



UNIVERSIDADE FEDERAL DE UBERLÂNDIA  
FACULDADE DE ENGENHARIA MECÂNICA

Lucas Otaviano Alves

**METODOLOGIA DE COMPRESSÃO DE SINAIS BASEADA EM  
TRANSFORMADA WAVELET DISCRETA UTILIZANDO OTIMIZAÇÃO  
POR EVOLUÇÃO DIFERENCIAL**

Uberlândia  
2022

Lucas Otaviano Alves

**METODOLOGIA DE COMPRESSÃO DE SINAIS BASEADA EM  
TRANSFORMADA WAVELET DISCRETA UTILIZANDO OTIMIZAÇÃO  
POR EVOLUÇÃO DIFERENCIAL**

Projeto de Conclusão de Curso apresentado ao curso de Graduação em Engenharia Aeronáutica, da Faculdade de Engenharia Mecânica da Universidade Federal de Uberlândia como requisito para a obtenção do título de Bacharel em Engenharia Aeronáutica.

Orientador: Prof. Dr. Aldemir Aparecido Cavalini Junior

Uberlândia

2022

À todos que me ajudaram chegar  
até aqui, em especial à minha família.

## AGRADECIMENTOS

Gostaria de agradecer primeiramente à Deus, e logo então à minha família, especialmente aos meus tios Jurandir e Gisele, anjos da guarda que proveram o suporte e me possibilitaram o privilégio da educação de qualidade, desde a infância. Também não poderia deixar de agradecer à minha mãe, Sulamita, e avó, Onélia, pelo incentivo constante aos estudos, conselhos valiosos e palavras de carinho.

Sou grato aos amigos que Uberlândia me proporcionou, cujos momentos compartilhados são guardados com carinho na memória, e cuja amizade será levada desde a oficina de aerodesign e salas de aula até a vida.

Agradeço à UFU e seu corpo docente e técnico, que me forneceram o espaço e as ferramentas para evoluir tecnicamente e humanamente, e me tornar um Engenheiro competente.

Agradeço também ao professor Aldemir, por me inspirar, e dar a oportunidade de conhecer e trabalhar em vibração, uma área que gosto muito.

Sou grato também à equipe de extensão Tucano Aerodesign, pela oportunidade de amadurecimento técnico e social durante minha trajetória enquanto estudante de Engenharia Aeronáutica. Sem a Tucano, não chegaria onde estou.

Por fim, agradeço à Embraer, pela oportunidade de estagiar e trabalhar em vibração e ruído enquanto primeira oportunidade profissional, e também à Petrobras, por apoiar uma parte do desenvolvimento deste trabalho, no âmbito do projeto Edge Analytics.

“Se você quiser descobrir os segredos do Universo, pense em termos de energia, frequência e vibração.”  
(Nikola Tesla)

## RESUMO

Este trabalho apresenta o desenvolvimento de um modelo de compressão de sinais baseado na teoria da Transformada Wavelet Discreta acoplado à um otimizador por Evolução Diferencial para definição automática do valor ótimo de limiar (*threshold*) durante a etapa de quantização. Um algoritmo foi implementado em Python, definindo como objetivos do otimizador a minimização do erro quadrático médio entre o sinal original e o sinal reconstruído após compressão, além da maximização da taxa de compressão. Ao final, dois sinais de diferentes máquinas rotativas são comparados para diferentes configurações de otimização, sendo mostrada a comparação entre os sinais comprimidos e seus equivalentes originais. O método desenvolvido alcançou elevadas taxas de compressão e baixos erros, ao custo de um tempo de otimização relativamente alto para viabilização de compressão de sinal simultânea à aquisição.

