mathbb{R}$  são substituídos pelos índices  $u$  e  $v \in \mathbb{N}$ . Dessa forma, a equação que descreve a função de escala pode ser reescrita conforme apresentado na equação (41) (RIOUL; VETTERLI, 1991):

$$\phi_{u,v}(t) = 2^{-u/2} \phi(2^{-u}t - v), \quad u, v \in \mathbb{N}, \quad (41)$$

sendo  $u$  o fator de escala e  $v$  o índice de translação da função para sinais discretos.

Para o caso da função de wavelet  $\psi_{s,k}(t)$ , durante o processo de discretização, os índices  $s$  e  $k \in \mathbb{R}$  são substituídos pelos índices  $2^u$  e  $2^u v$  respectivamente, com  $v$  e  $u \in \mathbb{N}$ . Dessa forma, a função  $\psi_{s,k}(t)$  pode ser reescrita conforme apresenta a equação (42) (RIOUL; VETTERLI, 1991):

$$\psi_{u,v}(t) = \frac{1}{\sqrt{|2^u|}} \psi\left(\frac{t - 2^u v}{2^u}\right), \quad u, v \in \mathbb{N}, \quad (42)$$

sendo  $u$  o fator de escala,  $v$  o índice de translação da função e  $1/\sqrt{|2^u|}$  um fator utilizado para normalizar a energia da função.

Utilizando o resultado apresentado em (42), é possível discretizar a transformada wavelet contínua apresentada anteriormente. O resultado, apresentado na equação (43), é a chamada transformada wavelet discreta (RIOUL; VETTERLI, 1991):

$$D(u, v) = \frac{1}{\sqrt{|2^u|}} \int_{-\infty}^{+\infty} d(t) \psi\left(\frac{t - 2^u v}{2^u}\right) dt, \quad u, v \in \mathbb{N}, \quad (43)$$

sendo  $D(u, v)$  a transformada wavelet discreta da função  $d(t)$ .

Como as funções wavelet e escala formam uma base ortogonal, torna-se possível representar um sinal através da utilizações das funções  $\phi_{u,v}(t)$  e  $\psi_{u,v}(t)$ . A equação (44) ilustra o procedimento utilizado para decompor um sinal  $g(t)$  através de uma base ortogonal formada pelas funções de escala e de wavelets (RIOUL; VETTERLI, 1991):

$$g(t) = \sum_{v=-\infty}^{\infty} cA(v) \phi_v(t) + \sum_{u=0}^{\infty} \sum_{v=-\infty}^{\infty} cD(u, v) \psi_{u,v}(t), \quad u, v \in \mathbb{N}. \quad (44)$$

Para que essa representação seja a mais próxima possível da função original, é preciso en-

contrar valores para os coeficientes  $cA(u, v)$  e  $cD(u, v)$  que minimizem a função de erro definida anteriormente. Esse processo é apresentado nas equações (45) e (46), respectivamente (STRANG; NGUYEN, 1997):

$$cA(u, v) = \int g(t)\phi_{u,v}(t)dt, \quad (45)$$

$$cD(u, v) = \int g(t)\psi_{u,v}(t)dt. \quad (46)$$

A ideia proposta pela equação (44) é utilizar os conceitos explorados durante a análise multirresolução para representar um sinal através de uma aproximação mais grosseira e seus detalhes. A partir dessa equação, torna-se possível variar tanto a escala quanto o índice de translação a fim de se localizar diferentes características do sinal.

Por fim, devido ao comportamento das funções de escala (características de um filtro passa-baixas) e das funções de wavelets (características de um filtro passa-faixas), os coeficientes  $cA$  e  $cD$  são chamados de coeficientes de aproximação e detalhes, respectivamente (STRANG; NGUYEN, 1997).

### 3.9 Implementação através de bancos de filtros

O termo banco de filtros refere-se a um conjunto de filtros associado em cascata. A ideia da utilização de bancos de filtros para a realização do cálculo da transformada wavelet foi proposta por Mallat, que percebeu uma relação entre toda a teoria matemática envolvendo wavelets e os conceitos relacionados ao processamento digital de sinais (MALLAT, 1999).

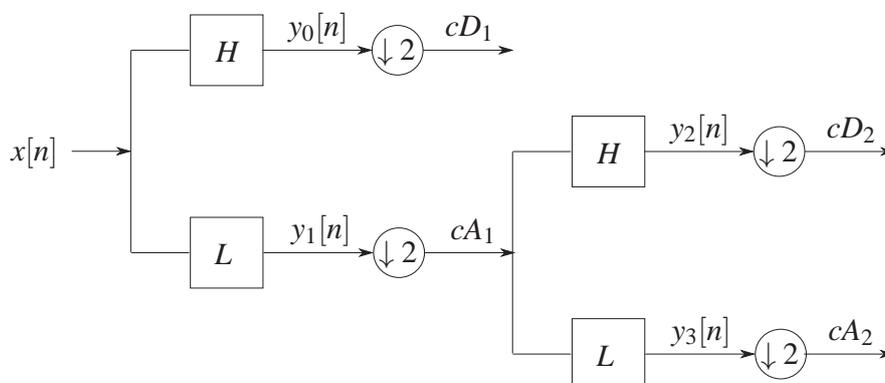
A proposta de Mallat baseou-se na análise espectral das funções de escala  $\Phi_{u,v}(\omega)$  e de wavelets  $\Psi_{u,v}(\omega)$ . Como já mencionado, a função  $\Phi_{u,v}(\omega)$  apresenta o comportamento de um filtro passa-baixas, enquanto a função  $\Psi_{u,v}(\omega)$  apresenta o comportamento de um filtro passa-faixas.

Dessa forma, definindo-se um filtro passa-baixas com resposta em frequência semelhante à apresentada pela função de escala  $\Phi_{u,v}(\omega)$  e analisando um sinal de entrada qualquer  $x[n]$  já discretizado, é possível encontrar os coeficientes de aproximação  $cA$  a partir de uma operação de filtragem, substituindo dessa forma toda a matemática envolvida para localizar coeficientes capazes de fazer com que o valor da função de erro seja mínimo.

Seguindo a mesma linha de raciocínio, é possível utilizar um filtro passa-altas para separar do sinal original  $x[n]$  os detalhes contidos na banda de frequências mais elevada que não foi utilizada na análise envolvendo o filtro passa-baixas. Dessa forma, ajustando a frequência de corte do filtro passa-altas de acordo com a frequência de corte do filtro passa-baixas, é possível

identificar os coeficientes de detalhe  $cD$  do sinal de entrada a partir de uma operação de filtragem (MALLAT, 1999). A Figura 19 apresenta um banco de filtros utilizado para o processo de análise.

Figura 19 - Banco de filtros de análise.

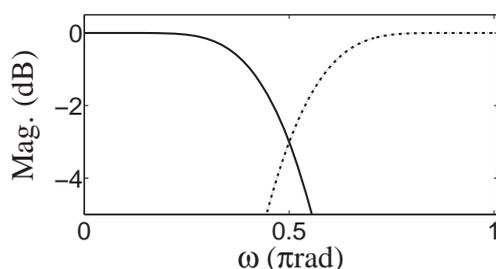


Fonte: Adaptado de Burrus, Gopinath e Guo (1997).

É possível verificar que um dizimador diádico foi acoplado à saída de cada estágio de filtragem. Esse dizimador tem a função de descartar uma a cada duas amostras que saem de cada um dos filtros utilizados, e são usados para fazer com que o somatório do número de pontos gerados após o sinal passar pelos dois filtros digitais (L e H) seja igual ao número de pontos do sinal original de entrada.

O método utilizado para solucionar esse problema foi ajustar a frequência de corte de ambos os filtros para  $\pi/2$  radianos. Esse comportamento pode ser verificado na Figura 20, que apresentam a resposta em frequência de um banco de filtros utilizado para implementar a família Daubechies de quarta ordem (RIOUL; VETTERLI, 1991).

Figura 20 - Frequência de corte do banco de filtros da família db4.



Legenda: - - Passa-altas      - Passa-baixas

Fonte: Elaboração do próprio autor.

O teorema de Nyquist afirma que a máxima frequência que um sinal pode alcançar é  $\pi$  radianos. Considerando que o sinal original  $x[n]$  foi filtrado utilizando filtros com frequência de corte igual a  $\pi/2$  radianos, torna-se possível sub-amostrar esse sinal utilizando um dizimador

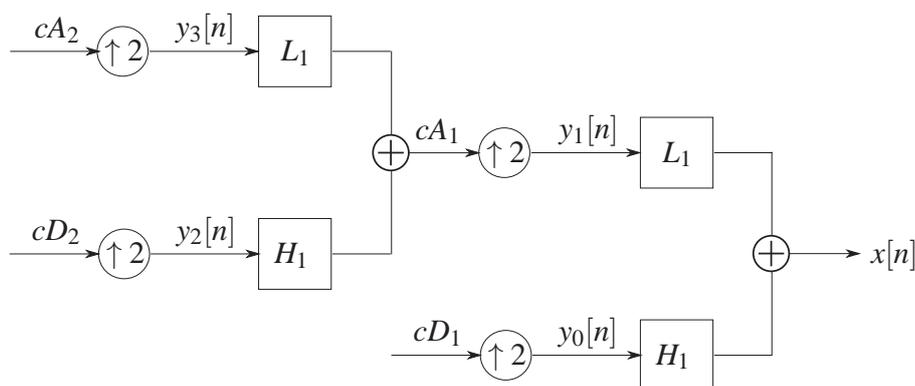
diádico, que irá descartar uma a cada duas amostras dos sinais resultantes das filtragens passa-baixas e passa-altas (OPPENHEIM; SCHAFER; BUCK, 1999).

Analisando essa afirmação no domínio da frequência, tem-se que essa sub-amostragem irá provocar uma expansão do espectro do sinal filtrado de  $\pi/2$  para  $\pi$  radianos, ou seja, o critério de Nyquist será respeitado, garantindo assim que o sinal original possa ser recuperado sem que ocorram distorções.

Como resultado desse processo, têm-se os coeficientes de aproximação e detalhe. A grande vantagem desse método é a possibilidade de se aumentar o número de níveis de decomposição simplesmente acoplando bancos de filtros em cascata, como foi ilustrado na Figura 19.

A partir dos coeficientes gerados no processo de decomposição, é possível reconstruir o sinal original  $x[n]$  utilizando um banco de filtros de síntese, conforme apresenta a Figura 21.

Figura 21 - Banco de filtros de síntese.



Fonte: Adaptado de Burrus, Gopinath e Guo (1997).

O conceito referente ao banco de síntese, também chamado de banco de reconstrução, é justamente o oposto do que foi proposto pelo banco de análise. Dessa forma, ao invés de dizimadores para reduzir o número de pontos dos sinais de saída, são inseridos zeros para aumentar o número de pontos dos sinais de entrada, comprimindo o espectro dos sinais para uma banda limitada novamente por  $\pi/2$  radianos.

Em seguida, os sinais interpolados são aplicados à entrada dos filtros de reconstrução  $L_1$  e  $H_1$ , cujos resultados somados produzem novamente uma representação aproximada do sinal original de entrada  $x[n]$ .

Devido à utilização de dizimadores e interpoladores, nem sempre o sinal obtido a partir da reconstrução será exatamente igual ao sinal original de entrada. Entretanto, pode-se considerá-lo como uma boa aproximação, suficiente para ser utilizada em aplicações acústicas e de compressão de imagens, por exemplo.

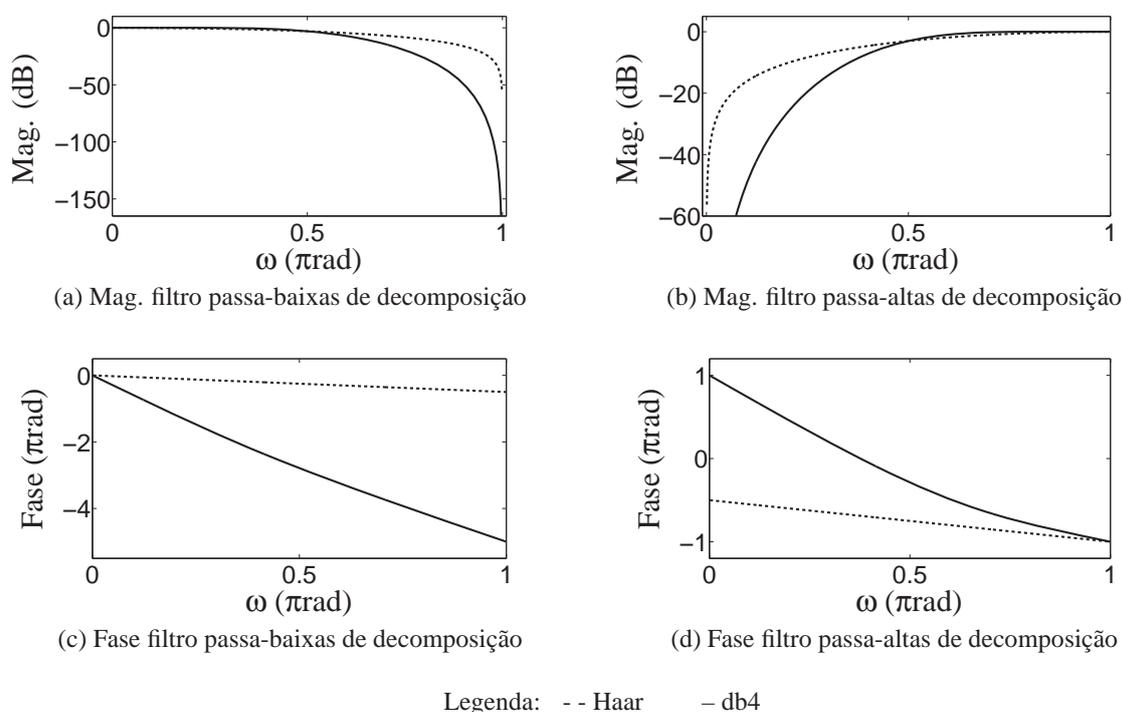
Os filtros  $L$  e  $H$  bi-particionam o sinal analisado. O processo de subamostragem gerado

pelo uso dos dizimadores poderia implicar numa condição de irreversibilidade, impedindo que o processo de reconstrução do sinal fosse utilizado. Entretanto, o projeto dos filtros é feito de maneira que a informação necessária para que haja a reconstrução seja mantida.

Se o processo de reconstrução é feito utilizando os próprios filtros  $L$  e  $H$  empregados no processo de análise, diz-se que o banco de filtros é ortogonal. Em contrapartida, se são necessários dois filtros  $L_1$  e  $H_1$  com características distintas as dos filtros utilizados no processo de análise, diz-se que os filtros são bi-ortogonais (MALLAT, 1999).

A Figura 22 apresenta a resposta em frequência e a fase de bancos de filtros utilizados para representar as famílias *db4* e *haar*, onde é possível observar as variações que ocorrem em função da escolha da família de wavelets.

Figura 22 - Resposta em frequência de um banco de filtros.



Fonte: Elaboração do próprio autor.

A vantagem da utilização dessa técnica empregando banco de filtros para a realização da análise de multirresolução é justamente a possibilidade de se utilizar plataformas com *hardware* dedicado para realizar todo o processo, como por exemplo, microcontroladores ou DSP's.

Os coeficientes de aproximação e detalhe podem ser obtidos através de uma operação de convolução entre a resposta impulsiva dos filtros e o sinal de entrada, conforme apresentado nas equações (47) e (48):

$$cA[n] = \sum_k L(n-2k)x[k], \quad (47)$$

$$cD[n] = \sum_k H(n-2k)x[k]. \quad (48)$$

Todo esse procedimento descrito até aqui é conhecido como algoritmo de Mallat e nada mais é do que uma operação de filtragem do sinal de entrada  $x[n]$  utilizando um banco de filtros com dizimadores acoplados nas saídas.

Esse processo pode ser repetido em cascata, gerando o chamado algoritmo piramidal. Entretanto, é importante ressaltar que para um sinal qualquer com  $m$  pontos, o número máximo de decomposições que pode ser realizado pode ser calculado utilizando a relação  $n_{max} = \log_2 m$  (SOARES, 2009).

### 3.10 Comentários

Neste capítulo abordaram-se os conceitos referentes à análise multirresolução, base para o desenvolvimento da transformada wavelet. Apresentaram-se as equações utilizadas para o cálculo da transformada wavelet, bem como o procedimento utilizado para tal.

Ademais, descreveu-se o método empregado por Mallat para implementar a transformada wavelet discreta através de sistemas digitais, permitindo assim a utilização da transformada em aplicações que utilizam sistemas embarcados.

Estes conceitos serão utilizados futuramente nos capítulos 5 e 6, onde serão abordados os problemas do esquiteamento de aves e da classificação de ovos.

## 4 DECOMPOSIÇÃO DE MODO EMPÍRICO

Neste capítulo será introduzido o conceito da decomposição de modo empírico. Inicialmente será realizada uma contextualização da técnica, relacionando a mesma a outras frequentemente utilizadas durante o processo de análise de sinais como, por exemplo, as transformadas de Fourier e wavelets. Será apresentado o procedimento para o cálculo da decomposição de modo empírico, bem como as principais características desse processo. Por fim, será realizada uma interpretação do significado físico das funções de modo intrínseco geradas a partir desse processo de decomposição.

### 4.1 Conceitos iniciais

A decomposição de modo empírico, denotada pela expressão EMD (do inglês, *Empirical Mode Decomposition*), é uma técnica desenvolvida por Huang e Shen (2005) para a realização de uma análise empírica não-linear de sinais complexos e não-estacionários. Essa técnica, ao ser utilizada em conjunto com a análise espectral de Hilbert, constitui uma ferramenta conhecida como transformada de Hilbert-Huang (HHT, do inglês, *Hilbert Huang Transform*).

A base utilizada para a realização dessas decomposições é adaptativa, capaz de representar sinais complexos e não-estacionários através de um somatório de funções denominadas funções de modo intrínseco - IMF (do inglês, *Intrinsic Mode Functions*) mais um resíduo.

Além de permitir a decomposição de sinais utilizando bases empíricas, a EMD também permite a reconstrução do sinal original sem que ocorra perda de informação ou distorção. Essa reconstrução é feita a partir de uma combinação entre as IMFs e o resíduo obtidos no processo de decomposição.

A ideia é similar ao proposto nas tradicionais análises de Fourier e wavelets, entretanto, a interpretação das IMFs não apresenta a mesma clareza matemática. Os resultados apresentados nas decomposições, embora fisicamente coerentes, utilizam uma base adaptativa, dificultando assim o estabelecimento de um conjunto de formulações matemáticas que garanta uma fundamentação teórica do método.

### 4.2 Procedimento para cálculo da EMD

O método EMD foi desenvolvido assumindo que toda série temporal não-linear e não-estacionária é composta por modos de oscilação intrínsecos. A essência desse método é identificar empiricamente esses modos de oscilação através das características de tempo e escala do sinal analisado. Dessa forma, o sinal de entrada original passa a ser representado através

de um conjunto de funções de modo intrínseco, definidas empiricamente de acordo com as características do sinal analisado.

O cálculo da EMD se baseia num processo denominado *sifting*, que corresponde à separação do sinal original em suas IMFs. Esse processo é capaz de extrair as características locais de um sinal sem que ocorra a sobreposição nos domínio do tempo e escala.

As seguintes condições são requeridas para o estabelecimento de uma IMF (ZEILER et al., 2010):

- Uma IMF apresenta apenas um extremo entre dois cruzamentos de zero subsequentes, isto é, o número de máximos e mínimos locais difere apenas por um;
- Uma IMF apresenta valor médio nulo.

Além das decomposições em IMFs, o processo de *sifting* acaba gerando um sinal de resíduo. Esse resíduo representa a parcela do sinal original que não pode ser representada através da utilização de IMFs, e é necessário para que seja realizada uma reconstrução do sinal original a partir de suas decomposições empíricas.

O processo de *sifting* pode ser representado através do algoritmo para cálculo da EMD. Através desse algoritmo, um sinal original  $x(t)$  é decomposto em suas IMFs  $x_n(t)$  e resíduo  $r(t)$ , como apresenta a equação (49):

$$x(t) = \sum_n x_n(t) + r(t). \quad (49)$$

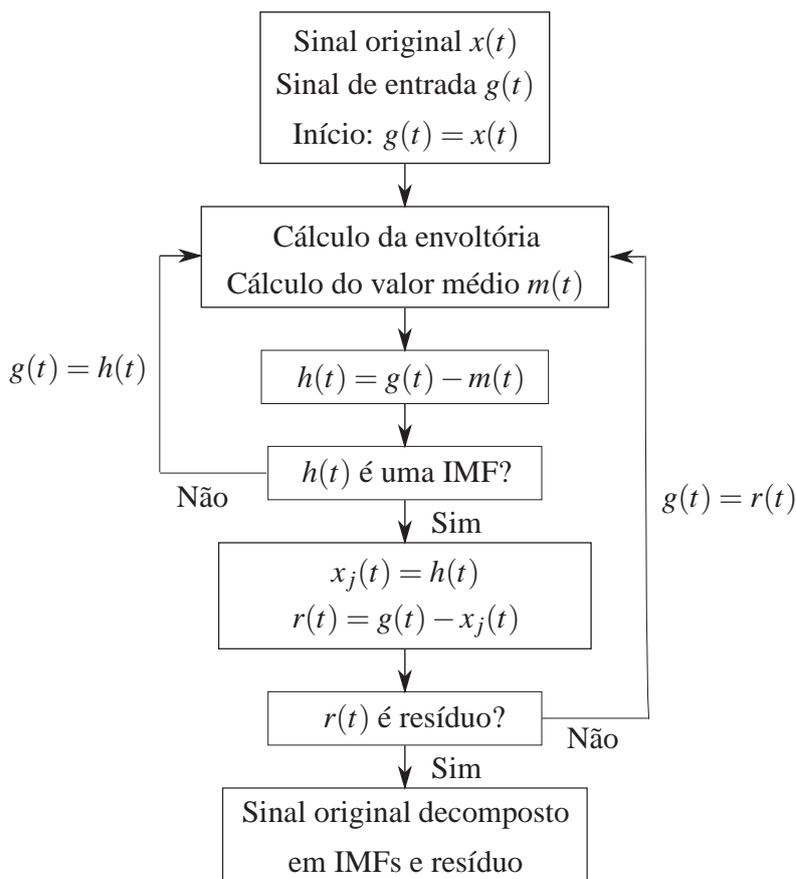
### 4.3 Algoritmo para o cálculo da EMD

O procedimento empregado pelo algoritmo para realizar a decomposição de modo empírico pode ser resumido através de um fluxograma, como o apresentado na Figura 23.

O processo descrito por esse fluxograma pode ser definido através de algumas etapas, conforme é apresentado na sequência (RILLING; FLANDRIN; GONÇALVES, 2003):

1. Define-se um contador  $n = 1$  e considera-se o resíduo  $r_0(t) = x(t)$ , sendo  $x(t)$  o sinal de entrada;
2. Processo de extração das  $n$ -ésimas IMFs:
  - (a) Define-se a função auxiliar  $h_0(t) = r_{n-1}(t)$  e um contador  $k = 1$ ;
  - (b) Identificam-se todos os máximos e mínimos locais de  $h_{k-1}(t)$ ;

Figura 23 - Fluxograma do processo utilizado para o cálculo da EMD.

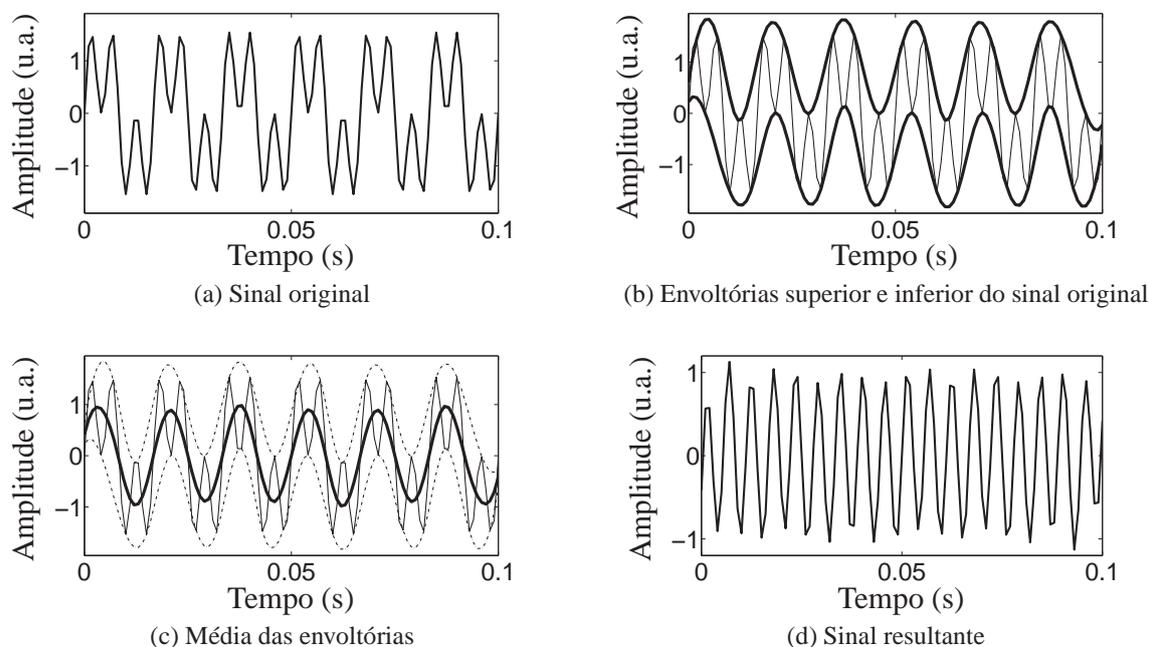


Fonte: Adaptado de Zeiler et al. (2010).

- (c) Através de interpolações utilizando *splines* cúbicos, calculam-se as envoltórias do sinal  $h_{k-1}(t)$ , sendo a envoltória obtida a partir dos valores máximos definida como  $U_{k-1}(t)$  e a envoltória obtida a partir dos valores mínimos definida como  $L_{k-1}(t)$ ;
- (d) Determina-se a média  $m_{k-1}(t) = \frac{1}{2}[U_{k-1}(t) + L_{k-1}(t)]$  das envoltórias geradas a partir da função  $h_{k-1}(t)$ ;
- (e) Subtrai-se o valor médio obtido a partir das envoltórias da função auxiliar  $h_{k-1}(t)$  :  
 $h_k(t) = h_{k-1}(t) - m_{k-1}(t)$
- i. Se a função resultante  $h_k(t)$  não está de acordo com as condições necessárias para o estabelecimento de uma IMF, incrementa-se o contador  $k$  ( $k = k + 1$ ) e repete-se o processo de *sifting* a partir da etapa (b);
  - ii. Se  $h_k(t)$  satisfaz os critérios para o estabelecimento de uma IMF, então define-se  $x_n(t) = h_k(t)$  e  $r_n(t) = r_{n-1}(t) - x_n(t)$ .
3. Se  $r_n(t)$  corresponde a um resíduo, interrompe-se o processo de *sifting*; caso contrário, incrementa-se o contador  $n$  ( $n = n + 1$ ) e reinicia-se o processo a partir da etapa 2.

Esse processo pode ser visualizado através da Figura 24, que ilustra o método descrito anteriormente para a extração de uma IMF a partir de um sinal qualquer.

Figura 24 - Procedimento para cálculo da EMD.



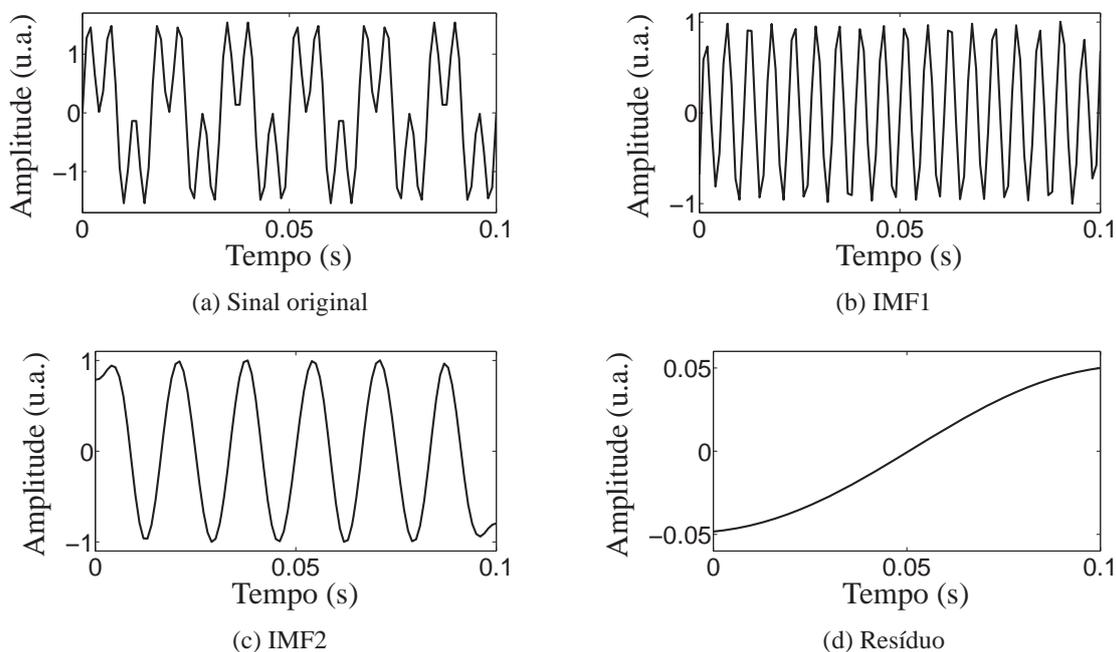
Fonte: Elaboração do próprio autor.

O sinal original (Figura 24(a)) é composto por duas senoides com frequências fixas, respectivamente. Como descrito anteriormente, a primeira etapa para a extração de uma IMF consiste na identificação dos valores de máximo e mínimo a fim de se determinar as envoltórias superior e inferior do sinal (Figura 24(b)).

Na sequência, calcula-se a média das envoltórias (Figura 24(c)) e subtrai-se esse médio obtido a partir das envoltórias do sinal original, culminando num sinal resultante (Figura 24(d)). Então, verifica-se se o sinal resultante obedece os critérios pré-estabelecidos para ser considerado uma IMF. Caso obedeça, o processo é interrompido; caso contrário, repete-se o procedimento até que a condição seja atendida.

Um exemplo é apresentado na Figura 25. Nesse exemplo, é realizada a decomposição de modo intrínseco de um sinal  $x(t)$  composto por duas senoides de 60 e 180 Hz, respectivamente.

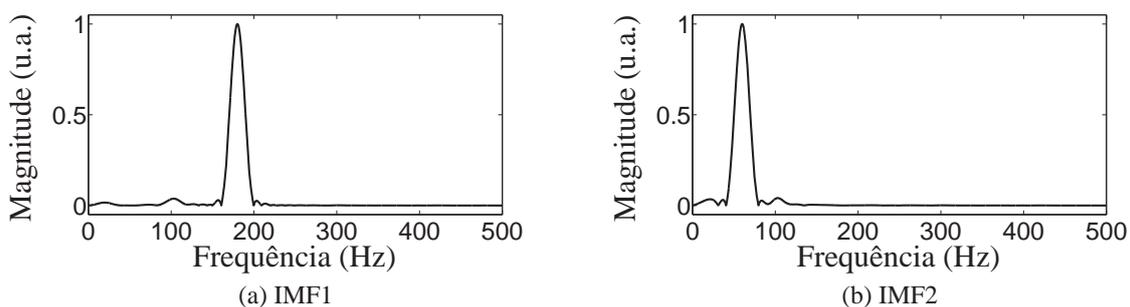
Figura 25 - Decomposição de um sinal em IMFs.



Fonte: Elaboração do próprio autor.

É possível notar que o sinal original, apresentado na Figura 25(a), foi decomposto em duas IMF's, apresentadas nas Figuras 25(b) e 25(c), além de um resíduo, apresentado na Figura 25(d). A análise espectral dessas IMF's é apresentada na Figura 26.

Figura 26 - Análise espectral das IMF's.



Fonte: Elaboração do próprio autor.

Nota-se da Figura 26 que a primeira IMF (Figura 26(a)) apresenta o sinal senoidal de 180 Hz, enquanto a segunda IMF (Figura 26(b)) apresenta a senoide de 60 Hz.

## 4.4 Características do processo de decomposição de modo empírico

O número médio de iterações necessárias para a obtenção de cada IMF pode ser calculado dividindo-se duas vezes o número de amostras do sinal ( $2N$ ) pelo seu número de cruzamentos com zero. Ademais, o número máximo de IMFs gerado para cada sinal será, aproximadamente,  $\log_2(N)$  (ZEILER et al., 2010).

O critério de parada do processo de *sifting* é função da amplitude da IMF relacionada. Dessa forma, é realizada a decomposição do sinal de entrada em IMFs até que o nível mais elevado de decomposição atenda a um critério de parada pré-estabelecido.

Um dos critérios utilizados para a parada do processo de *sifting* utiliza a função  $\sigma(t)$ , conforme apresenta a equação (50):

$$\sigma(t) = \frac{U(t) + L(t)}{U(t) - L(t)}. \quad (50)$$

Além da função definida na equação (50), são utilizados dois limiares,  $\delta_1$  e  $\delta_2$ , e um parâmetro  $\alpha \in [0, 1]$  para a realização da parada do processo de decomposição.

A partir desses parâmetros, o processo de *sifting* é calculado até que  $\sigma(t) < \delta_1$  num intervalo de amostras correspondente à fração  $(1 - \alpha)$  do número total de amostras do sinal original  $x(t)$  e  $\sigma(t) < \delta_2$  para o restante das amostras do sinal. Valores típicos para os parâmetros mencionados são  $\alpha \approx 0.05$ ,  $\delta_1 \approx 0.05$  e  $\delta_2 \approx 10\delta_1$  (RILLING; FLANDRIN; GONÇALVES, 2003).

Ao final do processo, será gerado um sinal que pode apresentar um valor constante, uma inclinação monotônica ou ainda apenas um extremo. Esse sinal é definido como resíduo  $r(t)$  e é necessário para o processo de reconstrução do sinal original a partir das IMFs.

Uma característica da EMD é que esta técnica não se baseia na utilização de filtros passa-faixas com resposta em frequência pré-estabelecida como ocorre, por exemplo, no caso das wavelets. Dessa forma, as IMFs são obtidas a partir de um processo de filtragem automático e adaptativo.

O algoritmo da EMD produz IMFs localmente ortogonais. Entretanto, a ortogonalidade global das IMFs não é garantida, uma vez que IMFs distintas podem apresentar frequências idênticas em instantes de tempo distintos (tipicamente, esse fato ocorre em menos de 1% dos casos).

O processo utilizado pelo algoritmo da EMD apresenta algumas deficiências. Dentre elas, destacam-se (ZEILER et al., 2010):

1. Cálculo das envoltórias: O problema está no modo como as envoltórias  $U(t)$  e  $L(t)$  são

calculadas. A técnica mais utilizada emprega *splines* para a criação dessas envoltórias. Os *splines* representam funções compostas por polinômios de ordem  $n$ , e que obedecem a algumas condições como, por exemplo, serem contínuas e continuamente diferenciáveis por  $(n - 1)$  vezes. Essas envoltórias são utilizadas como base para o cálculo da média local dos sinais e, normalmente, são obtidas através da utilização de *splines* cúbicos. Essa interpolação normalmente gera bons resultados, entretanto, o custo computacional para a realização da mesma é alto.

2. Condições de contorno: a interpolação usando *splines* pode apresentar falhas nas extremidades de um intervalo. Dessa forma, é possível que essas falhas induzam a variações no início e fim do conjunto de dados analisado, acarretando em resultados que não condizem com as características físicas do sistema analisado. Por tratar-se de um processo iterativo, esses resultados podem se propagar até as decomposições de ordem mais elevada.
3. Critério de parada do processo de *sifting*: durante o cálculo da EMD, o processo de *sifting* é realizado até que a média dos sinais de envoltória analisados atinja um valor aproximadamente nulo. Sendo assim, esse critério depende diretamente da amplitude da IMF relacionada. Devido a essas características, pode ocorrer o chamado *over-sifting*, que tende a dividir uma IMF em fragmentos sem significado físico.
4. Amplitude e resolução em frequência: escolhas inadequadas dos parâmetros mencionados anteriormente podem afetar diretamente a qualidade das IMFs em relação às suas características de amplitude e frequência. Ademais, formas de onda que apresentam oscilações com amplitude muito baixa também não serão detectadas nesse tipo de análise. Em relação à resolução em frequência, o processo utilizado pela EMD se comporta como um banco de filtros diádico. Isso ocorre pois o número de extremos de cada IMF é reduzido pela metade de uma IMF a outra, fazendo com que a frequência máxima do sinal seja reduzida pela metade a cada IMF gerada. Ademais, convém ressaltar que a sobreposição de dois sinais que apresentam uma mesma frequência  $\omega$  não será detectada através de IMFs diferentes.

## 4.5 Interpretação das IMFs

Por ser uma técnica fundamentalmente empírica, não há a possibilidade de se avaliar teoricamente os resultados da EMD, exigindo dessa forma que, para a garantia de resultados confiáveis, o processo seja repetido por um grande número de vezes.

Ademais, não se pode garantir que as IMFs obtidas através das decomposições apresentarão significado físico coerente. Entretanto, essa afirmação também é válida para os outros métodos que envolvem uma análise utilizando base fixa (ZEILER et al., 2010).

A avaliação da qualidade do processo de *sifting* pode ser feita analisando o número máximo de iterações necessárias para a extração de cada IMF. Dessa forma, considera-se um processo eficiente aquele capaz de extrair informações de um sinal original  $x(t)$  através de IMFs sem que esse processo apresente um custo computacional muito elevado.

## 4.6 Comentários

O fato da decomposição de modo empírico utilizar uma base adaptativa para representar um determinado sinal em análise faz dessa técnica uma ferramenta bastante versátil para representar sinais que não apresentam um padrão matemático.

O processo de interpolação utilizado durante o cálculo das envoltórias é um dos grandes fatores limitantes desse processo, pois o número de iterações depende do tipo de sinal que se está buscando interpolar. Dessa forma, o tempo de convergência não será constante, dificultando a utilização do método em aplicações onde o tempo de processamento deve ser rigorosamente o mesmo.

Em suma, o procedimento para cálculo das IMF's, embora apresente relativa simplicidade, tem um alto custo computacional, inviabilizando a utilização da técnica em plataformas com baixa capacidade de processamento.

Os conceitos abordados nesse capítulo serão utilizados futuramente nos capítulos 5 e 6, onde serão abordados os problemas do esquiteamento de aves e da classificação de ovos.

## 5 SISTEMA DE PROTEÇÃO CONTRA ACIDENTES DURANTE O ESQUARTEJAMENTO DE AVES

Neste capítulo é apresentado o problema envolvendo a operação de esquartejamento de aves em frigoríficos. São apresentadas as metodologias utilizadas para abordá-lo, bem como os resultados obtidos durante o processo de classificação de sinais. Para facilitar a análise destes resultados, os mesmos foram agrupados de acordo com a técnica utilizada para classificá-los.

### 5.1 Descrição do problema

O esquartejamento de aves é um processo frequentemente utilizado na indústria frigorífica e tem por objetivo separar as aves abatidas em partes diversas que, posteriormente, serão comercializadas.

Esse processo pode ser feito utilizando um sistema automatizado, como já ocorre em alguns frigoríficos. Entretanto, devido às grandes variações tanto de peso quanto de tamanho das aves que serão esquartejadas, grande parte dos frigoríficos opta por utilizar trabalhadores para a realização desse processo de corte. A Figura 27 apresenta uma foto de um trabalhador operando um sistema de esquartejamento de aves.

Figura 27 - Trabalhador operando um sistema de esquartejamento de aves.



Fonte: Elaboração do próprio autor.

Durante o processo de esquartejamento, o trabalhador segura com as mãos a parte da ave que deseja cortar e a leva ao contato da serra, até que a mesma seja cortada. Como forma de proteção, são utilizadas luvas de aço inoxidável, conforme apresenta a Figura 28.

Essas luvas são confeccionadas utilizando uma liga metálica de ferro, cromo e níquel. Essa liga é utilizada na construção dos elos que constituem a luva, atendendo a um conjunto de normas pré-estabelecidas, tais como a NR-6, a EN1082-1, a EN14328, a EN1811 e a ISO 13999. Essas normas definem que o arame utilizado para a confecção dos elos deve apresentar bitola

Figura 28 - Luva utilizada durante o processo de esquartejamento de aves.



Fonte: R3EPI Soluções em equipamentos de segurança (2011).

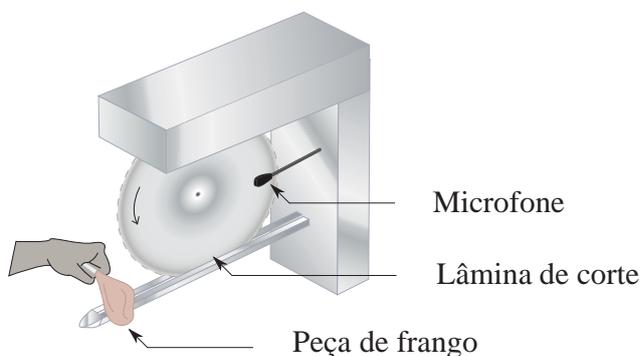
de 0,55mm e os elos que constituirão a luva deverão apresentar diâmetro interno de 2,90mm. Ademais, são fabricadas em tamanhos distintos, escolhidos de acordo com o tamanho da mão do trabalhador que as irá manusear (R3EPI SOLUÇÕES EM EQUIPAMENTOS DE SEGURANÇA, 2011).

Embora seja desenvolvida para evitar acidentes, a luva acaba servindo efetivamente como equipamento de proteção apenas nos casos onde ocorrem leves toques na serra. Dessa forma, em casos onde o contato entre a luva e a serra é mais forte, é possível que a luva seja rompida, ocasionando desde pequenos cortes até mesmo a amputação de uma parte da mão envolvida no acidente.

Baseando-se nesse problema surge a seguinte proposta: analisar os sons gerados durante o processo de esquartejamento de aves e classificar os mesmos, de modo que um sistema de frenagem possa ser acionado nos instantes em que o som gerado seja o correspondente ao toque acidental entre luva e serra, evitando dessa forma que a luva seja cortada e que a mão do trabalhador envolvido seja atingida (PEREIRA et al., 2008).

O sistema utilizado durante o processo de corte é composto por um motor, uma serra circular e uma haste de sustentação utilizada para apoiar a parte da ave que se deseja cortar. Um esboço desse sistema é apresentado na Figura 29.

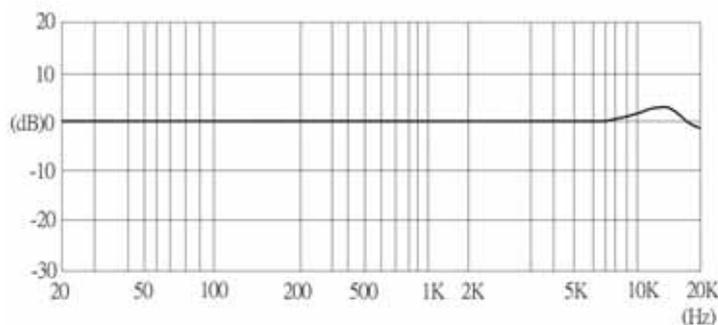
Figura 29 - Equipamento utilizado durante o processo de esquartejamento de aves.