**Palavras-chave:** vibração; compressão de sinal; wavelet; otimização; evolução diferencial

## LISTA DE FIGURAS

Figura 1 – Termos de pesquisa relacionados ao termo: "Industria 4.0" . . . . .	11
Figura 2 – Perspectiva global do volume armazenado de dados até 2025 . . . . .	12
Figura 3 – Esquema genérico de um sistema de monitoramento de vibração de máquinas rotativas . . . . .	15
Figura 4 – Esquema da metodologia de compressão proposta. A metodologia proposta no atual trabalho apresenta semelhanças com a metodologia de Tanaka . . . . .	15
Figura 5 – Desempenho de compressão de diferentes wavelet-mãe e do método DCT	16
Figura 6 – Avaliação temporal de diferentes sinais antes e após compressão . . . .	17
Figura 7 – Sinal temporal de engrenagem reconstruído após <i>thresholding</i> dos coeficientes wavelet para preservação dos coeficientes mais relevantes . . . .	18
Figura 8 – Espectro de engrenagem defeituosa com <i>thresholding versus</i> sinal original	19
Figura 9 – Wavelets-mãe ótimas para o mesmo sinal e diferentes valores de CR . . .	20
Figura 10 – Reconstrução de dois sinais diferentes . . . . .	20
Figura 11 – Valor das escalas de quantização ( <i>thresholds</i> ) dos coeficientes nas diferentes camadas de decomposição . . . . .	21
Figura 12 – Relação entre CR e o erro PRD para a metodologia proposta (NRDPWT-GAar) e outras duas metodologias de compressão de sinais de ECG . . .	22
Figura 13 – Sobreposição do sinal original (azul) sobre o sinal comprimido (vermelho)	22
Figura 14 – Representação de uma wavelet a decompor um sinal senoidal. . . . .	23
Figura 15 – Comparação entre decomposição STFT (GABOR, 1946) e wavelet . . . .	24
Figura 16 – Famílias wavelet . . . . .	25
Figura 17 – Representação da família <i>Daubechies</i> para várias ordens e níveis. . . . .	26
Figura 18 – Decomposição do sinal em bancos de filtros HP ( <i>High Pass</i> (Passa-alta)) e LP ( <i>Low Pass</i> (Passa-baixa)) a cada nível. . . . .	27
Figura 19 – Metodologia de compressão proposta . . . . .	28
Figura 20 – Coeficientes DWT cA e cD de um sinal decomposto . . . . .	29
Figura 21 – Coeficientes DWT cA e cD originais e após quantização. $\Gamma = 20\%$ . . .	31
Figura 22 – Coeficientes DWT cA e cD originais e após quantização. $\Gamma = 40\%$ . . .	32
Figura 23 – Metodologia de compressão acoplada ao otimizador diferencial (em vermelho) . . . . .	35
Figura 24 – CR ( <i>Compression Rate</i> ) das ordens das wavelets <i>Daubechies</i> . . . . .	36
Figura 25 – Avaliação da melhor ordem para as wavelets <i>Daubechies</i> por razão entre CR e MSE (quanto maior, melhor) . . . . .	37
Figura 26 – Avaliação do sinal temporal após compressão, para $\Gamma_i = 0.05$ , $\Gamma_i = 0.10$ , $\Gamma_i = 0.15$ e $\Gamma_i = 0.20$ . Em preto: sinal original; em vermelho: sinal reconstruído . . . . .	38

Figura 27 – Avaliação da performance de compressão do sinal, para $\Gamma_i = 0.05$ , $\Gamma_i = 0.10$ , $\Gamma_i = 0.15$ e $\Gamma_i = 0.20$ . . . . .	38
Figura 28 – Mancal Magnético: Comparação entre o sinal original e o sinal comprimido	40
Figura 29 – Mancal Magnético: Comparação do espectro de frequências entre o sinal original e o sinal comprimido . . . . .	41
Figura 30 – Mancal Magnético: Comparação entre o sinal original e o sinal compri- mido em dois instantes diferentes . . . . .	42
Figura 31 – Mancal Magnético: Comparação do espectro de frequências entre o sinal original e o sinal comprimido em dois instantes diferentes . . . . .	43
Figura 32 – Variação de $\Gamma$ ao longo de cada um dos coeficientes wavelet otimizados: sinal de rotor em mancal magnético ( $\Gamma_i = X_i \cdot \max(\text{coeff}_i)$ ) . . . . .	43
Figura 33 – Avaliação da performance de compressão do sinal, para $\Gamma_i = 0.05$ , $\Gamma_i = 0.10$ , $\Gamma_i = 0.15$ e $\Gamma_i = 0.20$ . . . . .	44
Figura 34 – Exaustor: Comparação entre o sinal original e o sinal comprimido . . .	46
Figura 35 – Exaustor: Comparação do espectro de frequências entre o sinal original e o sinal comprimido . . . . .	47
Figura 36 – Variação de $\Gamma$ ao longo de cada um dos coeficientes wavelet otimizados: sinal de exaustor industrial ( $\Gamma_i = X_i \cdot \max(\text{coeff}_i)$ ) . . . . .	47



## LISTA DE TABELAS

Tabela 1 – Configurações do processo de compressão: sinal de rotor em mancal magnético . . . . .	39
Tabela 2 – Resultados do processo de compressão: sinal de rotor em mancal magnético . . . . .	39
Tabela 3 – Configurações do processo de compressão: sinal de exaustor industrial .	45
Tabela 4 – Resultados do processo de compressão: sinal de exaustor industrial . .	45

## LISTA DE ABREVIATURAS E SIGLAS

cA	Coeficientes de Aproximação: passa-baixa
cD	Coeficientes de Detalhe: passa-alta
CR	<i>Compression Rate</i>
CWT	<i>Continuous Wavelet Transform</i>
DCT	<i>Discrete Cosine Transform</i>
DE	<i>Differential Evolution</i>
DWT	<i>Discrete Wavelet Transform</i>
ECG	Eletrocardiograma
FFT	<i>Fast Fourier Transform</i>
F <sub>s</sub>	<i>Frequency sampling</i> (Taxa de amostragem)
GA	<i>Genetic Optimization Algorithm</i>
HP	<i>High Pass</i> (Passa-alta)
Hz	Hertz
IWT	<i>Integer Wavelet Transform</i>
KB	<i>Kilobyte</i>
LBFGS	<i>Limited Broyden-Fletcher-Goldfarb-Shanno</i>
LP	<i>Low Pass</i> (Passa-baixa)
MSE	<i>Mean Squared Error</i>
NRDPWT	<i>Non-Recursive Discrete Periodized Wavelet Transform</i>
PRD	<i>Percentual Root Mean Square Difference</i>
STFT	<i>Short-Time Fourier Transform</i>