Fonte: Adaptado de Pereira et al. (2008).

A fim de se capturar os sons gerados durante o processo, acoplou-se um microfone de eletreto a esse sistema. A Figura 30 apresenta a resposta em frequência do eletreto utilizado para adquirir os dados. Suas características construtivas são apresentadas na Tabela 1.

Figura 30 - Resposta em frequência do microfone utilizado .



Fonte: Kingstate Eletronics Corp. (2011).

Tabela 1 - Características do microfone utilizado.

Dados técnicos	
Diretividade	Omnidirecional
Sensibilidade	-42 dB $\pm$ 3 dB
Tensão de operação padrão	2 Vcc
Impedância de saída	2,2 k $\Omega$
Tensão de operação máxima	10Vcc
Frequência de operação	20 Hz $\sim$ 20 kHz
Relação sinal ruído	58 dBA
Temperatura de operação	-20°C $\sim$ +70°C

Fonte: Kingstate Eletronics Corp. (2011).

A fixação do microfone foi feita numa região onde o mesmo não fosse atingido por muitos resíduos durante a operação de corte, resíduos estes que poderiam reduzir sua eficiência. A definição da localização também levou em conta o dia-a-dia dos trabalhadores, optando-se por uma localização que não atrapalhasse o serviço dos mesmos.

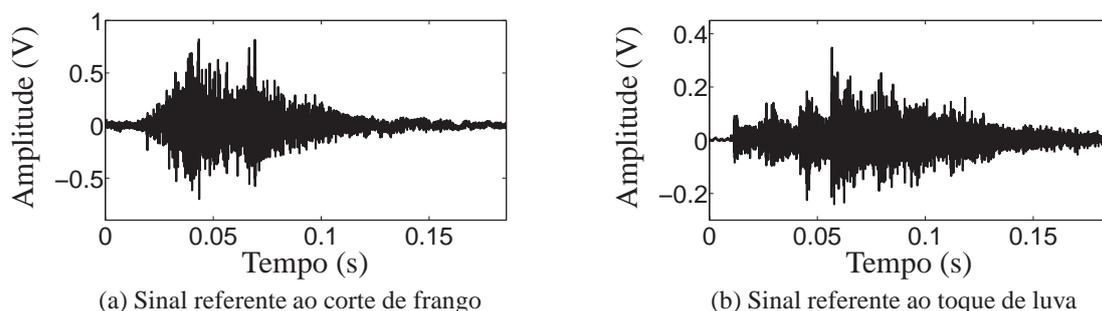
A aquisição do sinal captado pelo microfone foi realizada utilizando a placa de som de um micro-computador. Essa placa efetuava a amostragem utilizando um conversor analógico-digital de dezesseis bits a uma frequência de 44,1kHz. A análise dos sinais adquiridos foi feita utilizando um microcomputador e *software* Matlab. Dessa forma, a partir dos dados reais, foram efetuados vários tipos de simulações distintas buscando o método que melhor separasse os sinais.

Ao longo do trabalho, define-se como amostra o sinal adquirido pelo sistema de aquisição. Dessa forma, cada som gerado por um toque de luva ou um corte de frango é chamado de

amostra. Cada amostra é composta por vários pontos adquiridos durante o intervalo de tempo em que ocorre o contato entre o material e a serra. Esses pontos foram utilizados como fonte de informação para as operações de processamento.

A Figura 31 apresenta um exemplo de sinais acústicos adquiridos pelo sistema utilizando a placa de som. Esses sinais foram gerados a partir do corte de frango e de um leve toque da luva na serra e estão representados no domínio do tempo.

Figura 31 - Sinais provenientes da operação de esquitejamento de aves.



Fonte: Elaboração do próprio autor.

Durante todo o ensaio, optou-se por utilizar toques suaves entre luva e serra. Essa medida foi adotada para aumentar a sensibilidade do sistema, haja vista que se o sistema é capaz de detectar um toque suave, certamente será capaz de detectar um acidente mais grave. O experimento foi realizado com o auxílio de profissionais treinados, cabendo a eles a definição do que seria considerado como toque mais forte e do que seria considerado como toque suave.

A partir dos dados adquiridos, deu-se início à etapa de processamento dos mesmos. Para tanto, inicialmente utilizou-se uma operação de filtragem. Essa operação tem como principal vantagem sua simplicidade e baixo custo computacional, entretanto, não é uma análise multirresolução.

Em seguida, optou-se por processar os mesmos sinais utilizando técnicas de análise multirresolução. Inicialmente, o problema foi abordado utilizando wavelets e, na sequência, utilizando a decomposição de modo empírico.

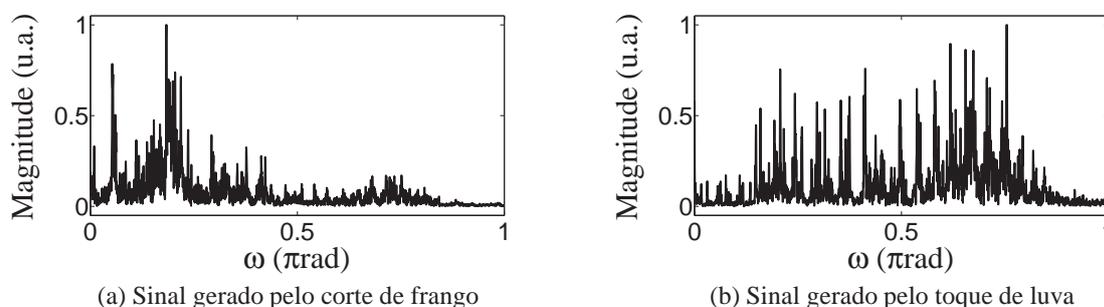
Os resultados obtidos, bem como os métodos utilizados para cada caso, são descritos na sequência.

## 5.2 Classificação dos sinais utilizando um filtro passa-faixas

A proposta inicial para separar os sinais gerados durante a operação de esquitejamento de aves baseou-se numa operação de filtragem. Dessa forma, a primeira tarefa realizada após a aquisição dos dados foi realizar a análise espectral dos mesmos, buscando uma faixa de fre-

quências que pudesse ser utilizada para distinguir os sinais. O resultado dessa análise para os sinais apresentados anteriormente é ilustrado na Figura 32.

Figura 32 - Análise espectral dos sinais gerados durante o esquiteamento de aves - análise inicial.

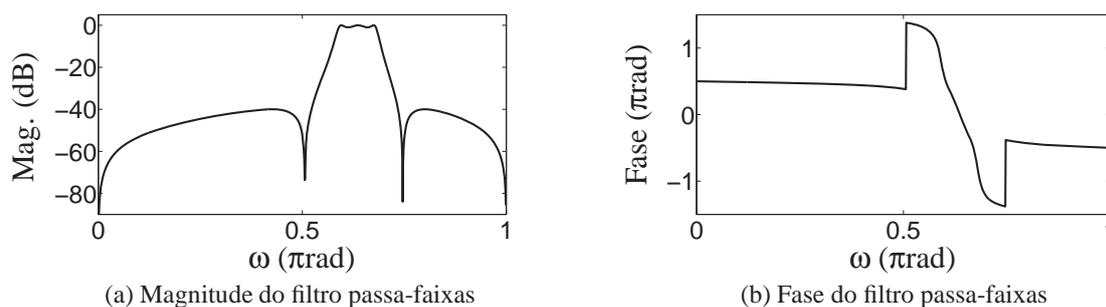


Fonte: Elaboração do próprio autor.

Da Figura 32, nota-se que há uma faixa de frequências que pode ser utilizada como informação para separar os sinais. Dessa forma, utilizando um filtro passa-faixas, seria possível distinguir os sinais e ativar um sistema de frenagem.

Projetou-se então um filtro elíptico passa-faixas, com banda passante entre  $0.5896\pi\text{rad}$  e  $0.6803\pi\text{rad}$ , frequências de corte entre  $0.4989\pi\text{rad}$  e  $0.7710\pi\text{rad}$  e atenuação de 40dB na faixa de rejeição, cujas respostas em frequência de magnitude e fase estão apresentadas na Figura 33.

Figura 33 - Resposta em frequência do filtro utilizado para separar os sinais provenientes do esquiteamento de aves.



Fonte: Elaboração do próprio autor.

A fim de se maximizar as diferenças entre os sinais, após o processo de filtragem calculou-se a energia parcial dos mesmos. Para tanto, os sinais foram elevados ao quadrado e somados em grupos de 128 pontos, conforme apresenta a equação (55):

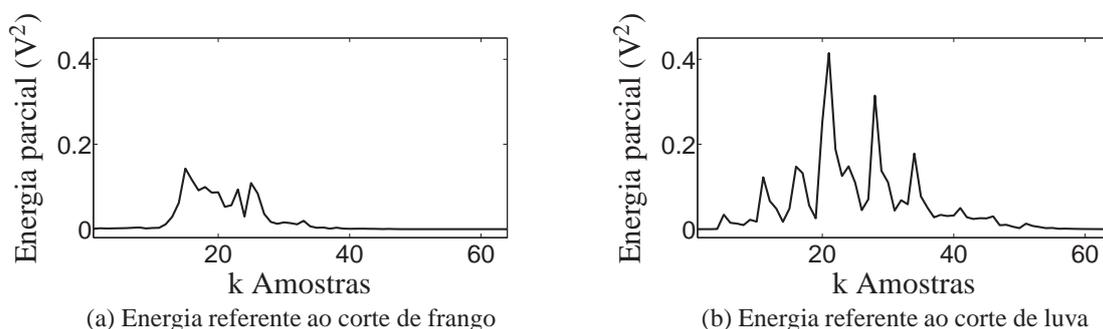
$$E[k] = \sum_{n=(k-1)128}^{(128k-1)} [y[n]]^2, \quad k = 1, \dots, N/128, \quad (51)$$

sendo  $N$  o número de pontos do sinal.

Optou-se por utilizar somente 128 pontos justamente para tornar o processo rápido o suficiente para detectar o toque accidental de luva na serra a tempo de se evitar que um acidente ocorra. Esse número foi definido empiricamente e utilizado ao longo da análise.

A Figura 34 apresenta um exemplo da utilização dessa equação. Nela, apresenta-se o resultado obtido após o processo de filtragem e do cálculo da energia dos sinais apresentados anteriormente na Figura 31.

Figura 34 - Energia dos sinais individuais.



Fonte: Elaboração do próprio autor.

Ressalta-se que cada amostra  $k$  presente na figura representa o resultado do cálculo da energia parcial de grupos de 128 pontos. Para cada amostra analisada, foram armazenados somente os valores de pico obtidos a partir do cálculo da energia parcial dos sinais filtrados. É possível notar que, nesta análise, o valor de pico referente ao som gerado pelo corte de frango é menor do que o valor de pico calculado a partir do som envolvendo o toque de luva na serra.

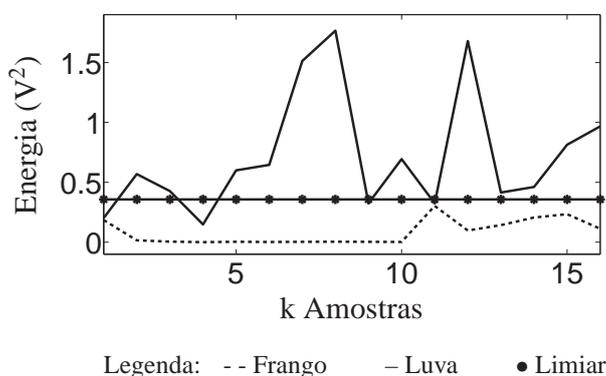
A partir dessa observação, calculou-se um valor de limiar fixo definido pela média dos valores de pico provenientes do som gerado pelo corte de frango. Esse limiar foi calculado utilizando um espaço amostral de 112 amostras. Baseado na definição desse limiar, essa técnica considera como sinais provenientes de acidente todos aqueles cujo valor de energia seja superior a esse valor pré-estabelecido.

Para validar a técnica, inicialmente realizou-se a análise de dezesseis amostras de sinais gerados a partir do corte de frango e dezesseis amostras de sinais gerados a partir do toque accidental de luva na serra. Por ser uma análise inicial, foram serrados pedaços de frango que não apresentavam ossos muito grossos, como por exemplo, partes da asa. O resultado é apresentado na Figura 35.

É possível notar que grande parte do número de pontos de energia referentes ao toque de luva na serra apresenta-se acima do nível de limiar pré-estabelecido.

Verifica-se que, por se tratarem de toques suaves, alguns toques apresentaram energia tão

Figura 35 - Energia calculada a partir do sinal filtrado - análise inicial.

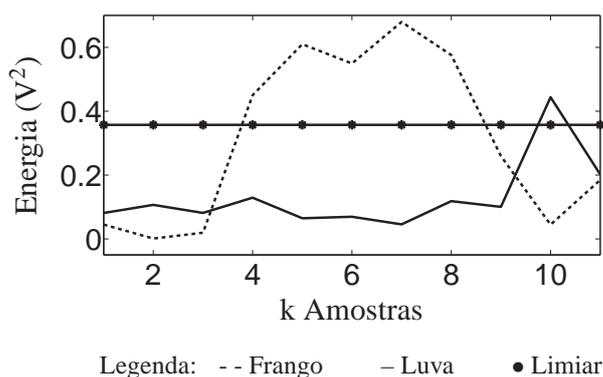


Fonte: Elaboração do próprio autor.

baixa que não puderam ser detectados, ou seja, houve momentos em que ocorreu o contato da luva com a serra e esse toque não foi detectado, pois se confundiu com o corte de frango. Para o caso ilustrado pela Figura 35, o índice de toques detectados foi de 75%.

Na sequência, a proposta foi realizar o mesmo procedimento analisando o som gerado pelo tipo de corte considerado pelos trabalhadores como sendo o mais difícil: o corte de frango à passarinho. Nesse tipo de corte, são serrados ossos mais grossos, como os da coxa. O resultado dessa análise é apresentado na Figura 36.

Figura 36 - Energia calculada a partir do sinal filtrado - corte de ossos.



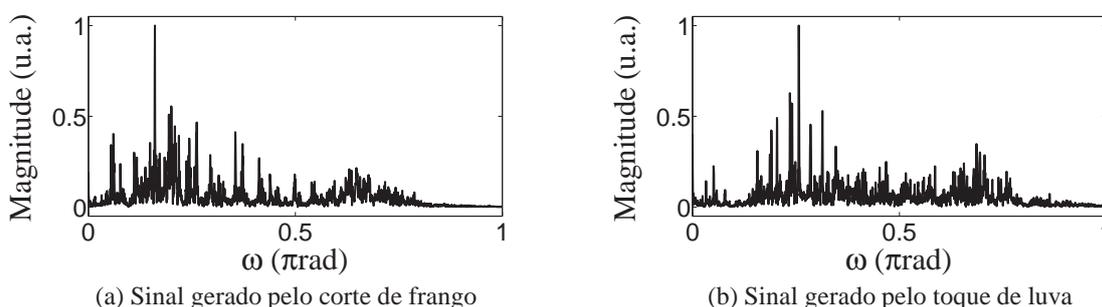
Fonte: Elaboração do próprio autor.

Utilizando o mesmo valor de limiar definido anteriormente, foram analisados onze sinais gerados pelo corte de frango e onze gerados pelo toque suave da luva. Nessa análise, apenas 9,09% dos sinais referentes ao toque de luva foram detectados. Além disso, alguns pontos gerados por sinais referentes ao corte de frango foram detectados como toque acidental de luva na serra, constituindo os chamados falsos positivos.

Convém ressaltar que o índice de acertos refere-se aos toques de luva identificados, não tendo relação com o índice de falsos positivos, que avalia apenas a quantidade de sinais de frango que é identificada pelo sistema como sendo proveniente de toques acidentais de luva.

O índice de falsos positivos para este caso apresentado foi de 45,45%, ou seja, o sistema mais errou do que acertou. Uma nova análise espectral foi feita utilizando uma das amostras do caso anterior. O resultado é apresentado na Figura 37.

Figura 37 - Análise espectral dos sinais gerados durante o esquartejamento de aves - corte de ossos.



Fonte: Elaboração do próprio autor.

Observando a Figura 37, nota-se que não há mais uma região do espectro que pode ser utilizada para separar os sinais, limitando dessa forma a utilização dessa técnica.

A análise foi estendida para um total de duzentas e vinte e quatro amostras divididas entre corte de frango e toque de luva e os resultados são apresentados na Tabela 2.

Tabela 2 - Detecção com filtro passa-faixas.

	Filtro passa-faixas
Acertos (%)	69,64
Falsos Positivos (%)	45,54

Fonte: Elaboração do próprio autor.

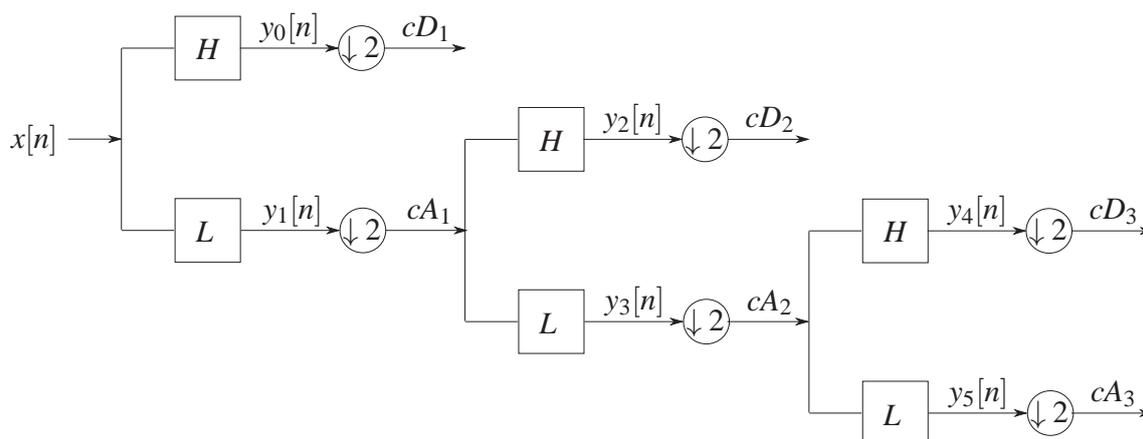
Da Tabela 2, é possível notar que apesar do índice de acertos desse método ter sido alto, haja vista que foram realizados ensaios envolvendo toques suaves de luva na serra, houve um elevado número de falsos positivos.

Dessa forma, a utilização dessa técnica para identificar os acidentes torna-se inviável do ponto de vista do empregador, uma vez que o rendimento do trabalho seria muito baixo. Ademais, o acionamento constante do sistema de frenagem da serra reduziria a vida útil tanto do equipamento utilizado para frear a máquina quanto no próprio motor que impulsiona a serra.

### 5.3 Classificação dos sinais utilizando a DWT

Na sequência, foram analisados os mesmos sinais apresentados anteriormente ao descrever o sistema com um filtro passa-faixas, utilizando agora a transformada wavelet discreta. Inicialmente realizou-se a decomposição dos sinais, utilizando para isso um banco de filtros, conforme apresentado na Figura 38.

Figura 38 - Banco de filtros utilizado durante o processo de classificação.



Fonte: Adaptado de Gomes, Velho e Goldenstein (1997).

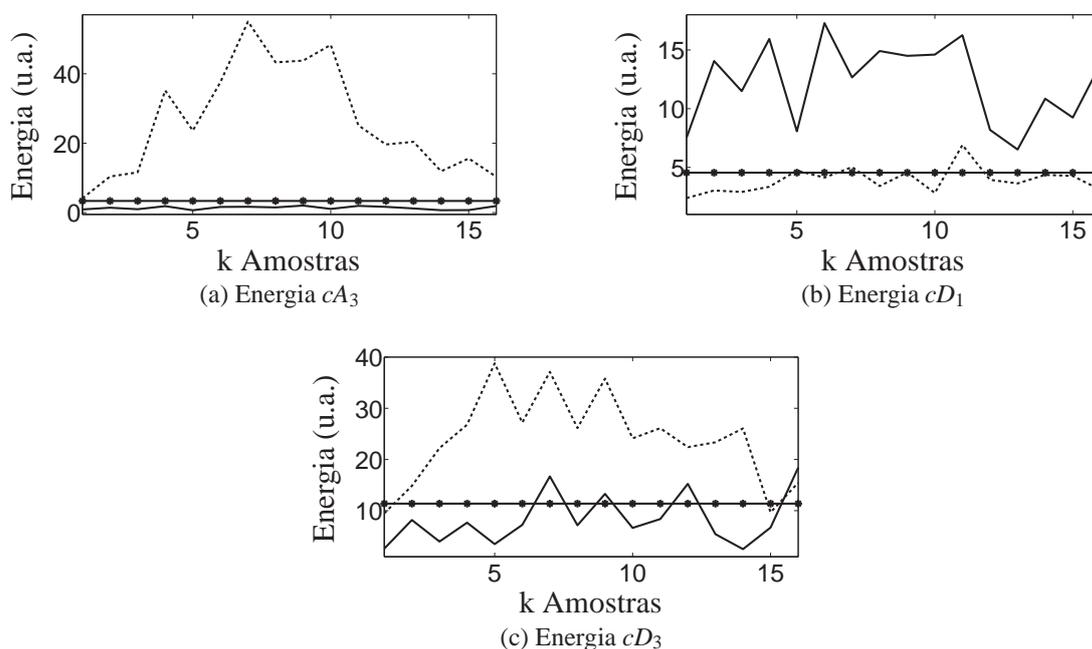
Na primeira análise, optou-se por realizar três níveis de decomposição. Após decompor os sinais, calculou-se a energia parcial dos mesmos de maneira análoga à descrita anteriormente, armazenando apenas os valores de pico de energia para cada uma das decomposições.