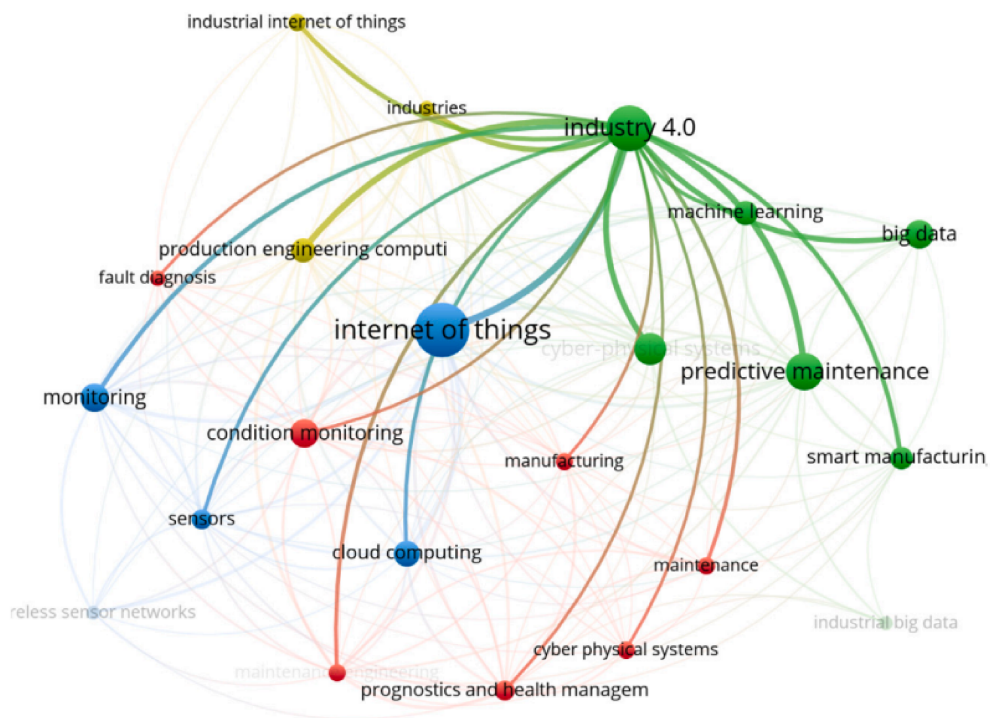
## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>11</b>
<b>2</b>	<b>OBJETIVOS . . . . .</b>	<b>14</b>
2.1	OBJETIVO GERAL . . . . .	14
2.2	OBJETIVOS ESPECÍFICOS . . . . .	14
<b>3</b>	<b>REVISÃO BIBLIOGRÁFICA . . . . .</b>	<b>15</b>
<b>4</b>	<b>FUNDAMENTAÇÃO TEÓRICA . . . . .</b>	<b>23</b>
4.1	TRANSFORMADA WAVELET . . . . .	23
4.1.1	Transformada Wavelet Contínua . . . . .	24
4.1.2	Transformada Wavelet Discreta . . . . .	26
<b>5</b>	<b>METODOLOGIA . . . . .</b>	<b>28</b>
5.1	MÉTODO DE COMPRESSÃO . . . . .	28
5.2	OTIMIZAÇÃO DE LIMIAR . . . . .	33
<b>6</b>	<b>RESULTADOS E DISCUSSÃO . . . . .</b>	<b>36</b>
6.1	ROTOR EM MANCAL MAGNÉTICO COM ADIÇÃO DE IMPACTOS	36
6.2	EXAUSTOR INDUSTRIAL . . . . .	44
<b>7</b>	<b>CONCLUSÃO . . . . .</b>	<b>49</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>50</b>

## 1 INTRODUÇÃO

Desde o final do século passado, o cenário industrial encontra-se em estado de rápida transformação, impulsionado pelo contexto de disrupção e digitalização trazidos pela 4ª Revolução Industrial. Diante deste contexto de mudanças, chamado "Indústria 4.0", ganham relevância e ampla adoção conceitos como virtualização, IoT (*Internet of Things*), big data, data analytics, inteligência artificial, computação em nuvem, robotização, entre outros. A Figura 1 traz os termos de pesquisa mais relacionados ao termo "Indústria 4.0".

Figura 1 – Termos de pesquisa relacionados ao termo: "Industria 4.0"



Fonte: ZONTA et al. (2020)


Frente a este cenário, empresas têm buscado aplicar as tecnologias desenvolvidas pela indústria 4.0 para a manutenção industrial baseada em confiabilidade por meio da manutenção preditiva, buscando assim aumentar a produtividade, reduzir custos, e aumentar a eficiência e segurança dos colaboradores.

A manutenção preditiva permite que, por meio do monitoramento contínuo e automatizado de maquinários, problemas possam ser antecipados muito antes da falha do equipamento. Vale ressaltar que, diante das soluções empregadas na estratégia de manutenção preditiva, o monitoramento de vibração se destaca como uma das principais técnicas para antecipação de problemas em maquinários.

Tendo em vista esta demanda crescente no uso de dados, surge um novo desafio para os próximos anos: armazenamento e transmissão de grandes volumes de informação,

como mostra a Figura 2, obtida por meio de uma pesquisa realizada por (IDC, 2021), que ressalta o aumento no volume global de dados armazenados até 2025. Além disso, a tendência de aumento na demanda por armazenamento de dados é amplificada levando-se em conta as técnicas de monitoramento preditivo contínuo tendo por base a análise de dados de transdutores com alta taxa de amostragem, já que, em relação ao tempo de amostragem, são adquiridos grandes volumes de dados.

Figura 2 – Perspectiva global do volume armazenado de dados até 2025



Fonte: IDC (2021)

Para o ambiente industrial, a solução para o desafio apresentado acima está dividida em duas abordagens principais: expansão da capacidade de armazenamento por meio de aquisição ou construção de servidores de armazenamento dados, ou redução do volume ocupado pelos dados armazenados (compactação/compressão).

A partir da segunda abordagem, busca-se minimizar as perdas provenientes do processo de compactação e maximizar a taxa de compressão, ou seja, a razão entre o espaço em disco ocupado pelo arquivo ao final do processo de compressão e o espaço em disco originalmente ocupado pelo arquivo.

Neste contexto, desde sua consolidação como teoria, a partir dos trabalhos de Morlet e Grossman em 1984 (DAUBECHIES, 1992), (PENG ET AL., 1999), a análise wavelet tem sido amplamente utilizada nos campos de compressão e classificação de sinais periódicos e também de imagens. A localização nos domínios do tempo e frequência torna a compressão a partir de transformada wavelet especialmente adequada para sinais transientes ou temporalmente variantes.

Além disso, as propriedades de base ortonormal e bi-ortogonal tornam eficiente a transformação e redução de dimensionalidade de domínios, o que é revertido na existência de algoritmos computacionais rápidos e acurados para operações de redução de espaço e simplificação de modelos.

Para o campo de compressão de sinais, encontra larga utilização e estudos na área biomédica, acústica e de vibrações. (UTHAYAKUMAR ET AL., 2018) realizaram uma extensa revisão dos trabalhos empregados neste campo, destacando *wavelet* como um

método relevante nos campos de compressão de sinais cardíacos e imagens, principalmente imagiologia médica. Também vale apontar para (PENG ET AL., 1999) que realizaram uma revisão bibliográfica de trabalhos com *wavelets* nos campos de monitoramento de condição de máquinas, diagnóstico de falhas e compressão de sinais.

Apesar das vantagens acima citadas, a utilização desta teoria é dependente de uma ou mais etapas de quantização, que necessariamente implicam em um processo de perda de dados de natureza irreversível.

Deste modo, é buscado obter uma razão de compromisso entre o CR (*Compression Rate*) e a distorção do sinal após compressão. Para isso, algumas das técnicas que, combinadas à compressão por wavelet possuem potencial de encontrar o valor ótimo para o limiar (*threshold*) durante a etapa de quantização, são os métodos de otimização de variáveis.

## 2 OBJETIVOS

### 2.1 OBJETIVO GERAL

Este trabalho tem por objetivo realizar a implementação computacional de um algoritmo de compressão de sinais baseado na Transformada Wavelet Discreta com seleção de limiar automática baseado em otimização por Evolução Diferencial, buscando maximizar a compressão e reduzir o erro de quantização.