Repetiu-se então a análise proposta anteriormente, substituindo o filtro passa-faixas pelo banco de filtros utilizado para realizar a decomposição com wavelets. Para tanto, os ensaios apresentados anteriormente foram refeitos utilizando a decomposição com a família de wavelets de Haar. A análise do caso inicial apresentado pela Figura 35, onde não são efetuados cortes de ossos muito grossos, é apresentada na Figura 39.

Durante a análise, utilizaram-se os coeficientes de detalhe  $cD_1$  e  $cD_3$ , além do coeficiente de aproximação  $cA_3$ . Os coeficientes de aproximação  $cA_1$  e  $cA_2$  não foram utilizados por apresentarem características semelhantes às encontradas na aproximação  $cA_3$  e o coeficiente de detalhe  $cD_2$  não foi utilizado pois nesse estágio de decomposição não foi possível separar os sinais.

Uma alteração foi proposta em relação à análise utilizando apenas um filtro passa-faixas: antes de realizar o processo de decomposição, os sinais foram normalizados em função de seus valores máximos absolutos. O objetivo dessa normalização é minimizar tanto os efeitos dos circuitos de condicionamento de sinais quanto os efeitos do posicionamento do microfone que será utilizado para captar os sons junto à serra, reduzindo a influência das variações de ganho

Figura 39 - Energia calculada a partir do resultado da DWT.



Legenda: -- Frango    – Luva    • Limiar

Fonte: Elaboração do próprio autor.

ocorridas durante a aquisição dos sinais

Da Figura 39, nota-se que o toque acidental de luva na serra pode ser identificado através da análise da energia gerada a partir dos coeficientes de detalhe  $cD_1$ , enquanto o som gerado pelo corte de frango pode ser identificado a partir dos coeficientes de aproximação  $cA_3$  e dos coeficientes de detalhe  $cD_3$ .

Assim como no caso envolvendo o filtro passa-faixas, optou-se por utilizar valores de limiar fixo. Dessa forma, empregando um espaço amostral de 112 amostras de frango, definiram-se limiares fixos utilizando os valores de pico de energia calculados a partir das decomposições  $cA_3$  e  $cD_3$  e, empregando um espaço amostral de 112 amostras de luva, definiu-se um limiar fixo utilizando valores de pico de energia calculados a partir da decomposição  $cD_1$ .

Definindo nível lógico 1 para sinais de energia que superam o valor do limiar e nível lógico 0 para sinais que não ultrapassam o limiar, utilizaram-se variáveis lógicas auxiliares para identificar a ocorrência de acidente. Sendo assim, se o valor de energia apresentado pela decomposição  $cD_1$  for maior que o valor de limiar pré-estabelecido, uma variável lógica auxiliar  $D1$  assume o valor 1; caso contrário, essa variável lógica assume o valor 0.

A partir dessas observações, define-se a condição de acidente através da seguinte operação lógica:

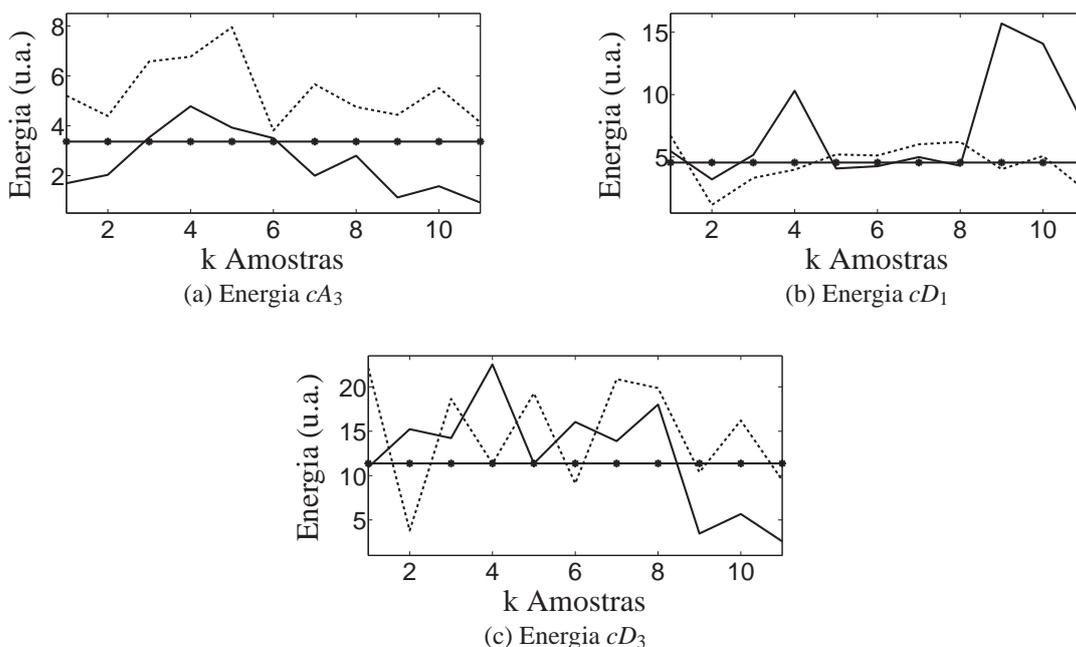
$$Acidente = D1.\overline{(A3.D3)}, \quad (52)$$

sendo  $A3$ ,  $D1$  e  $D3$  as variáveis lógicas utilizadas para indicar que o limiar foi ou não alcançado.

Dessa forma, o índice  $Acidente = 1$  indica que o sistema de frenagem deve ser acionado, enquanto o índice  $Acidente = 0$  indica um procedimento normal de trabalho.

Na análise apresentada na Figura 39, utilizou-se a família de wavelets de Haar. Verifica-se que, para o caso mais simples, todos os toques de luva foram detectados, não havendo a ocorrência de falsos positivos. O mesmo procedimento foi repetido para o caso envolvendo o corte de frango à passarinho, apresentado anteriormente pela Figura 36. O resultado é apresentado na Figura 40.

Figura 40 - Energia calculada a partir do resultado da DWT - corte de ossos.



Legenda: - - Frango      - Luva      • Limiar

Fonte: Elaboração do próprio autor.

Para o caso mais complicado, o índice de acertos do método utilizando wavelets foi de 45,45%, enquanto o índice de falsos positivos foi de 9,09%. Embora ainda tenham ocorrido falsos positivos, fica clara a eficiência do método utilizando wavelets em relação ao baseado apenas numa operação de filtragem.

A análise foi estendida para um total de duzentas e vinte e quatro amostras divididas entre corte de frango e toque de luva, as mesmas utilizadas anteriormente durante o processo de

classificação utilizando um filtro passa-faixas. Os resultados obtidos são apresentados na Tabela 3, onde são relacionados os índices de acertos e falsos positivos de cada família de wavelets utilizada durante o processo de decomposição.

Tabela 3 - Detecção de acidentes utilizando três decomposições.

	Família				
	haar	dmey	db4	db10	sym2
Acertos (%)	76,79	79,46	78,57	81,25	74,11
Falsos Positivos (%)	7,14	11,61	12,50	11,61	10,71

	Família				
	sym10	bior1.1	bior2.8	coif4	coif5
Acertos (%)	79,46	76,79	78,57	79,46	80,36
Falsos Positivos (%)	13,39	7,14	8,93	13,39	12,50

Fonte: Elaboração do próprio autor.

Analisando os resultados da técnica proposta, nota-se que o maior índice de acertos, ou seja, o maior número de toques de luva detectados, foi obtido pela família db10. O problema é que essa mesma família apresentou um dos maiores índices de falsos positivos, limitando dessa forma sua aplicação. Ademais, tem-se como outro fator limitante o número de coeficientes necessário para se implementar essa família utilizando um banco de filtros (para o caso da db10, seriam necessários 20 coeficientes, gerando um atraso de 20 amostras por estágio de decomposição).

Observando agora o resultado apresentado pela família Haar, nota-se que embora o índice de acertos não tenha sido o maior ao compará-lo com as demais famílias, o índice de falsos positivos foi um dos menores obtidos. Um dos fatores que justificam esse resultado é o fato da família Haar apresentar um suporte compacto, fato este que faz com que essa família seja comumente empregada para identificar fenômenos de curta duração, como por exemplo, bordas em imagens.

Dessa forma, relacionando essa informação ao fato de os sons gerados pelo corte de frango apresentarem uma energia maior na região de baixa frequência, ou seja, transições mais lentas, justifica-se o fato do índice de falsos positivos ter sido menor.

Convém ressaltar que o critério utilizado para a tomada de decisões influencia diretamente os resultados obtidos. Dessa forma, têm-se que a família de Haar, para as condições apresentadas, mostra-se mais eficiente para separar os sinais do que a família db10, o que não quer dizer que uma família é melhor ou pior do que a outra para representar um sinal, haja vista que ambas constituem uma base ortogonal.

Ademais, a família Haar apresenta como grande vantagem o fato de poder ser implementada

utilizando filtros de apenas dois coeficientes, tornando o tempo de atraso menor e permitindo a utilização de um *hardware* com menor poder computacional.

Na sequência, a análise foi refeita alterando-se o número de decomposições, que passou de três para cinco. Essa alteração foi feita com o objetivo de se tentar encontrar um nível de decomposição capaz de separar melhor os sinais e, por conseguinte, reduzir o número de falsos positivos apresentado na abordagem anterior.

Optou-se por realizar, no máximo, cinco decomposições. Esse número se baseou no tempo de atraso envolvido no processo de decomposição, uma vez que para um sinal alcançar o quinto nível, será necessário que o mesmo passe por cinco filtros digitais em cascata.

Nessa nova análise, notou-se que através da decomposição  $cD_5$  é possível detectar os instantes em que ocorrem cortes de frango. Optou-se então por combinar as informações obtidas a partir das decomposições  $cD_1$  e  $cD_5$ , definindo a ocorrência ou não de acidentes através da seguinte operação lógica:

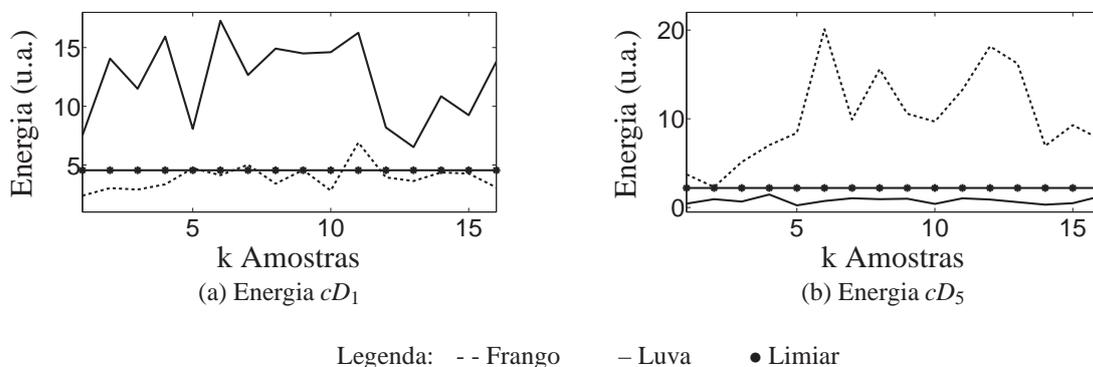
$$Acidente = D1.\overline{D5}, \quad (53)$$

sendo  $D1$  e  $D5$  as variáveis lógicas utilizadas para indicar que o limiar foi ou não alcançado.

Dessa forma, assim como no caso anterior, o índice  $Acidente = 1$  indica que o sistema de frenagem deve ser acionado, enquanto o índice  $Acidente = 0$  indica um procedimento normal de trabalho.

Na Figura 41 é apresentada a análise do caso onde não são efetuados cortes de ossos muito grossos. Para essa análise, assim como na abordagem utilizando apenas três níveis de decomposição, todos os toques de luva foram detectados, não havendo a ocorrência de falsos positivos.

Figura 41 - Energia calculada utilizando cinco decomposições.



Fonte: Elaboração do próprio autor.

Assim como nos casos anteriores, a análise foi estendida para um total de duzentas e vinte

e quatro amostras divididas entre corte de frango e toque de luva, as mesmas utilizadas anteriormente. Os resultados obtidos são apresentados na Tabela 4, onde são relacionados os índices de acertos e falsos positivos de cada família de wavelets utilizada durante o processo de decomposição.

Tabela 4 - Detecção de acidentes utilizando cinco decomposições.

	Família				
	haar	dmey	db4	db10	sym2
Acertos (%)	70,54	74,11	74,11	75,00	71,43
Falsos Positivos (%)	1,79	2,68	2,68	2,68	4,46

	Família				
	sym10	bior1.1	bior2.8	coif4	coif5
Acertos (%)	74,11	70,54	72,32	74,11	75,00
Falsos Positivos (%)	3,57	1,79	2,68	2,68	2,68

Fonte: Elaboração do próprio autor.

Da Tabela 4, nota-se que os índices de falsos positivos caíram em todos os casos, o que torna o sistema mais viável do ponto de vista do empregador. Em contrapartida, o sistema apresentou uma leve perda em sensibilidade, ou seja, parte dos toques que estavam sendo detectados através da metodologia anterior deixaram de ser detectados por essa nova técnica.

Assim como na abordagem anterior, a família de wavelets de Haar apresentou o melhor resultado, sendo a mais indicada para a abordagem do problema devido as condições de baixo custo e complexidade computacional já mencionados. Entretanto, devido ao menor número de falsos positivos apresentados por esse método, é possível optar pela utilização de outra família, como por exemplo a db4.

Observando os resultados apresentados pela família db4 nesse novo método, verifica-se que os índices de acerto foram próximos dos índices de acerto apresentados pela família Haar no método anterior, com a vantagem de ter apresentado um índice de falsos positivos menor.

Obviamente, optar por essa família também tem suas desvantagens, como por exemplo o tempo de atraso necessário para o cálculo das decomposições e o custo computacional para a implementação da mesma, haja vista que são necessários oito coeficientes para sua implementação.

Analisando de forma geral, a abordagem do problema utilizando cinco decomposições torna-se mais viável, haja vista que dessa forma torna-se possível detectar os eventuais acidentes sem que ocorra um número muito elevado de falsos positivos, aumentando a segurança do trabalhador sem que os índices de produção exigidos pelo empregador sejam muito afetados.

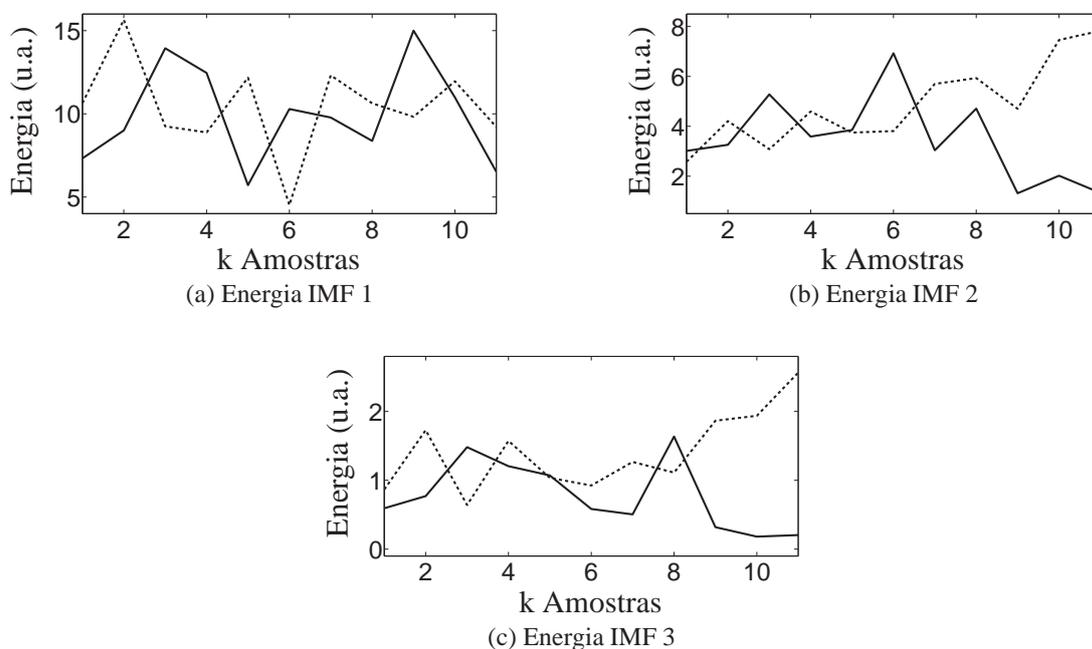
## 5.4 Classificação dos sinais utilizando a EMD

Utilizando-se a decomposição de modo empírico, inicialmente optou-se calcular a energia das IMFs e, em seguida, tentar separar os sinais em função de seus níveis de energia. Foram utilizadas as mesmas condições empregadas na análise com wavelets: normalizou-se o sinal em função do seu valor máximo, calculou-se a energia parcial do sinal de cada uma das IMFs, detectaram-se os valores de pico de energia, definiu-se um limiar fixo a partir dos valores de pico de energia e, por fim, classificaram-se os sinais entre certos e falsos positivos.

Avaliou-se inicialmente a possibilidade de se utilizar o critério de parada sugerido por Rilling, Flandrin e Gonçalves (2003) para a extração das IMFs, o qual poderia utilizar quantidades diferentes de processos de *sifting* para cada sinal analisado. Entretanto, essa variação culminaria num tempo de processamento diferente para cada sinal, inviabilizando essa aplicação para sistemas que tenham que operar em tempo real, como é o caso desse sistema de proteção.

No primeiro caso, definiu-se um total de dois processos de *sifting* para a extração de cada IMF. O resultado obtido é apresentado na Figura 42.

Figura 42 - Análise inicial utilizando IMFs.



Legenda: - - Frango      - Luva

Fonte: Elaboração do próprio autor.

Da Figura 42, nota-se que a decomposição de modo empírico não foi capaz de separar os

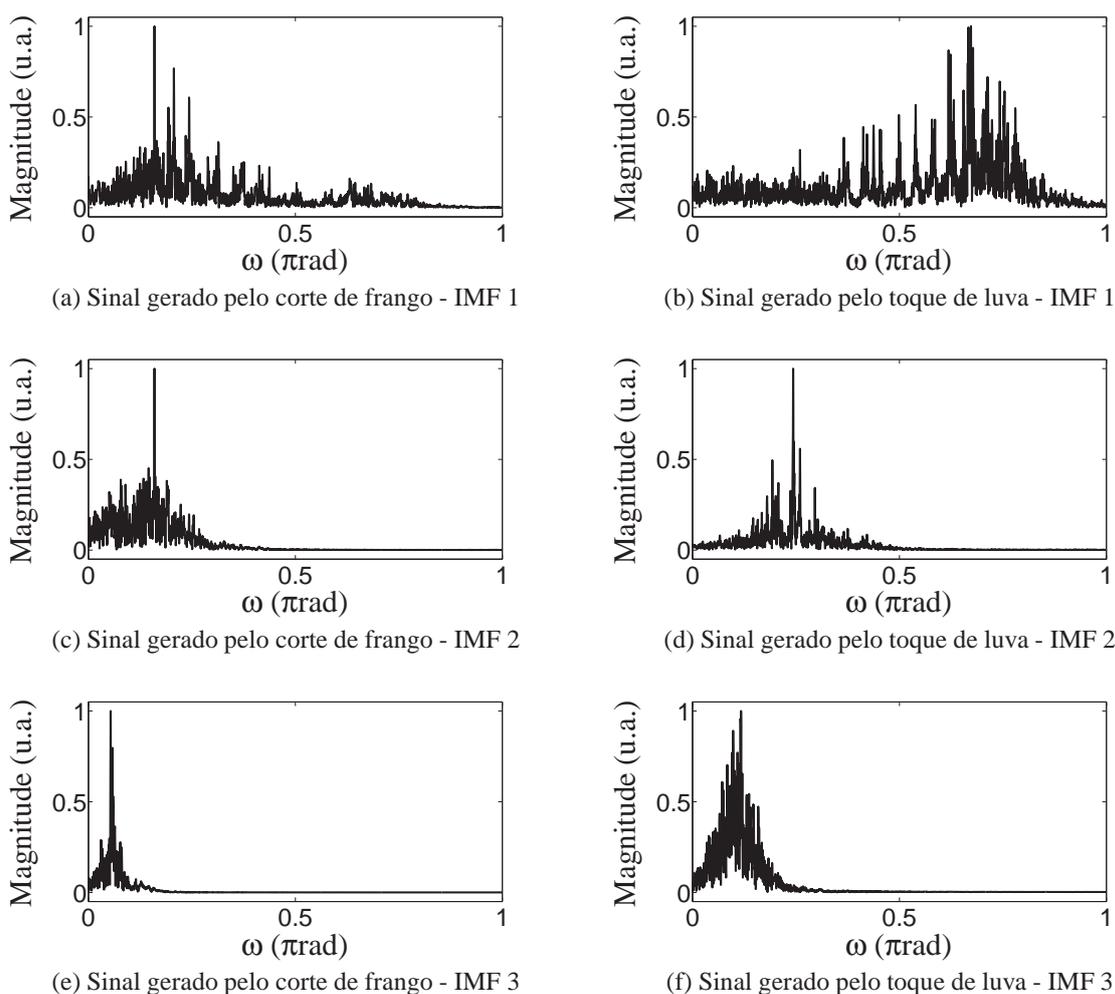
sinais, haja vista que os níveis de energia apresentados são semelhantes.

Inicialmente, variou-se o número de processos de *sifting*, a fim de verificar se o problema estava sendo gerado devido ao baixo número de iterações para a extração das IMFs. Porém, notou-se que a variação obtida ao se aumentar esse número de iterações não foi suficiente para proporcionar a classificação dos sinais.

Partiu-se então para uma análise espectral dos sinais gerados por cada IMF. A ideia é semelhante à proposta inicialmente quando se utilizou um filtro passa-faixas: localizar regiões no espectro das IMFs que possam ser utilizadas como fonte de informação para a classificação dos sinais.

Na Figura 43 apresenta-se o espectro gerado a partir das IMFs para sinais provenientes do som gerado durante o corte de aves e do som gerado durante o toque accidental da luva na serra. As IMFs utilizadas nessa análise espectral foram obtidas através de dois processos de *sifting*.

Figura 43 - Análise espectral dos sinais provenientes das IMFs.



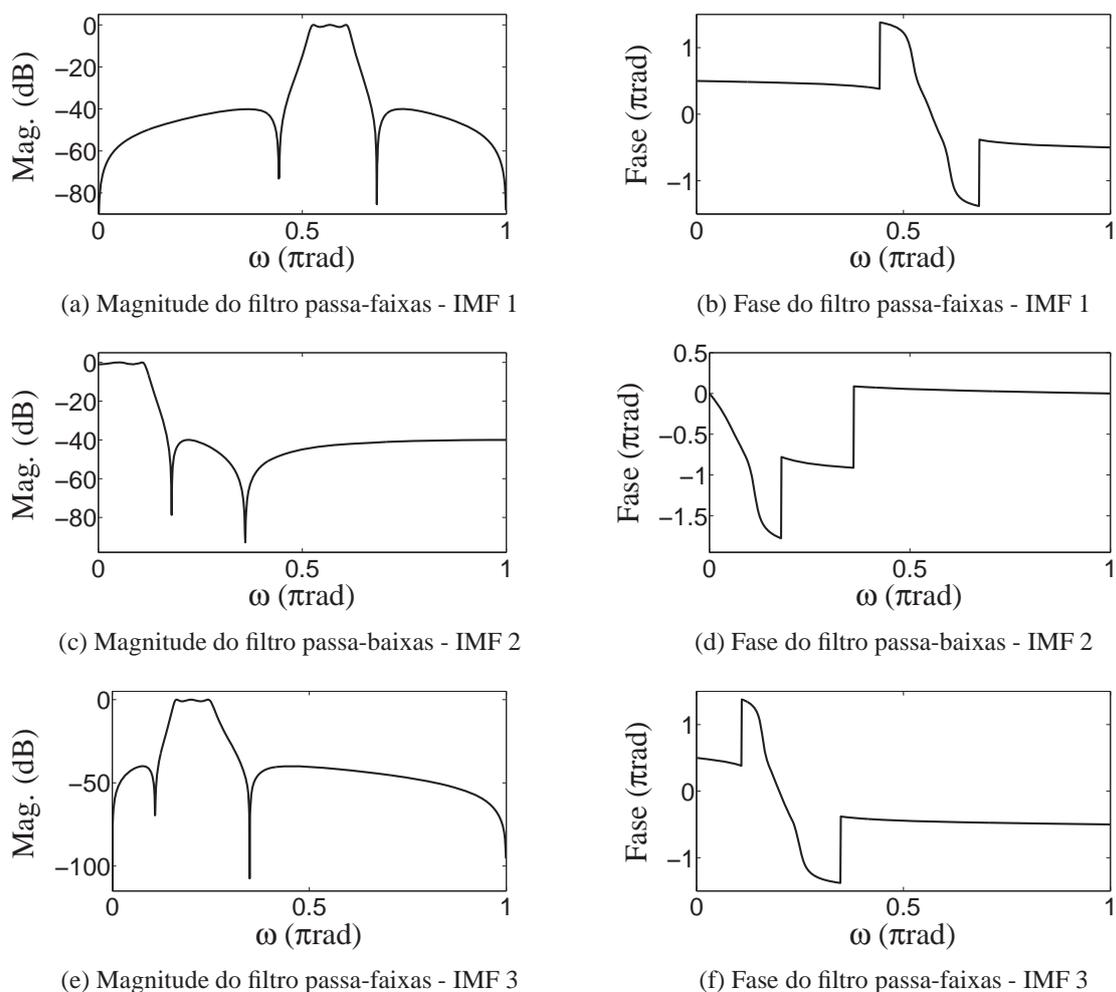
Fonte: Elaboração do próprio autor.

É possível notar que a frequência máxima do sinal cai pela metade a cada IMF extraída, fato que ocorre devido ao número de cruzamentos com zero ser reduzido pela metade de uma IMF à outra.

Verifica-se que, de fato, há regiões nos espectros das IMFs que podem ser utilizadas para classificar os sinais. Dessa forma, se ao invés de se utilizar o resultado das IMFs diretamente para o cálculo da energia fossem utilizados sinais filtrados numa faixa capaz de distinguir os mesmos, seria possível utilizar esse método para classificar a ocorrência ou não de acidentes.

A partir dessa observação, projetou-se três filtros digitais, cujas respostas em frequência são apresentadas na Figura 44.

Figura 44 - Resposta em frequência dos filtro utilizados para separar os sinais a partir das IMFs.



Fonte: Elaboração do próprio autor.

Os sinais gerados pelo processo de decomposição de modo empírico, após filtrados, foram

utilizados para o cálculo da energia. Nessa análise, notou-se que as IMFs 1 e 3 são melhores para localizar a incidência de toque acidental de luva na serra, enquanto a IMF 2 é melhor para identificar o corte de aves.

Definindo nível lógico 1 para sinais de energia que superam o valor do limiar e nível lógico 0 para sinais que não ultrapassam o limiar, define-se a condição de acidente através da operação lógica apresentada pela equação (54):

$$Acidente = E_{IMF1} \cdot E_{IMF3} \cdot \overline{(E_{IMF2})}, \quad (54)$$

sendo  $E_{IMF1}$ ,  $E_{IMF2}$  e  $E_{IMF3}$  as variáveis lógicas utilizadas para indicar que o limiar foi ou não alcançado.

Dessa forma, assim como o proposto na análise utilizando wavelets, o índice  $Acidente = 1$  indica que o sistema de frenagem deve ser acionado, enquanto o índice  $Acidente = 0$  indica um procedimento normal de trabalho.

Assim como nos casos anteriores, inicialmente realizou-se a análise do caso mais simples e, na sequência, analisou-se o caso do corte de frango à passarinho. A análise do caso mais simples é apresentada na Figura 45, que repete a análise apresentada na Figura 42, mas agora utilizando os filtros apresentados anteriormente.

Para esse caso, o índice de acertos do método utilizando EMD e um banco de filtros acoplado foi de 62,5%, não havendo a ocorrência de nenhum falso positivo durante a análise. A Figura 46 apresenta os resultados do caso envolvendo o corte de frango à passarinho.

Para esse caso, o índice de acertos utilizando EMD foi de 45,45%, enquanto o índice de falsos positivos foi de 18,18%. Fica claro que os resultados não foram melhores do que os obtidos através das wavelets. Entretanto, é possível verificar que houve uma melhora em relação à análise inicial baseada apenas numa operação de filtragem.

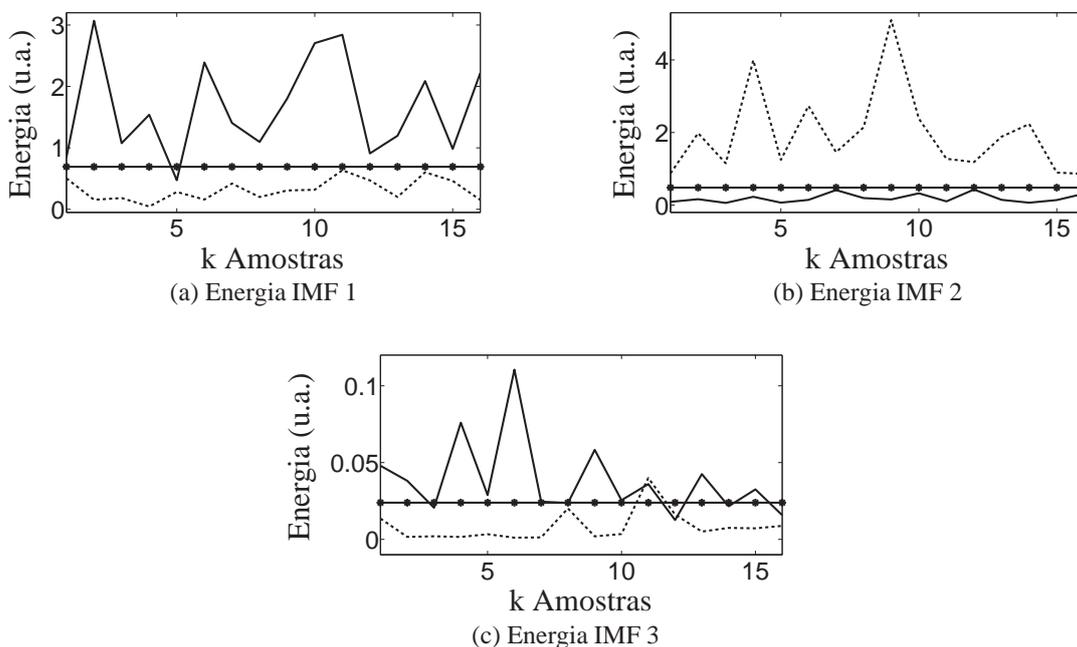
Na sequência, a análise foi estendida para um total de duzentas e vinte e quatro amostras divididas entre corte de frango e toque de luva, as mesmas utilizadas anteriormente. Os resultados são apresentados na Tabela 5, que foi organizada em função do número de processos de *sifting* utilizado na extração de cada uma das IMFs.

Tabela 5 - Detecção de acidentes utilizando EMD.

	Número de processos de <i>sifting</i>				
	1	2	3	8	9
Acertos (%)	76,79	67,86	73,21	61,61	58,04
Falsos Positivos (%)	15,18	15,18	21,43	13,39	13,39

Fonte: Elaboração do próprio autor.

Figura 45 - Energia calculada a partir das IMFs.



Legenda: -- Frango    – Luva    • Limiar

Fonte: Elaboração do próprio autor.

Um fato curioso que ocorreu nesse processo está relacionado ao número de processos de *sifting* utilizado para gerar as IMFs. Como já mencionado, durante o processo de geração das IMFs, são calculadas várias médias do sinal, até que um critério de parada seja alcançado.

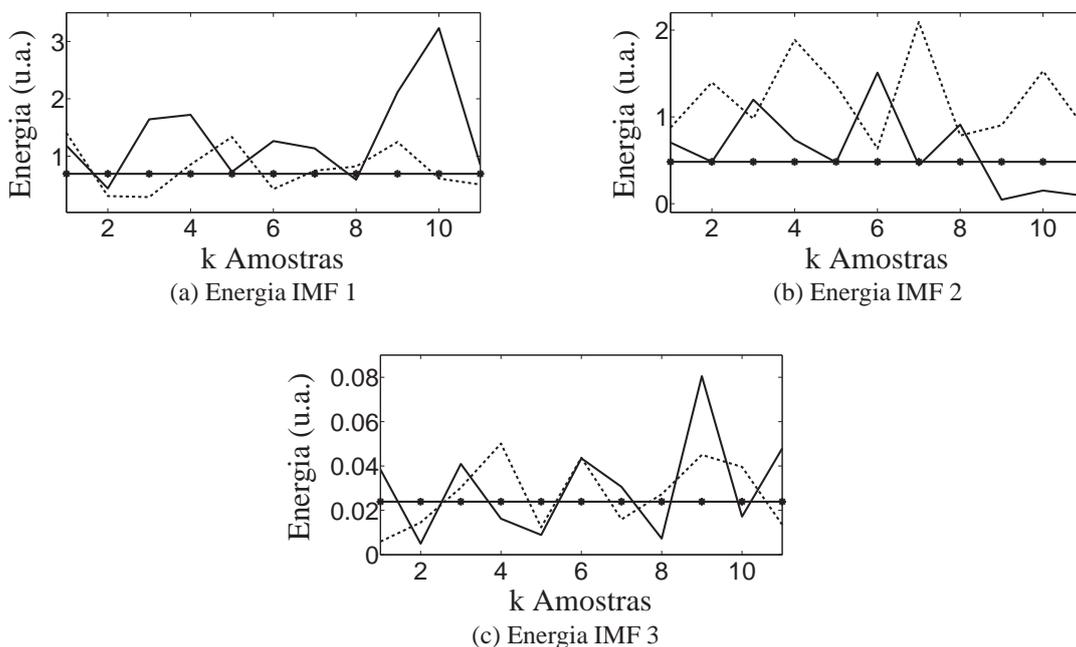
Dessa forma, notou-se que IMFs geradas a partir de um grande número de processos de *sifting* (e, conseqüentemente, um grande número de médias) acabavam perdendo as características que as diferenciavam, tornando-se dessa forma sinais não separáveis.

Devido a isso, optou-se por utilizar um número limitado de processos de *sifting*, evitando que as IMFs geradas se tornassem aproximações grosseiras do sinal original.

O maior índice de acertos, e também o menor índice de falsos positivos desse método, foi encontrado utilizando apenas um processo de *sifting*. Se comparados todos os métodos, verifica-se que os melhores resultados foram obtidos utilizando-se wavelets, o que faz dessa técnica a melhor para a caracterização desse tipo de problema.

A abordagem utilizando EMD, embora tenha apresentado bons resultados se comparados aos encontrados pelo processo de filtragem simples, exige uma plataforma de *hardware* embarcado com maior capacidade computacional, pois seria necessário armazenar um determinado número de pontos do sinal de entrada, calcular as envoltórias através da utilização de *splines* e realizar um determinado número de processos de *sifting* até que as IMFs sejam geradas.

Figura 46 - Energia calculada a partir das IMFs - corte de ossos.



Legenda: -- Frango    - Luva    • Limiar

Fonte: Elaboração do próprio autor.

Embora essas restrições inviabilizem a utilização dessa técnica para o caso em estudo, pois o custo da plataforma de processamento para a implementação da mesma seria mais elevado do que o de uma plataforma utilizada para implementar um banco de filtros, ela pode ser bastante útil para a realização de análises de sinais armazenados, ou seja, uma análise que não seja feita em tempo real.

## 5.5 Comentários

Os resultados obtidos ao longo do experimento comprovam que o sistema pode ser utilizado para evitar acidentes de trabalho durante o esartejamento de aves. O método utilizando wavelets foi o mais eficiente, sendo o mais recomendado também por exigir um sistema embarcado com menor capacidade de processamento e, conseqüentemente, menos custo.

O método utilizando cinco níveis de decomposição de wavelets foi o que apresentou os melhores resultados, pois apesar de não ter os mesmos índices de acerto do método utilizando três níveis de decomposição, foi capaz de conciliar bons resultados com baixos índices de falsos positivos, conciliando assim os interesses do empregador e do trabalhador.

Para a validação dos métodos propostos, seria interessante repetir a análise para um conjunto maior de dados, verificando dessa forma a confiabilidade do sistema.

Ademais, por se tratar de um sistema utilizado para a prevenção de acidentes de trabalho, torna-se necessário utilizar um sistema redundante em conjunto com o sistema proposto por esse trabalho, de modo que no caso falha do sistema baseado em análise acústica, um sistema auxiliar possa interromper o funcionamento da serra antes da ocorrência de um acidente.

## **6 SISTEMA DE DETECÇÃO DE TRINCA EM OVOS**

Neste capítulo é apresentado o problema envolvendo a classificação de ovos, que visa separar de maneira automatizada ovos inteiros de ovos trincados. Assim como no caso do sistema de proteção contra acidentes, são apresentadas as metodologias utilizadas para abordar o mesmo, bem como os resultados obtidos durante ao longo do processo classificatório.

### **6.1 Descrição do problema**

Uma das etapas de grande importância dentre as que constituem o processo de produção de ovos é a detecção de trincas. Essa etapa tem como finalidade garantir a integridade física dos ovos que estão sendo produzidos, minimizando dessa forma a comercialização de ovos danificados que, por ventura, possam estar contaminados com algum tipo de micro-organismo.

Atualmente, há máquinas utilizadas para essa finalidade e seu funcionamento é baseado numa análise acústica, assim como a proposta deste trabalho. O problema é que são máquinas importadas, em geral fabricadas na Holanda ou Japão, caras e inacessíveis aos pequenos produtores de ovos.

Uma solução encontrada pelos pequenos produtores consiste na observação dos ovos por funcionários treinados. Nesse método, os ovos são colocados contra uma forte iluminação e um funcionário observa todos os ovos que passam por uma esteira, retirando manualmente aqueles que lhe parecem trincados.

O problema desse tipo de método é que o índice de acertos depende da capacidade do operador de identificar os ovos trincados, de forma que numa eventual distração do mesmo, os índices podem ser baixos.

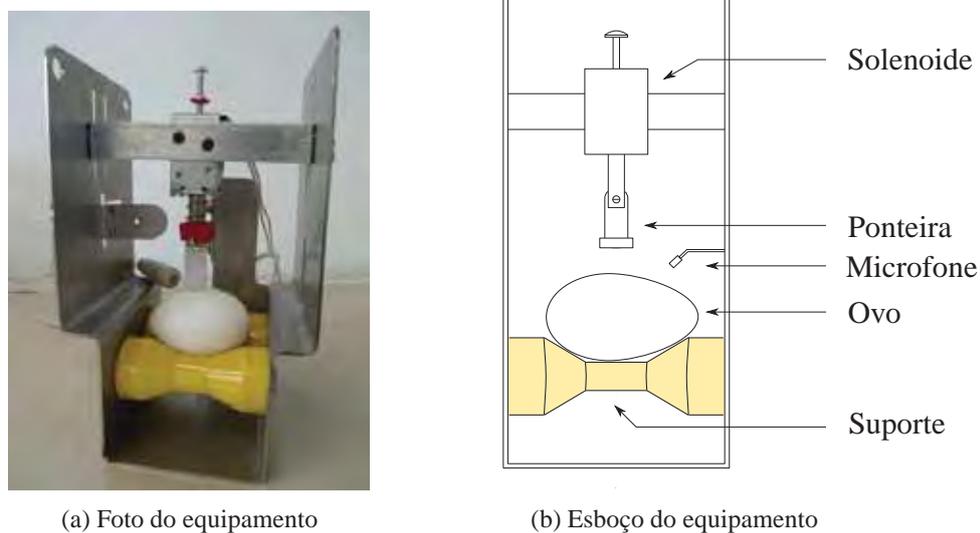
A partir dessas informações e buscando uma solução capaz de atender as necessidades do pequeno produtor a um preço acessível para esse tipo de mercado, a proposta desta etapa do trabalho é desenvolver um sistema de classificação capaz de detectar ovos trincados, separando os mesmos dos ovos inteiros.

Seguindo os conceitos propostos por trabalhos já desenvolvidos, como os apresentados por Eissa (2009) e por Coucke et al. (1999), a proposta desse estudo é caracterizar os ovos a partir do som gerado por uma excitação mecânica.

Trata-se de uma análise inicial, que visa verificar a viabilidade da implementação de um sistema com essas características através de uma mecânica simples e um processamento capaz de ser implementado por meio de sistemas embarcados a preços acessíveis.

Para tanto, inicialmente foi desenvolvido um protótipo para a realização da excitação mecânica dos ovos e captação dos sons gerados durante esse processo. Uma foto do equipamento utilizado é apresentada na Figura 47(a) e um esboço do mesmo é ilustrado na Figura 47(b).

Figura 47 - Equipamento utilizado durante o processo de classificação de ovos.

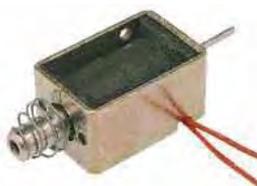


Fonte: Elaboração do próprio autor.

Nota-se que, nesse protótipo, não há uma esteira mecânica para levar os ovos até o sistema de excitação, sendo os mesmos posicionados manualmente num suporte fixo projetado com as mesmas características das esteiras mecânicas utilizadas por sistemas comerciais.

O sistema de excitação mecânico é composto por uma solenoide alimentada por uma tensão DC de 24V e uma ponteira plástica. A Figura 48 apresenta a solenoide utilizada no processo.

Figura 48 - Solenoide utilizada para excitar mecanicamente os ovos.



Fonte: Soletec (2011).

Nesse sistema, inicialmente um pulso elétrico é enviado à solenoide. Isso faz com que a mesma atraque e, conseqüentemente, eleve a ponteira plástica utilizada para atingir os ovos. Em seguida, num sistema comercial, a esteira mecânica utilizada pela máquina posiciona o ovo abaixo da ponteira plástica.

No caso desse protótipo, esse posicionamento é feito de forma manual. Por fim, o pulso

elétrico é desativado, fazendo com que a solenoide desatruque e que a ponteira atinja o ovo que se deseja analisar.

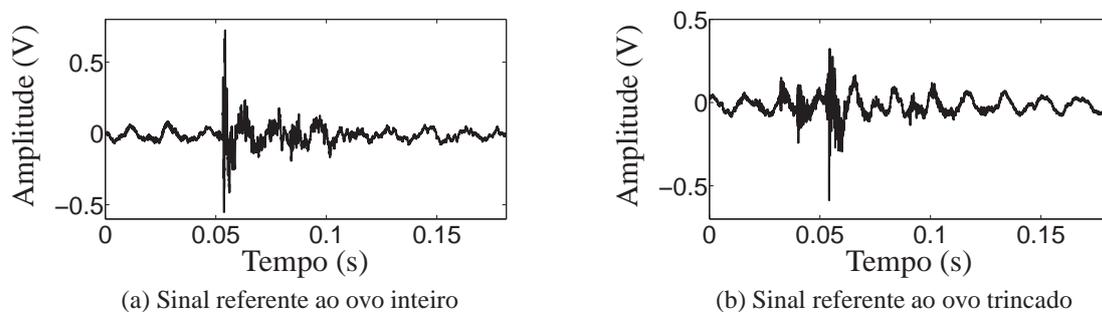
O conjunto formado pela ponteira e pelo eixo da solenoide apresentava um peso de 35g e a altura média utilizada durante o impacto dos ovos foi de 1,5cm. Ademais, nessa simulação optou-se por manter o pulso de excitação da solenoide ligado em períodos de 85ms, e após o posicionamento do ovo pelo usuário, o intervalo de tempo entre uma excitação mecânica e outra foi de 1s.