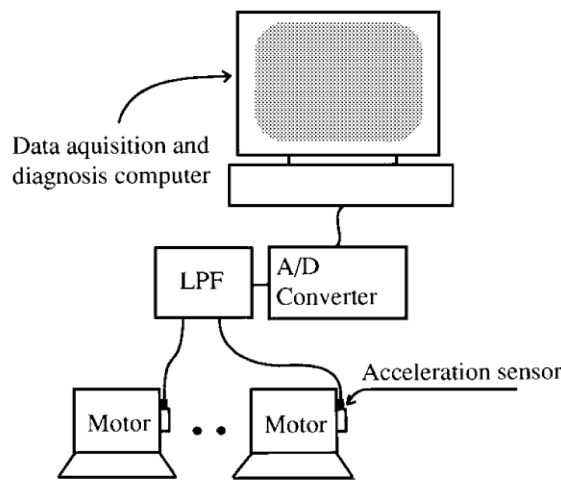
### 2.2 OBJETIVOS ESPECÍFICOS

- Desenvolver um algoritmo computacional capaz de comprimir sinais utilizando Transformada Wavelet Discreta;
- Otimizar os valores dos limiares (*thresholds*) de quantização por meio de um algoritmo de otimização baseado em Evolução Diferencial, buscando maximizar a taxa de compressão e minimizar o erro de quantização;
- Avaliar a taxa de compressão dos dados;
- Avaliar o erro de compressão dos dados, comparando os dados comprimidos com os dados originais;
- Avaliar o tempo de execução do modelo implementado.

### 3 REVISÃO BIBLIOGRÁFICA

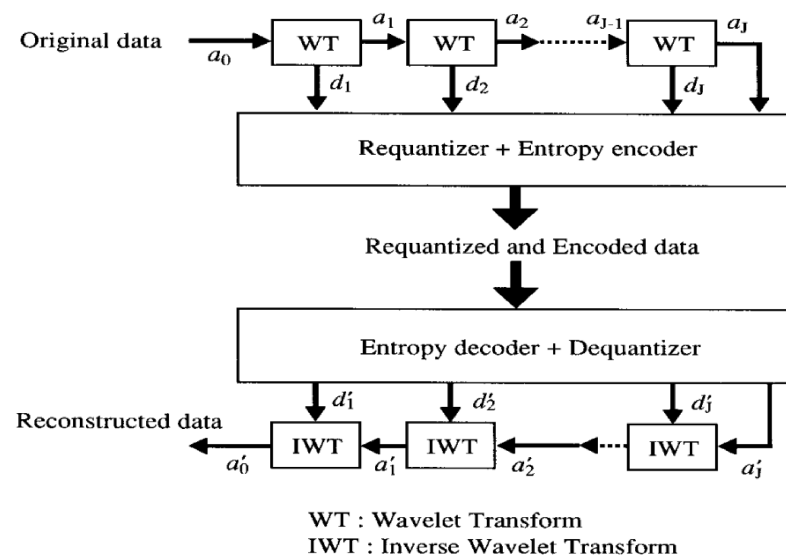
(TANAKA ET AL., 1997) propôs uma metodologia de compressão de sinais utilizando DWT. Os sinais eram provenientes de uma usina termelétrica, empregados para *fault diagnosis*. Uma ilustração esquemática do sistema de monitoramento das máquinas rotativas pode ser observada na Figura 3.

Figura 3 – Esquema genérico de um sistema de monitoramento de vibração de máquinas rotativas



Fonte: TANAKA et al. (1997)

Figura 4 – Esquema da metodologia de compressão proposta. A metodologia proposta no atual trabalho apresenta semelhanças com a metodologia de Tanaka