Ao longo do ensaio, foram efetuadas quatro excitações mecânicas em cada ovo testado, buscando assim evitar que um ovo bom pudesse ser confundido com um ovo trincado.

A aquisição dos sinais foi realizada utilizando um microfone de eletreto com as mesmas características do microfone descrito anteriormente. Ademais, utilizou-se a placa de som de um microcomputador com conversor analógico-digital de dezesseis bits amostrando os sinais a uma frequência de 44,1kHz.

Na Figura 49 apresenta-se um exemplo de sinais acústicos adquiridos pelo sistema utilizando a placa de som. Esses sinais foram gerados a partir da análise de um ovo branco inteiro e um ovo branco trincado. A separação desses ovos entre inteiro e trincado foi feita colocando os mesmos contra a luz gerada por uma lâmpada incandescente de 40W.

Figura 49 - Sinais característicos do processo de classificação de ovos.



Fonte: Elaboração do próprio autor.

Utilizou-se um microcomputador para controlar tanto o pulso de excitação para ativar a solenoide quanto a aquisição dos sinais através do microfone, de modo que a aquisição fosse iniciada exatamente no instante em que o pulso elétrico que mantinha a solenoide atracada fosse desativado.

Desse modo, garante-se que o som gerado pelo impacto mecânico seja captado todas as vezes, possibilitando assim a análise dos sinais e classificação dos ovos.

Para a realização do experimento, foram utilizados dois tipos de ovos: os ovos brancos e os ovos marrons. Optou-se por utilizar ovos que não haviam passado por um processo de

classificação na tentativa de simular condições reais.

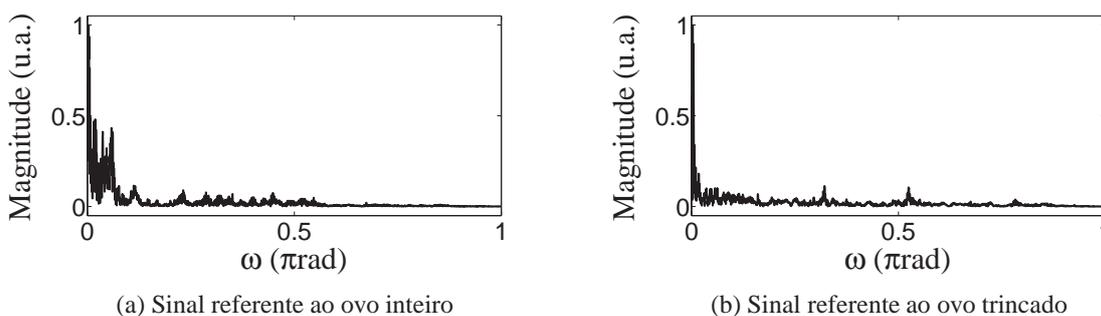
Para a análise envolvendo os ovos brancos, utilizaram-se 40 ovos inteiros e 40 ovos trincados. Essa classificação entre inteiro e trincado foi feita utilizando um sistema de iluminação e os tipos de trinca apresentados pelos ovos empregados no ensaio variavam desde muito finas até as mais grosseiras. Realizou-se uma separação semelhante para o caso envolvendo os ovos marrons. Entretanto, para esse caso, utilizaram-se 13 ovos inteiros e 13 ovos trincados.

Após a etapa de aquisição dos sinais acústicos gerados durante esse processo, deu-se início à etapa de processamento dos sinais. Assim como no caso do sistema de proteção, inicialmente utilizou-se uma operação de filtragem e, na sequência, optou-se por processar os mesmos sinais utilizando técnicas de análise multirresolução. Os resultados obtidos, bem como os métodos utilizados para cada caso, são descritos na sequência.

## 6.2 Classificação dos sinais utilizando um filtro passa-faixas

A primeira abordagem do problema baseou-se na utilização de um filtro passa-faixas para separar os sinais acústicos gerados durante esse processo, de tal forma que os mesmos pudessem ser utilizados como fonte de informação para a classificação dos ovos. Para tanto, inicialmente realizou-se uma análise espectral de sinais referentes a um ovo branco inteiro e um ovo branco trincado. Essa análise é apresentada na Figura 50.

Figura 50 - Análise espectral dos sinais gerados durante o processo de classificação de ovos.

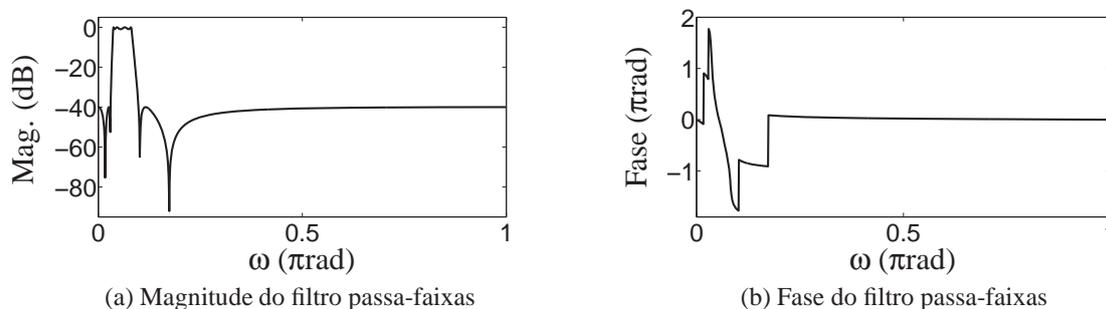


Fonte: Elaboração do próprio autor.

Dessa análise observa-se que para os dois casos há uma maior concentração de energia situada na região de baixa frequência. Ademais, verifica-se que há uma faixa de frequências onde a energia referente ao ovo inteiro é maior do que a energia referente ao ovo trincado. Dessa forma, buscando extrair essa informação e utilizá-la para classificar os ovos, projetou-se um filtro passa-faixas elíptico com banda passante entre  $0.0363\pi\text{rad}$  e  $0.0816\pi\text{rad}$ , frequências de corte entre  $0.0045\pi\text{rad}$  e  $0.1134\pi\text{rad}$  e atenuação de 40dB na faixa de rejeição, cujas respostas

em frequência de magnitude e fase estão apresentadas na Figura 51.

Figura 51 - Resposta em frequência do filtro utilizado para classificar os ovos.



Fonte: Elaboração do próprio autor.

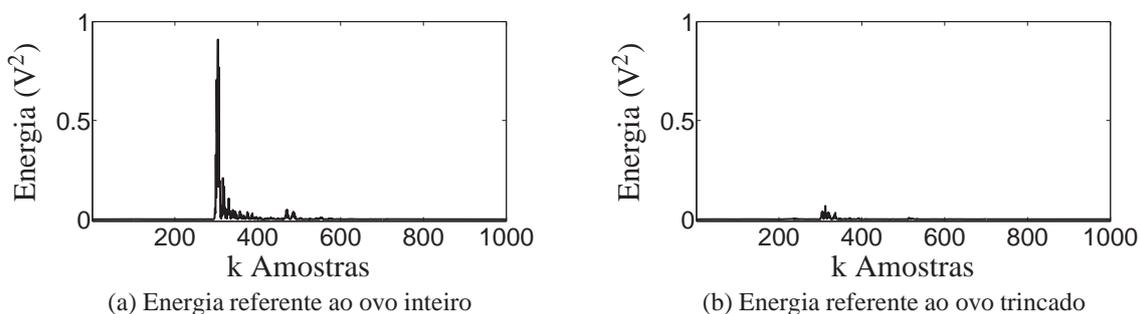
Assim como no caso do sistema de proteção, após o processo de filtragem calculou-se a energia dos mesmos, utilizando-se a equação (55):

$$E[k] = \sum_{n=(k-1)8}^{(8k-1)} [y[n]]^2, \quad k = 1, \dots, N/8, \quad (55)$$

sendo  $N$  o número de pontos do sinal.

Como os sinais acústicos gerados devido à excitação mecânica apresentam curta duração no tempo, optou-se por utilizar somente 8 pontos para o cálculo da energia. Esse número foi definido empiricamente e utilizado ao longo da análise. A Figura 52 apresenta um exemplo da utilização da equação (55).

Figura 52 - Energia dos sinais individuais - caso A.



Fonte: Elaboração do próprio autor.

Para o caso analisado, verifica-se uma grande diferença entre os níveis alcançados pela energia referente ao sinal de ovo inteiro e ao sinal de ovo trincado. Dessa forma, assim como no caso do sistema de proteção, optou-se por armazenar somente os valores de pico de ener-

gia apresentados em cada caso e, a partir desses valores, definir um limiar fixo utilizado para classificar os ovos.

Abordando inicialmente o caso envolvendo ovos brancos, calculou-se um limiar fixo a partir da média dos valores de pico apresentados por 160 amostras de ovos trincados. Nessa análise, cada ovo foi avaliado utilizando 4 excitações mecânicas, por isso a existência de 160 amostras de ovos trincados.

Foram considerados como sinais provenientes de ovos inteiros aqueles que apresentam energia maior do que o valor de limiar fixo pré-estabelecido, e como ovos trincados os que apresentam energia menor do que esse mesmo limiar.

Analisando o problema do ponto de vista do produtor, caso o sistema de classificação venha a apresentar falhas, é muito mais interessante que um ovo trincado seja erroneamente classificado como inteiro do que um ovo inteiro ser classificado erroneamente como trincado. Já do ponto de vista do consumidor, é muito mais interessante que o sistema classifique erroneamente um ovo inteiro como trincado do que um ovo trincado seja comercializado como inteiro, gerando assim um conflito de interesses.

Dessa forma, realizou-se uma composição com os dados gerados para classificar um ovo como inteiro ou trincado buscando atender ao interesses de ambas as partes. Para tanto, utilizaram-se quatro variáveis lógicas auxiliares, uma para cada excitação mecânica. Se a energia gerada pela primeira excitação mecânica fosse maior do que o limiar pré-definido, a variável lógica referente à primeira excitação mecânica recebia nível lógico 1; caso contrário, essa variável recebia nível lógico 0. O mesmo processo foi repetido para as demais excitações mecânicas, completando as quatro variáveis lógicas.

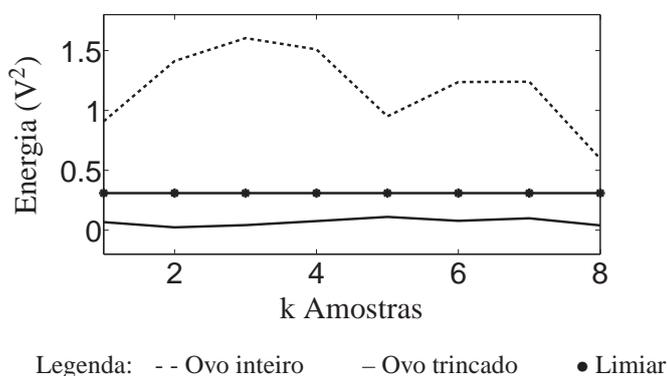
Teoricamente, utilizando esse método, ao final das quatro excitações mecânicas, um ovo bom resultaria em quatro variáveis lógicas auxiliares com nível lógico 1, enquanto um ovo trincado deveria apresentar quatro variáveis lógicas auxiliares com nível lógico 0.

Após a definição das variáveis lógicas, considerou-se como ovo inteiro aquele que apresenta uma ou mais variáveis lógicas com nível lógico 1, e considerou-se como ovo trincado aquele que apresenta todas as variáveis lógicas auxiliares com nível lógico 0.

Uma outra proposta seria a de realizar somente três excitações mecânicas e tomar a decisão baseada no resultado da maioria. O problema é que na prática, notou-se que o número de falhas ao utilizar esse procedimento era maior do que o número de falhas utilizando o procedimento com quatro excitações.

A Figura 53 apresenta um exemplo do método com quatro excitações. Nela, estão apresentados os níveis de energia alcançados por quatro ovos, sendo dois inteiros e dois trincados, totalizando dezesseis excitações mecânicas.

Figura 53 - Energia calculada a partir do sinal filtrado - caso A.



Fonte: Elaboração do próprio autor.

Fazendo a análise do primeiro ovo inteiro (amostras de 1 a 4), nota-se que todos os pontos de energia são superiores ao limiar pré-definido, ou seja, todas as variáveis lógicas auxiliares são definidas com nível lógico 1. Repetindo a mesma análise para o primeiro ovo trincado, verifica-se que todos os pontos de energia estão abaixo do limiar, ou seja, as variáveis lógicas auxiliares são zeradas. Esse exemplo é ilustrado na Tabela 6.

Tabela 6 - Lógica utilizada para classificar ovos.

Inteiro				Trincado			
aux1	aux2	aux3	aux4	aux1	aux2	aux3	aux4
1	1	1	1	0	0	0	0

Fonte: Elaboração do próprio autor.

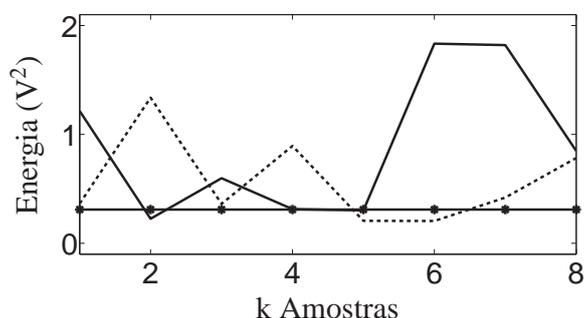
Utilizando a metodologia proposta anteriormente, para o caso do ovo inteiro, tem-se que ao menos uma variável assumiu nível lógico 1. Sendo assim, ele é classificado pelo sistema como inteiro. Já para o caso do ovo trincado, nenhuma variável lógica apresentou nível lógico 1. Dessa forma, ele é classificado pelo sistema como trincado.

Para o exemplo da Figura 53, o sistema classificatório detectou 100% dos ovos inteiros e nenhum ovo trincado foi classificado erroneamente como ovo inteiro.

A mesma análise foi repetida para um outro caso onde se utilizaram ovos com trincas mais finas do que as do caso anterior. O resultado é apresentado pela Figura 54.

Repetindo a análise para o segundo ovo inteiro (amostras de 5 a 8), nota-se que apenas duas das quatro excitações mecânicas apresentaram energia superior ao limiar pré-definido, ou seja, nível lógico 1. Ademais, analisando o segundo ovo trincado, observa-se que apenas uma das quatro excitações mecânicas apresenta anergia abaixo do limiar. Sendo assim, utilizando essa metodologia, o sistema classificaria os dois ovos como sendo inteiros, falhando no processo de

Figura 54 - Energia calculada a partir do sinal filtrado - caso B.



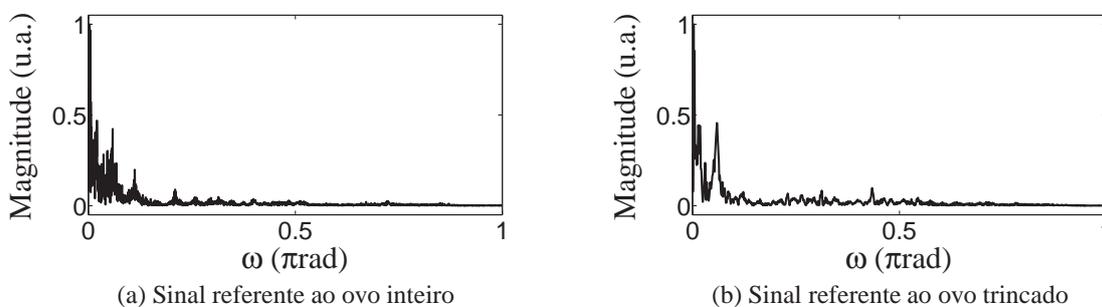
Legenda: --- Ovo inteiro    — Ovo trincado    • Limiar

Fonte: Elaboração do próprio autor.

separação dos sinais.

Uma nova análise espectral foi realizada, utilizando as amostras referentes à segunda excitação mecânica efetuada no segundo ovo bom e no segundo ovo trincado. O resultado é apresentado na Figura 55.

Figura 55 - Análise espectral dos sinais gerados durante o processo de classificação de ovos - caso B.

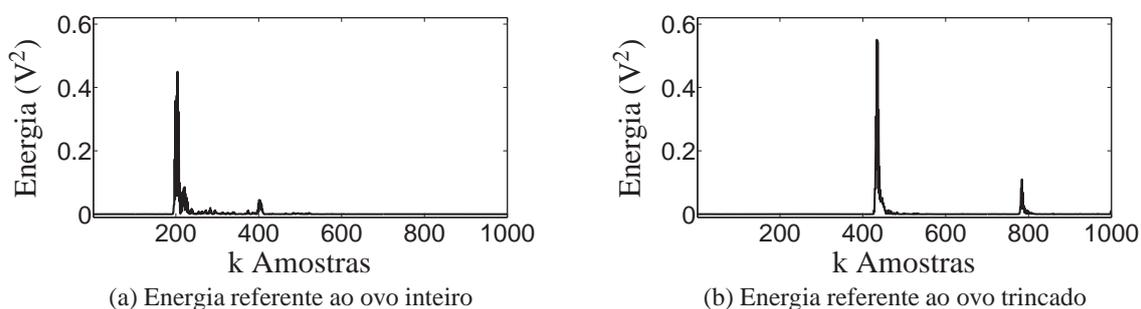


Fonte: Elaboração do próprio autor.

Ao calcular a energia desses sinais, constata-se o problema: para ambos os ovos, a energia na faixa de frequências utilizada foi semelhante, impossibilitando a separação dos mesmos através dessa técnica. A Figura 56 ilustra essa afirmação.

Observando a Figura 56, nota-se que ocorreu um atraso no tempo ao se comparar a energia calculada a partir dos sons gerados por ovos inteiros à energia calculada a partir dos sons gerados por ovos trincados. Esse atraso é o resultado do tempo que o sistema de excitação mecânico leva para atingir o ovo em análise e está relacionado ao tamanho do ovo que se deseja inspecionar. Dessa forma, ovos maiores terão um tempo de atraso menor do que os ovos menores, haja vista que o tempo necessário para o sistema de excitação atingir um ovo grande é menor do que o

Figura 56 - Energia dos sinais individuais - caso B.



Fonte: Elaboração do próprio autor.

tempo que o mesmo sistema leva para atingir um ovo pequeno.

Essa análise foi expandida para um espaço amostral de 80 amostras divididas entre ovos inteiros e trincados. O resultado é apresentado na Tabela 7.

Tabela 7 - Resultado para ovos brancos - filtragem.

	Filtro passa-faixas
Trincados não detectados (%)	62,50
Inteiros detectados (%)	95,00

Fonte: Elaboração do próprio autor.

Nota-se que nem todos os ovos inteiros foram detectados como inteiro, o que acarretaria num prejuízo financeiro ao produtor. Além disso, o índice de ovos trincados não detectados foi muito alto, o que torna esse método inviável para a resolução do problema.

A Tabela 8 apresenta o resultado da mesma análise aplicada agora a ovos marrons. Para essa análise, o limiar fixo foi definido utilizando 13 ovos trincados. Foram utilizados ao todo 26 ovos divididos entre bons e trincados.

Tabela 8 - Resultado para ovos marrons - filtragem.

	Filtro passa-faixas
Trincados não detectados (%)	61,54
Inteiros detectados (%)	92,31

Fonte: Elaboração do próprio autor.

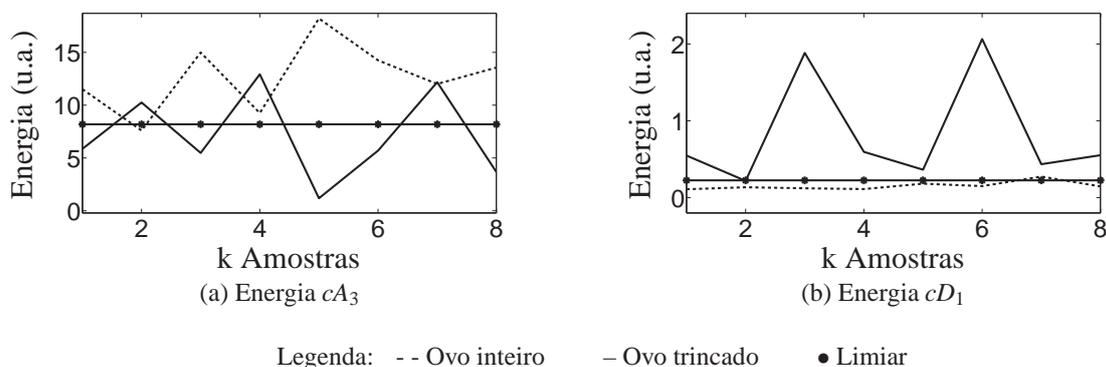
Assim como no caso anterior, alguns ovos bons foram identificados como trincados e grande parte dos ovos trincados não foi detectada, inviabilizando a utilização dessa técnica devido a sua baixa eficiência.

### 6.3 Classificação dos sinais utilizando a DWT

Dando sequência à análise, substituiu-se o sistema de filtragem passa-faixas por uma análise multirresolução utilizando wavelets a princípio a família de wavelets de Haar. Para tanto, inicialmente os sinais foram normalizados em função de seus valores máximos absolutos. Além disso, optou-se por realizar três decomposições, utilizando para isso um banco de filtros.

Dentre as decomposições geradas, foram utilizadas a aproximação  $cA_3$  e o detalhe  $cD_1$ , por serem aquelas que melhores separavam os sinais de interesse. Um exemplo é apresentado na Figura 57, que apresenta as decomposições referentes aos mesmos ovos utilizados para a análise inicial utilizando o filtro passa-faixas.

Figura 57 - Energia calculada a partir das decomposições - análise inicial.



Fonte: Elaboração do próprio autor.

Verifica-se que a decomposição  $cA_3$  é melhor para identificar ovos inteiros, enquanto a decomposição  $cD_1$  é mais eficiente na identificação de ovos trincados. A partir dessa informação, após decompor os sinais, calculou-se a energia dos mesmos de maneira análoga à descrita anteriormente, armazenando apenas os valores de pico de energia para cada uma das decomposições.

Foram, então, definidos dois valores de limiar fixo. Para o caso da decomposição  $cA_3$ , esse limiar foi definido utilizando a média dos valores de pico referentes a 160 amostras de ovos trincados. Já para o caso da decomposição  $cD_1$ , esse valor foi definido a partir da média dos valores de pico referentes a 160 amostras de ovos inteiros.

A proposta para esse tipo de análise é combinar os resultados apresentados nas decomposições  $cA_3$  e  $cD_1$  para definir a variável lógica auxiliar correspondente à excitação mecânica realizada através da seguinte relação:

$$Aux = A3.\overline{(D1)}, \quad (56)$$

sendo  $A3$  e  $D1$  as variáveis lógicas utilizadas para indicar que o limiar foi ou não alcançado.

Dessa forma, assim como no caso utilizando um filtro passa-faixas, obtém-se uma variável lógica  $Aux = 1$  ao se analisar um ovo inteiro e uma variável lógica  $Aux = 0$  ao analisar um ovo trincado. Para cada ovo, foram geradas quatro variáveis lógicas auxiliares, que foram combinadas para se definir se o ovo está inteiro ou trincado.

O critério utilizado para classificar os ovos foi o mesmo utilizado no sistema baseado no filtro passa-faixas, ou seja, se dentre as quatro excitações mecânicas realizadas uma ou mais apresenta valor de energia superior a um limiar pré-estabelecido, então esse ovo é classificado pelo sistema como sendo inteiro; caso nenhuma excitação mecânica apresente valor acima desse mesmo limiar, esse ovo é classificado como trincado. Para exemplificar a técnica, na Tabela 9 são apresentados os resultados obtidos ao analisar o primeiro ovo inteiro (amostras 1 a 4) e o primeiro ovo trincado.

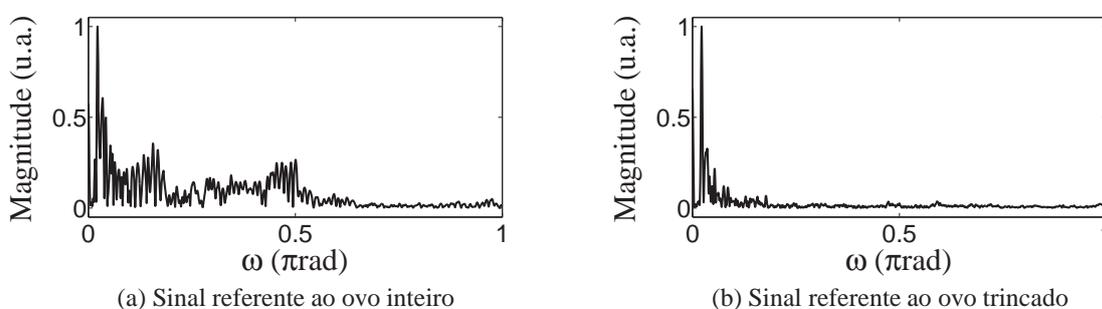
Tabela 9 - Lógica utilizada para classificar ovos.

	Inteiro				Trincado			
	aux1	aux2	aux3	aux4	aux1	aux2	aux3	aux4
$A3$	1	0	1	1	0	1	0	1
$D1$	0	0	0	0	1	0	1	1
$A3.(D1)$	1	0	1	1	0	1	0	0

Fonte: Elaboração do próprio autor.

Para os dois casos, ao menos uma variável auxiliar assumiu nível lógico 1, ou seja, o sistema não foi capaz de detectar o ovo trincado. Buscando melhorar esse resultado, a proposta foi combinar as técnicas de filtragem e decomposição com wavelets. Para tanto, inicialmente realizou-se a análise espectral da primeira amostra proveniente do ovo inteiro e da primeira amostra proveniente do ovo trincado. O resultado é apresentado na Figura 58.

Figura 58 - Análise espectral da aproximação A3.

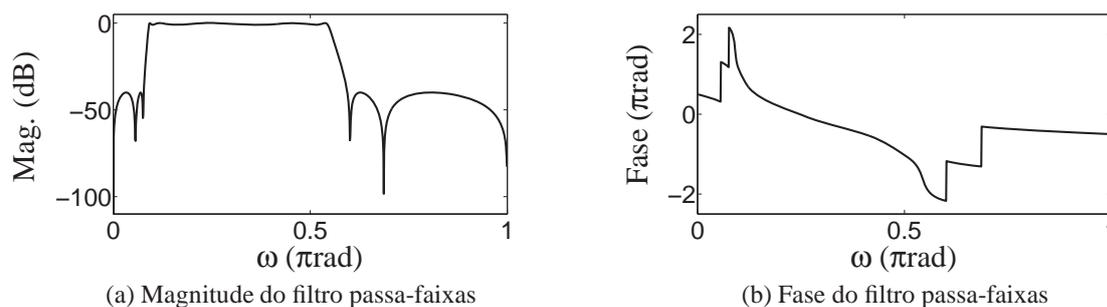


Fonte: Elaboração do próprio autor.

Da análise, nota-se que há uma faixa de frequências que pode ser utilizada como fonte de

informação para classificar os ovos. Dessa forma, a fim de se extrair essa informação, projetou-se um novo filtro passa-faixas elíptico com banda passante entre  $0.0907\pi\text{rad}$  e  $0.5442\pi\text{rad}$ , frequências de corte entre  $0.0045\pi\text{rad}$  e  $0.6349\pi\text{rad}$  e atenuação de 40dB na faixa de rejeição, cujas respostas em frequência de magnitude e fase estão apresentadas na Figura 59.

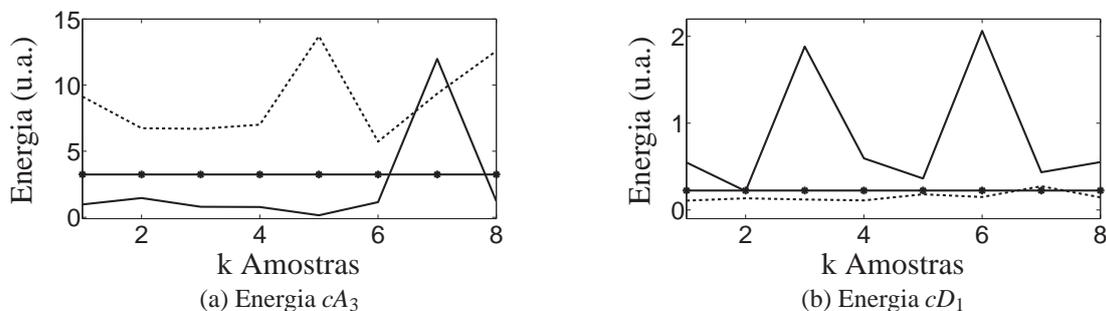
Figura 59 - Resposta em frequência do filtro utilizado para separar os sinais da aproximação A3.



Fonte: Elaboração do próprio autor.

Dessa forma, antes do cálculo de energia, o sinal proveniente da decomposição  $cA_3$  passa por um processo de filtragem. O resultado dessa nova análise para o mesmo caso abordado anteriormente é apresentado na Figura 60.

Figura 60 - Energia calculada a partir das decomposições - caso A.



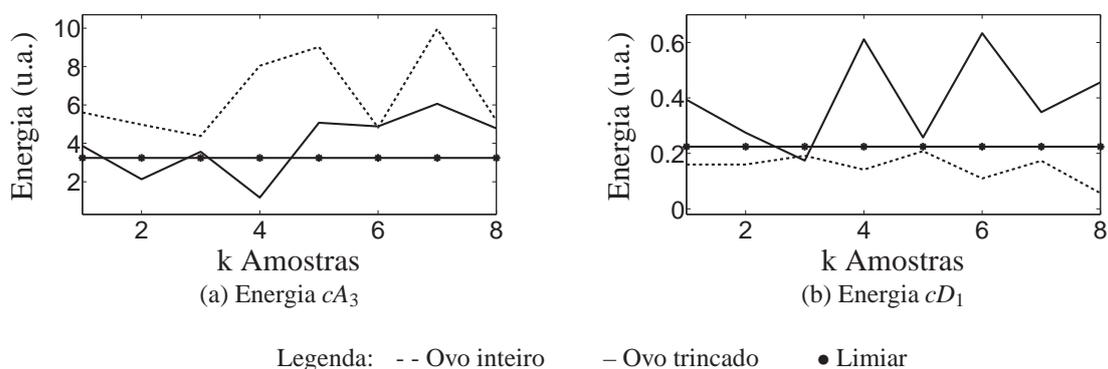
Legenda: - - Ovo inteiro    - Ovo trincado    • Limiar

Fonte: Elaboração do próprio autor.

Para o caso A, utilizando essa nova metodologia, o sistema detectou sem falhas tanto os ovos inteiros quanto os trincados. Repetiu-se então a análise para o segundo caso, onde o filtro passa-faixa utilizado anteriormente não foi capaz de separar os sinais. O resultado é apresentado na Figura 61.

Para esse caso, o sistema detectou todos os ovos inteiros e detectou um entre os dois ovos com trincas finais. Embora o resultado apresentado não tenha sido ideal, já é possível comprovar uma melhora em relação ao resultado obtido anteriormente.

Figura 61 - Energia calculada a partir das decomposições - caso B.



Fonte: Elaboração do próprio autor.

Repetindo o experimento para todo o espaço amostral, têm-se os resultados apresentados na Tabela 10.

Tabela 10 - Classificação de ovos brancos utilizando a DWT.

	Família				
	haar	dmey	db2	db6	sym2
Trincados não detectados (%)	25,00	32,50	20,00	25,00	20,00
Inteiros detectados (%)	92,50	97,50	100,00	100,00	100,00

	Família				
	sym8	bior2.4	bior3.1	coif1	coif2
Trincados não detectados (%)	30,00	22,50	20,00	25,00	25,00
Inteiros detectados (%)	100,00	100,00	97,50	100,00	100,00

Fonte: Elaboração do próprio autor.

Dentre os resultados obtidos, os melhores foram os apresentados ao se utilizar as famílias db2 e sym2, sendo as que melhor identificaram os ovos trincados sem que ovos inteiros fossem descartados ao longo desse processo. Sua boa capacidade para identificar parâmetros durante a fala foi uma das características exploradas para a obtenção desse resultado.

Ademais, essas famílias apresentam a vantagem de poder ser implementadas utilizando filtros de apenas quatro coeficientes, não exigindo dessa forma uma plataforma com capacidade de processamento muito elevado.

Na sequência, o experimento foi repetido para o caso envolvendo os ovos marrons. Para tanto, duas alterações foram efetuadas. Na primeira, ao invés de utilizar-se a decomposição  $cA_3$ , optou-se pela decomposição  $cA_2$ , de modo que a relação utilizada para calcular as variáveis lógicas auxiliares passou a ser definida da seguinte forma:

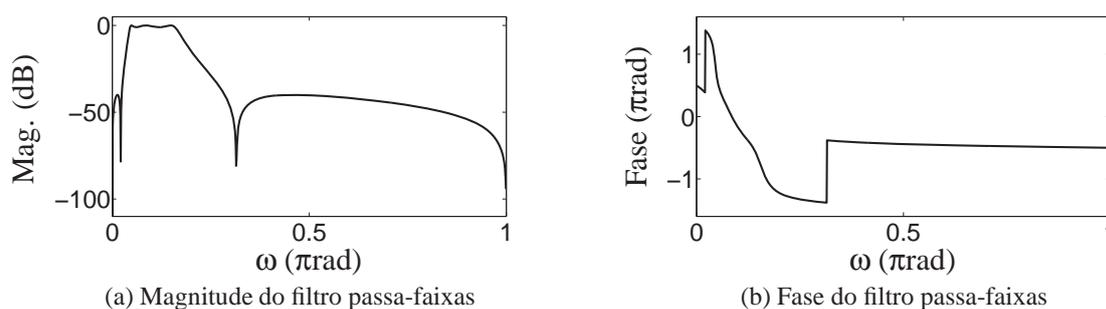
$$Aux = A2 \cdot \overline{(D1)}, \quad (57)$$

sendo  $A2$  e  $D1$  as variáveis lógicas utilizadas para indicar que o limiar foi ou não alcançado.

Essa mudança tem como principal vantagem a redução de um nível de decomposição, reduzindo assim o tempo de processamento necessário para classificar esse tipo de ovo. Essa mudança exigiu que um novo filtro, com características diferentes, fosse projetado para analisar essa decomposição.

Sendo assim, o filtro passa-faixas elíptico utilizado para filtrar os coeficientes da segunda aproximação passou a ter banda passante entre  $0.0454\pi\text{rad}$  e  $0.1587\pi\text{rad}$ , frequências de corte entre  $0.0045\pi\text{rad}$  e  $0.3628\pi\text{rad}$  e atenuação de 40dB na faixa de rejeição. A resposta em frequência desse filtro é apresentada na Figura 62.

Figura 62 - Resposta em frequência do filtro utilizado para separar os sinais da aproximação A2.



Fonte: Elaboração do próprio autor.

Assim como no caso dos ovos brancos, a análise foi expandida para todo o espaço amostral e os resultados estão apresentados na Tabela 11.

Tabela 11 - Classificação de ovos marrons utilizando a DWT.

	Família				
	haar	dmey	db4	db6	sym2
Trincados não detectados (%)	69,23	15,38	15,38	15,38	23,08
Inteiros detectados (%)	100,00	100,00	100,00	100,00	100,00

	Família				
	sym8	bior2.6	bior2.8	coif2	coif5
Trincados não detectados (%)	15,38	15,38	15,38	15,38	15,38
Inteiros detectados (%)	92,31	100,00	100,00	92,31	100,00

Fonte: Elaboração do próprio autor.

Analisando os resultados obtidos, nota-se que o índice de ovos trincados detectados foi maior do que o encontrado durante a análise dos ovos brancos. Entretanto, ressalta-se que o número de amostras utilizado para esse caso foi menor do que o número de amostras utilizado no caso envolvendo ovos brancos.

Dentre os resultados obtidos, destaca-se o apresentado pela família db4, onde todos os ovos inteiros foram detectados e apenas 15,38% dos ovos trincados não foram detectados. Essa família exige mais capacidade de processamento do que a família db2, que foi a que melhor resolveu o problema dos ovos brancos, pois para a família db4, cada um dos filtros utilizados para compor o banco necessita de 8 coeficientes. Em contrapartida, foram utilizados apenas dois estágios de decomposição, de forma que o custo computacional dos dois sistemas torna-se semelhante.

Em suma, nota-se uma grande melhora ao comparar o sistema utilizando somente um filtro passa-faixas e o sistema utilizando wavelets. Ademais, mesmo não tendo atingido uma eficiência de 100%, o sistema foi capaz de detectar a maior parte dos ovos trincados sem que os ovos inteiros sejam erroneamente classificados como trincados.

## 6.4 Classificação dos sinais utilizando a EMD

Na última etapa, o problema foi abordado utilizando a decomposição de modo empírico. Para tanto, os sinais a princípio foram normalizados em função de seu valor máximo absoluto e, na sequência, decompostos em cinco IMFs. Dentre as IMFs geradas, não se utilizou a IMF4, pois esta não foi capaz de separar os sinais de interesse.

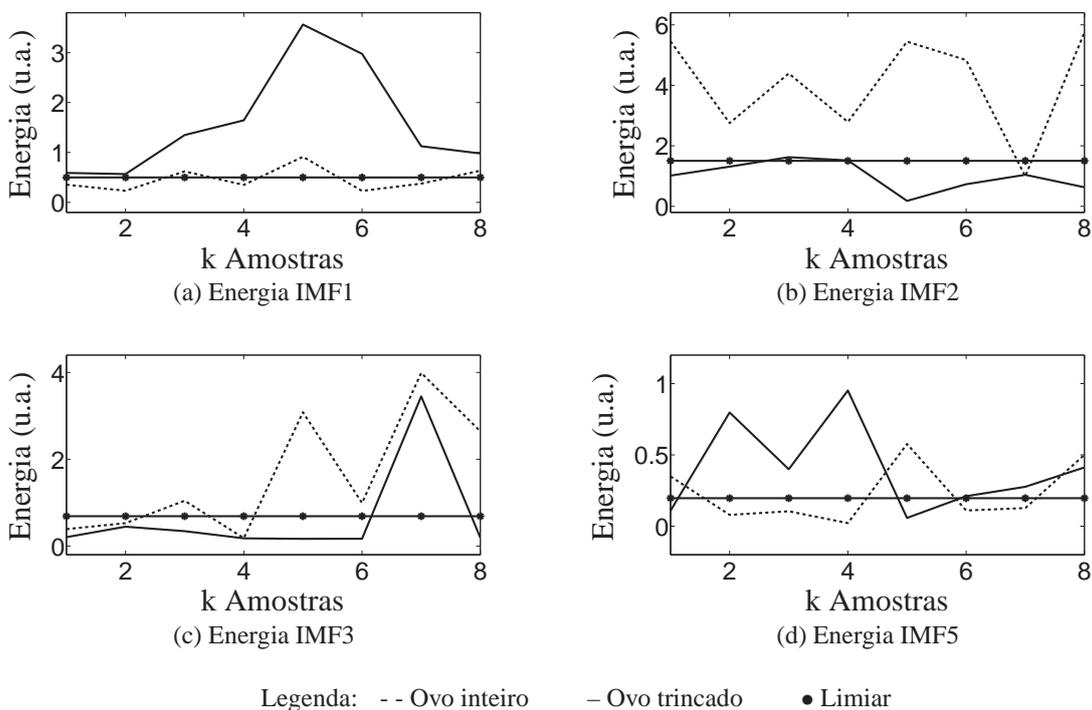
As mesmas condições empregadas anteriormente para a análise utilizando o filtro passa-faixas e a decomposição com wavelets foram empregadas também no processo de classificação utilizando IMFs, ou seja, foram efetuadas quatro excitações mecânicas por ovo, calculou-se a energia a partir de cada uma das IMFs, definiu-se valores de limiar fixo e utilizou-se variáveis lógicas auxiliares para a determinação do estado final dos ovos.

A Figura 63 apresenta a análise do caso abordado inicialmente pelas técnicas anteriores.

Nota-se que as IMFs 2 e 3 são melhores para se detectar ovos inteiros, enquanto as IMFs 1 e 5 são mais eficientes na detecção de ovos trincados. Dessa forma, utilizando-se o mesmo espaço amostral de 320 amostras divididas entre ovos inteiros e trincados, definiram-se valores de limiar a partir da média dos valores de pico dos ovos trincados para as IMFs 2 e 3, e valores de limiar a partir da média dos valores de pico dos ovos inteiros para as IMFs 1 e 5.

Assim como nos casos anteriores, se o nível máximo de energia alcançado por uma IMF apresenta valor superior ao limiar pré-definido, uma variável lógica é definida com nível lógico 1; caso contrário, a variável lógica em questão é zerada. A partir dessa informações, a proposta

Figura 63 - Energia calculada a partir das IMFs - caso A.



Fonte: Elaboração do próprio autor.

para essa análise foi a de combinar os resultados apresentados pelas IMFs para definir a variável lógica auxiliar correspondente à excitação mecânica realizada. Para tanto, utilizou-se a seguinte relação:

$$Aux = IMF2 \cdot IMF3 \cdot \overline{(IMF1 \cdot IMF5)}, \quad (58)$$

sendo  $IMF1$ ,  $IMF2$ ,  $IMF3$  e  $IMF5$  as variáveis lógicas utilizadas para indicar que o limiar foi ou não alcançado.

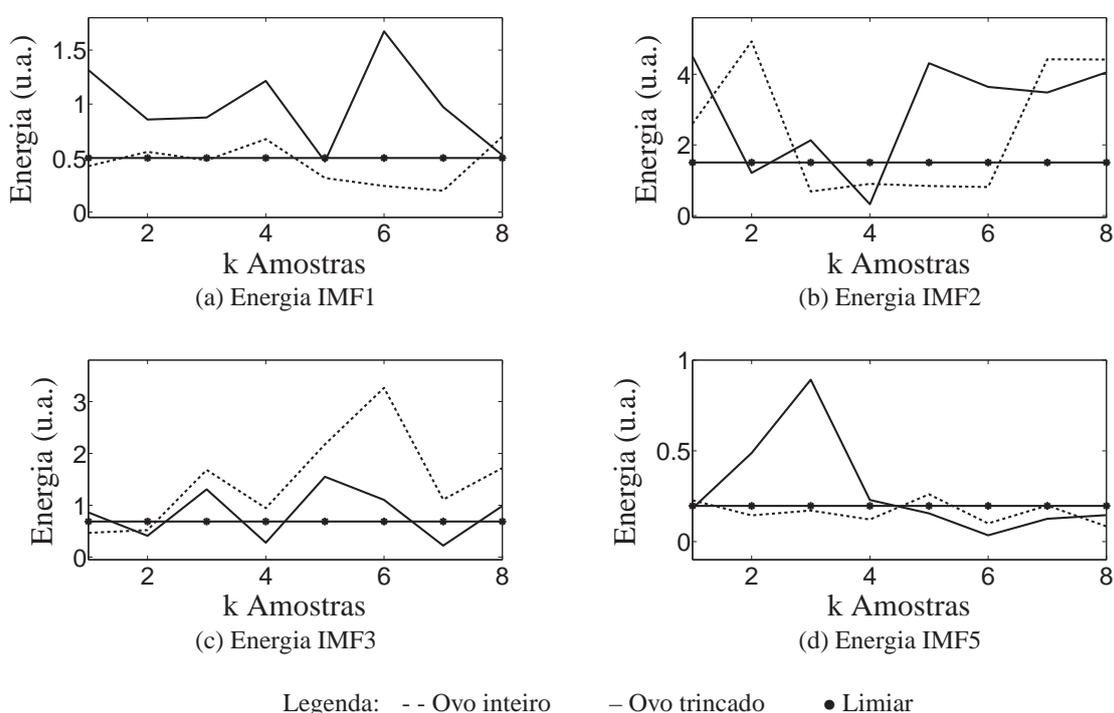
Assim como nos casos anteriores, a composição do resultado final foi feita utilizando quatro excitações mecânicas, empregando para tanto quatro variáveis lógicas auxiliares. Seguindo a mesma regra, se uma ou mais variáveis lógicas apresentassem nível lógico 1, o ovo seria considerado inteiro; se as quatro variáveis apresentassem nível lógico 0, o ovo seria considerado trincado.

Seguindo essas condições, para a análise apresentada na Figura 63, tanto os ovos inteiros quanto os trincados foram detectados.

Na sequência, foi analisado o segundo caso, conforme apresenta a Figura 64.

Neste caso, todos os ovos inteiros foram detectados, entretanto, apenas 50% dos ovos trin-

Figura 64 - Energia calculada a partir das IMFs - caso B.



Fonte: Elaboração do próprio autor.

cados foi identificado. Assim como feito anteriormente, aplicou-se o mesmo método para um espaço amostral de 80 ovos brancos divididos entre inteiros e trincados. O resultado é apresentado na Tabela 12.

Tabela 12 - Classificação de ovos brancos utilizando EMD.

	Número de processos de <i>sifting</i>				
	1	2	5	6	8
Trincados não detectados (%)	15,00	35,00	40,00	35,00	17,50
Inteiros detectados (%)	92,50	90,00	100,00	92,50	75,00

Fonte: Elaboração do próprio autor.

Dentre os resultados apresentados, destaca-se o obtido a partir de 5 processos de *sifting*. Embora o índice de ovos trincados detectados por esse estágio tenha sido inferior ao apresentado, por exemplo, pelo estágio que utilizou apenas um processo de *sifting*, todos os ovos inteiros foram detectados.

Se comparados os resultados obtidos utilizando EMD aos obtidos utilizando wavelets, nota-se que o desempenho dessa técnica foi inferior. Todavia, os resultados foram superiores aos obtidos utilizando apenas um filtro passa-faixas, comprovando assim a vantagem da utilização de um sistema que utiliza a técnica da análise multirresolução.

Na sequência, a mesma análise foi repetida para os ovos marrons. Os resultados são apresentados na Tabela 13.

Tabela 13 - Classificação de ovos marrons utilizando EMD.

	Número de processos de <i>sifting</i>				
	1	2	4	7	10
Trincados não detectados (%)	15,38	53,85	46,15	30,77	38,46
Inteiros detectados (%)	76,92	92,31	100,00	92,31	92,31

Fonte: Elaboração do próprio autor.

Para essa análise, o melhor resultado foi o apresentado utilizando 4 processos de *sifting*, onde todos os ovos inteiros foram detectados. Assim como no caso dos ovos brancos, os resultados apresentados não foram melhores do que os apresentados utilizando-se wavelets, mas constituem uma alternativa à análise utilizando apenas um filtro passa-faixas.

Ademais, se comparado com a técnica utilizando wavelets, o custo computacional do sistema utilizando EMD's é muito mais elevado, haja vista a dificuldade para se calcular os *splines* utilizados durante a extração de cada IMF.

## 6.5 Comentários

Em comparação com um sistema comercial presente no mercado, que detecta aproximadamente 98% dos ovos trincados segundo informam os fabricantes, verifica-se que o sistema desenvolvido nesse trabalho apresenta um rendimento bem inferior. Entretanto, não se compara o sistema mecânico de excitação utilizado por essas máquinas ao sistema utilizado durante esse trabalho.

O índice de acertos para ovos inteiros atingiu uma marca muito boa, restando um aprimoramento na técnica que identifica os ovos trincados. Um dos problemas apresentados é que o sistema mecânico utilizado não apresentava uma boa repetibilidade, ou seja, uma excitação mecânica não se saía exatamente como a anterior, influenciando o resultado da análise.

A partir desses resultados, estima-se que para um sistema mecânico de excitação com maior qualidade, seria possível elevar o índice de acertos na detecção de ovos trincados, haja vista os índices de acerto alcançados mesmo para um sistema mecânico desfavorável. Um exemplo disso é que o trabalho apresentado por Coucke et al. (1999), que ao invés de utilizar um sistema de excitação qualquer, utiliza como fonte de excitação um sistema desenvolvido pela empresa PCB Piezotronics com maior qualidade e precisão para avaliar as características físicas dos ovos.

Ressalta-se que neste trabalho o objetivo foi avaliar as técnicas relacionadas ao processamento digital de sinais e não implementar uma parte mecânica definitiva, buscando desen-

volver uma técnica que pudesse ser aplicada em conjunto com um sistema de excitação a preços acessíveis.

Para os trabalhos futuros, propõe-se aprimorar o sistema de excitação, melhorando a qualidade dos sinais utilizados para classificar os ovos e, conseqüentemente, aumentando a eficiência do sistema, além de repetir os ensaios propostos para um espaço amostral maior.

## 7 CONCLUSÕES

Os resultados obtidos ao longo dos ensaios envolvendo o sistema de proteção contra acidentes de trabalho mostram que a técnica utilizando um processo de análise multirresolução com wavelets é a mais indicada para resolver o problema, entre aquelas avaliadas neste trabalho.

Convém ressaltar que durante o ensaio, apenas toques suaves de luva foram utilizados, de forma que o sistema apresentou um índice de acertos elevado mesmo analisando o caso no qual a dificuldade de se detectar os toques foi maior. O procedimento utilizando cinco decomposições mostrou-se mais eficiente, pois apresentou índices muito baixos de falsos positivos e manteve um índice elevado de detecção de toques.

Verifica-se que a família Haar, que tem como características suporte compacto e capacidade de identificação de fenômenos de curta duração, apresentou os melhores resultados ao longo do processo de classificação dos sinais procedentes do esquiteamento de aves. Este fato é uma grande vantagem para a implementação desse sistema, pois essa família utiliza um banco de filtros com poucos coeficientes e, conseqüentemente, pode ser implementada através de uma plataforma embarcada com menor capacidade computacional e menor custo.

Os resultados apresentados utilizando apenas um filtro passa-faixas mostraram que essa técnica não apresenta a confiabilidade necessária para ser utilizada num sistema de proteção. Além disso, verifica-se necessidade de normalização dos sinais aplicados durante o ensaio, caso contrário as variações de ganho dos circuitos utilizados para adquirir os sinais podem influenciar diretamente os resultados, dificultando a definição de um valor de limiar fixo.

A abordagem utilizando EMD apresentou resultados melhores do que os apresentados pelo sistema que só utilizava um filtro passa-faixas. Todavia, esses resultados não foram melhores do que os apresentados pelo método baseado na decomposição com wavelets.

Ademais, a complexidade computacional desta técnica dificulta a implementação da mesma, uma vez que seria necessário utilizar um sistema embarcado mais caro, além de algoritmos mais sofisticados.

Ao analisar os resultados provenientes do sistema de classificação de ovos, verifica-se que o método que combina as decomposições com wavelets e um filtro passa-faixas apresentou os melhores resultados. Verificou-se que embora os resultados obtidos não tenham alcançado os índices de acerto dos sistemas comerciais, por se tratar de uma primeira versão e por ter se utilizado um sistema mecânico de baixo custo, foram resultados promissores.

Ressalta-se que assim como os equipamentos comerciais, os trabalhos utilizados como base para o desenvolvimento desse sistema de classificação utilizavam sistemas de excitação

mecânica distintos, com custos mais elevados.

Os resultados apresentados com as condições mencionadas mostram que é possível desenvolver um equipamento a um custo baixo utilizando a técnica baseada em wavelets, bastando para isso melhorar o sistema mecânico utilizado como fonte de excitação.

Assim como no caso do sistema de proteção, a análise utilizando EMD não apresentou resultados superiores aos apresentados utilizando wavelets ao longo do processo de classificação de ovos, de modo que sua utilização não seria indicada para a abordagem desse tipo de problema.

Além da melhora no sistema mecânico, a fim de se desenvolver um equipamento comercial, é necessária a repetição do experimento utilizando um número maior de amostras e de forma mais controlada, garantindo assim uma maior confiabilidade do mesmo.

Tanto para o caso da classificação de ovos quanto para o caso do sistema de proteção, nota-se a importância da escolha adequada da família de wavelets, sendo de suma importância buscar aquela capaz de identificar as características dos sinais que se deseja analisar.

Em suma, através deste trabalho foi possível comparar três técnicas distintas empregadas para classificar sinais acústicos, comparando as vantagens e desvantagens de cada uma delas para solucionar os problemas propostos. Por ser uma abordagem inicial, o trabalho apresentou resultados promissores, que podem ser utilizados como ponto de partida para aprimoramentos futuros, aumentando assim a confiabilidade e viabilidade dos sistemas descritos.

## 7.1 Trabalhos Futuros

Em relação ao trabalho envolvendo o esquiteamento de aves, para trabalhos futuros propõe-se a repetição do experimento em um ambiente com condições reais de trabalho, analisando um grupo maior de amostras e verificando a confiabilidade das técnicas descritas. Ademais, propõe-se a implementação num sistema embarcado, que pode ser constituído com base num DSP ou num FPGA, analisando assim tanto a técnica proposta como também a plataforma embarcada utilizada para implementá-la.

Já em relação ao sistema de classificação dos ovos, inicialmente propõe-se uma melhora no sistema mecânico de excitação, buscando um equipamento capaz de repetir as excitações mecânicas com as mesmas características. Além disso, recomenda-se utilizar ovos previamente classificados em uma granja ou por uma pessoa com treinamento para isso, evitando que ovos trincados sejam confundidos com ovos inteiros.

Por fim, propõe-se utilizar um espaço amostral maior e implementar o sistema classificador utilizando um sistema embarcado, analisando como o conjunto se comporta quando submetido às condições reais de trabalho.

## REFERÊNCIAS

- ARAFAT, A.; HASAN, K. Automatic detection of ECG wave boundaries using empirical mode decomposition. In: IEEE INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH AND SIGNAL PROCESSING - ICASSP, 2009, Taipei, Taiwan. *Proceedings...* New York: IEEE, 2009. p.461-464.
- AVERBUCH, A. et al. Wavelet-based acoustic detection of moving vehicles. *Multidimensional Systems and Signal Processing*, Hingham, v. 20, p. 55–80, 2009. doi. 10.1007/s11045-008-0058-z.
- BOUTANA, D.; BENIDIR, M.; BARKAT, B. On the selection of intrinsic mode function in EMD method: Application on heart sound signal. In: INTERNATIONAL SYMPOSIUM ON APPLIED SCIENCES IN BIOMEDICAL AND COMMUNICATION TECHNOLOGIES (ISABEL), 3., 2010, Roma, Italy. *Proceedings...* New York: IEEE, 2010. p. 1-5.
- BURRUS, S. C.; GOPINATH, R. A.; GUO, H. *Introduction to wavelets and wavelet transforms: a primer*. Upper Saddle River: Prentice Hall, 1997.
- CHARLESTON-VILLALOBOS, S.; ALJAMA-CORRALES, A.; GONZALEZ-CAMARENA, R. Analysis of simulated heart sounds by intrinsic mode functions. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY - EMBS'06, 28., 2006, New York. *Proceedings...* New York: IEEE, 2006 p. 2848-2851.
- CONDE, T. et al. Detection of internal cracks in manchego cheese using the acoustic impulse-response technique and ultrasounds. *Journal of Dairy Science*, Champaign, v. 91, n. 3, p. 918-927, 2008.
- COUCKE, P. et al. Measuring the mechanical stiffness of an eggshell using resonant frequency analysis. *British Poultry Science*, London, v. 40, n. 2, p. 227-232, 1999.
- DAUBECHIES, I. *Ten lectures on wavelets*. Philadelphia, PA: Society for Industrial and Applied Mathematics, 1992. (CBMS-NSF Regional Conference Series in Applied Mathematics, v. 61).
- DEGANG, S.; KAI, Y.; HAIFENG, T. Application of wavelet analysis in acoustic signal processing. In: INTERNATIONAL CONFERENCE ON ELECTRONIC MEASUREMENT AND INSTRUMENTS - ICEMI '07, 8., Xi'an. *Proceedings...* New York: IEEE, 2007. p. 3.772-3.775.
- DIEZMA-IGLESIAS, B.; RUIZ-ALTISENT, M.; BARREIRO, P. Detection of internal quality in seedless watermelon by acoustic impulse response. *Biosystems Engineering*, London, v. 88, n. 2, p. 221-230, 2004.

EISSA, A. A. Comparative eggshell stability assessment using three different non-destructive sensing instruments and breakage force strength. *Journal of Food Engineering*, Essex, v. 93, n. 4, p. 444-452, 2009.

GOMES, J.; VELHO, L.; GOLDENSTEIN, S. *Wavelets: teoria, software e aplicacoes*. Rio de Janeiro: IMPA, 1997.

GOMEZ, A. H.; WANG, J.; PEREIRA, A. G. Impulse response of pear fruit and its relation to magness-taylor firmness during storage. *Postharvest Biology and Technology*, Amsterdam, v. 35, n. 2, p. 209-215, 2005.

HE, H.; WANG, C.; WU, Y. Application of wavelet transform in sound source detection and fault diagnostic. In: INTERNATIONAL CONFERENCE ON COMPUTER, MECHATRONICS, CONTROL AND ELECTRONIC ENGINEERING - CMCE, 2010, Changchun, China. *Proceedings...* New York: IEEE, 2010. v. 5, p. 298-301.

HU, Q. et al. Hybrid intelligent detection for underwater acoustic target using EMD, feature distance evaluation technique and FSVDD. In: CONGRESS ON IMAGE AND SIGNAL PROCESSING - CISP, 2008, Sanya, China. *Proceedings...* New York: IEEE, 2008. v. 4, p. 54-58.

HUANG, N. E.; SHEN, S. S. P. *Hilbert-Huang Transform and its applications*. Singapore: World Scientific Publishing, 2005.

HUANG, N. E. et al. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences*, London, v. 454, n. 454, p. 903-995, 1998.

ISTRATE, D. et al. Information extraction from sound for medical telemonitoring. *IEEE Transactions on Information Technology in Biomedicine*, New York, v. 10, n. 2, p. 264-274, April 2006.

ITO, Y.; UOMOTO, T. Nondestructive testing method of concrete using impact acoustics. *NDT & E International*, London, v. 30, n. 4, p. 217-222, 1997.

JAVIDAN, R. Wavelet-based acoustic seabed discrimination system. In: INTERNATIONAL CONFERENCE ON IMAGE PROCESSING THEORY TOOLS AND APPLICATIONS - IPTA, 2., 2010, Paris, France. *Proceedings...* New York: IEEE, 2010. p. 253-257.

KINGSTATE ELETRONICS CORP. *Electret condenser microphone*. 1.2. ed. Taiwan, 2011. Disponível em: <<http://www.farnell.com/datasheets/97500.pdf>>. Acesso em: 07 nov. 2011.

KUMAR, D. et al. Third heart sound detection using wavelet transform-simplicity filter. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND

BIOLOGY SOCIETY - EMBS, 29., 2007, Lyon, France. *Proceedings...* New York: IEEE, 2007. p. 1277-1281.

LATHI, B. P. *Sistemas de comunicação*. Rio de Janeiro: Guanabara, 1987.

LI, G. et al. The application of empirical mode decomposition in target-starting sound detection. In: IEEE VEHICLE POWER AND PROPULSION CONFERENCE - VPPC, 2008, Harbin. *Proceedings...* New York: IEEE., 2008. p. 1-4.

LUK, B. et al. Impact-acoustics inspection of tile-wall bonding integrity via wavelet transform and hidden markov models. *Journal of Sound and Vibration*, London, v. 329, n. 10, p. 1954-1967, 2010.

MALLAT, S. *A Wavelet Tour of Signal Processing*, 2.ed. San Diego: Academic Press, 1999.

MISITI, M. et al. *Wavelet toolbox: for use with Matlab*. Natick: The MathWorks, 1996.

MIZRACH, A. Nondestructive ultrasonic monitoring of tomato quality during shelf-life storage. *Postharvest Biology and Technology*, Amsterdam, v. 46, n. 3, p. 271-274, 2007.

OPPENHEIM, A. V.; SCHAFER, R. W.; BUCK, J. R. *Discrete-time signal processing*. 2. ed. Upper Saddle River: Prentice Hall, 1999.

PEREIRA, E. A. B. et al. *Aperfeiçoamento aplicado em conjunto de corte de alimentos e metodologia de segurança introduzida em conjunto de corte de alimentos*. BR n. PI 0805320-0A2, 27 nov. 2008, 17 ago. 2010.

R3EPI SOLUÇÕES EM EQUIPAMENTOS DE SEGURANÇA. *Luva de aço inoxidável*. São Paulo, 2011. Disponível em: <<http://www.equipamentodeprotecaoindividual.com/epi/luvas-de-protecao/lu%va-de-acougueiro-malha-de-aco-%E2%80%93-leal>>. Acesso em: 07 nov. 2011.

RILLING, G.; FLANDRIN, P.; GONÇALVES, P. On empirical mode decomposition and its algorithms. In: IEEE-EURASIP WORKSHOP ON NONLINEAR SIGNAL AND IMAGE PROCESSING - NSIP, 2003, Grado, Italy. *Proceedings...* New York: IEEE, 2003.

RIOUL, O.; VETTERLI, M. Wavelets and signal processing. *IEEE Signal Processing Magazine*, New York, v. 8, n. 4, p. 14-38, Oct. 1991.

SCHOTTE, S.; BELIE, N. D.; BAERDEMAEKER, J. D. Acoustic impulse-response technique for evaluation and modelling of firmness of tomato fruit. *Postharvest Biology and Technology*, Amsterdam, v. 17, n. 2, p. 105-115, 1999.

SEKI, K.; SHIN, S.; TABARU, T. Discrimination of normal and studless tyres by wavelet sound analysis. In: ANNUAL CONFERENCE SICE 2004 , Sapporo, Japan. *Proceedings...* New York: IEEE, 2004. v.3, p.2312-2315.

SILVA, J. F. da. *Sistema de armazenamento de imagens comprimidas através da transformada wavelet*. Dissertação (Mestrado) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, jun. 2008.

SOARES, W. C. *Um método não-limiar para redução de ruído em sinais de voz no domínio wavelet*. Tese (Doutorado) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, maio 2009.

SOLETEC. *Solenóide Miniatura*. São Paulo, 2011. Disponível em: <<http://soletec.com.br/SERIEB.pdf>>. Acesso em: 07 nov. 2011.

STRANG, G.; NGUYEN, T. *Wavelets and filter banks*. Wellesley:Wellesley-Cambridge Press, 1997.

WANG, H. L. et al. Feature extraction of acoustic signal based on wavelet analysis. In: INTERNATIONAL CONFERENCE ON EMBEDDED SOFTWARE AND SYSTEMS SYMPOSIA - ICESS SYMPOSIA '08, 2008 , Chegdu, China. *Proceedings...* New York: IEEE, 2008. p. 437-440.

WANG, J.; JIANG, R. S.; YU, Y. Relationship between dynamic resonance frequency and egg physical properties. *Food Research International*, Barking, v. 37, n. 1, p. 45 – 50, 2004.

YAMAMOTO, H.; IWAMOTO, M.; HAGINUMA, S. Acoustic impulse response method for measuring natural frequency of intact fruits and preliminary applications to internal quality evaluation of apples and watermelons. *Journal of Texture Studies*, Westport, v.11, n.2, p. 117-136, 1980.

YANG, X.-L.; TANG, J.-T. Hilbert-Huang Transform and wavelet transform for ECG detection. In: INTERNATIONAL CONFERENCE ON WIRELESS COMMUNICATIONS, NETWORKING AND MOBILE COMPUTING - WICOM '08. 4.,2008, Dalian, China. *Proceedings...* New York: IEEE, 2008. p. 1-4.

ZEILER, A. et al. Empirical mode decomposition - an introduction. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS - IJCNN; IEEE WORLD CONGRESS ON COMPUTATIONAL INTELLIGENCE - WCCI, 2010, Barcelona, Spain. *Proceedings...* New York: IEEE, 2010. p. 1-8.

ZHENG, Z.; YI-LIN, W.; PING, C. Improved Hilbert-Huang Transform and its application in acoustic vector signal processing. In: INTERNATIONAL CONGRESS ON IMAGE AND SIGNAL PROCESSING - CISP, 3., 2010, Yantai, China. *Proceedings...* New York: IEEE, 2010. v. 7, p. 3103-3106.

ZHIDONG, Z.; ZHIJIN, Z.; YUQUAN, C. Time-frequency analysis of heart sound based on HHT [Hilbert-Huang transform]. In: INTERNATIONAL CONFERENCE ON COMMUNICATIONS, CIRCUITS AND SYSTEMS, 2005, Hong Kong, China. *Proceedings...* New York: IEEE, 2005. v. 2, p. 2.

ZIN, Z. et al. Analysis of heart sounds based on continuous wavelet transform. In: STUDENT CONFERENCE ON RESEARCH AND DEVELOPMENT - SCORED, 2003, Putrajaya, Malaysia. *Proceedings...* New York: IEEE, 2003. p. 19-22.