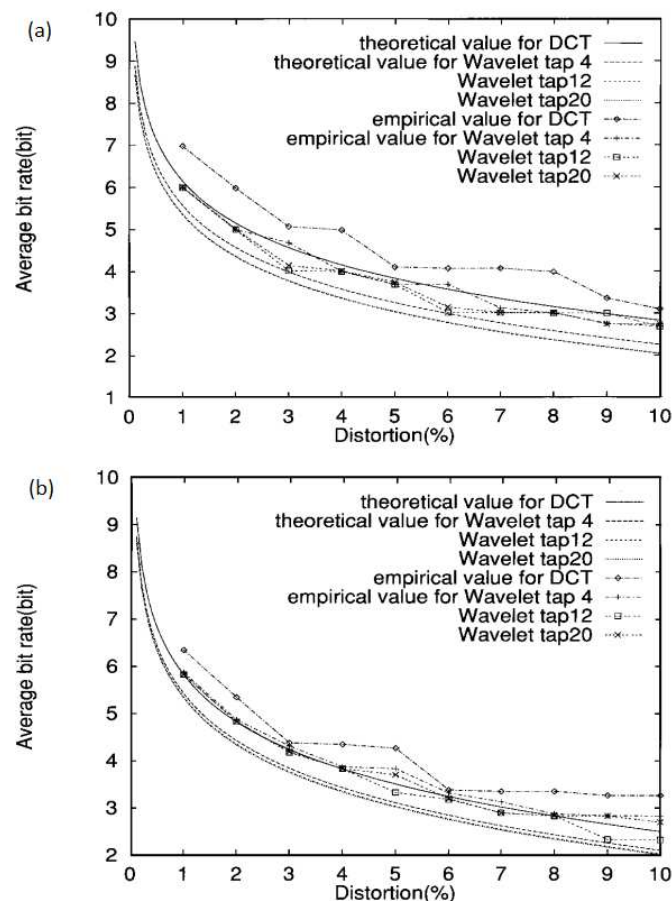
Fonte: TANAKA et al. (1997)



Em seu trabalho, Tanaka buscou reduzir a taxa de bits do sinal para uma distorção pré-definida pelo usuário. Para disso, (TANAKA ET AL., 1997) comparou os dados com diferentes famílias de wavelet-mãe, além de comparar a compressão de DWT com a compressão de DCT, levando em conta a distorção e *bit-rate* (inversamente proporcional à CR). Os sinais avaliados foram de diversos tipos de defeito em rolamentos de máquinas rotativas: desbalanceamento, falha na pista interna, falha na pista externa e má lubrificação.

A Figura 5 apresenta os resultados de compressão *versus* distorção para várias famílias de DWT, além de comparar com a compressão utilizando DCT. Nela, mostra-se duas condições de rolamento: rolamento em condições normais e rolamento com falha na pista externa. É possível notar o melhor desempenho geral das famílias wavelet frente à DCT em ambos os casos, além da redução significativa de distorção para valores de *bit-rate* acima de 8.

Figura 5 – Desempenho de compressão de diferentes wavelet-mãe e do método DCT. (a) Rolamento em condições normais; (b) Rolamento com falha na pista externa




Fonte: TANAKA et al. (1997)

Em seus trabalhos, (STASZEWSKI, 1998) e (STASZEWSKI, 1997), Wieslaw J. Staszewski realizou uma revisão teórica da teoria wavelet, além de demonstrar sua eficácia

para diferentes tipos de sinais. Ele utilizou a métrica MSE (*Mean Squared Error*) para avaliação do erro de reconstrução. Os sinais avaliados para a avaliação de compressão foram:

- Sinal estacionário contínuo
- Sinal contínuo não-estacionário
- Sinal transiente

Figura 6 – Avaliação temporal de diferentes sinais antes (–) e após compressão (– –): (a) Sinal estacionário contínuo, MSE=2.02%; (b) Sinal contínuo não-estacionário, MSE=5.03%; (c) Sinal transiente, MSE=0.20%




Fonte: STASZEWSKI (1998)

O autor também mostrou a utilização das wavelets para classificação de sinais anômalos. Esta metodologia vai além do escopo deste trabalho, mas é muito utilizada no campo de *health monitoring* e *fault diagnosis*, um tópico já evidenciado como atual e importante no Capítulo 1 deste trabalho. O emprego desta técnica pode ainda ser aliado a outras técnicas de classificação de sinal ou detecção de anomalias a partir de redes neurais para aumentar a confiabilidade do modelo de detecção. A Figura 7 mostra a diferença no sinal reconstruído após seleção e preservação dos parâmetros (níveis) mais relevantes para

um defeito em dentes de uma engrenagem. O defeito se torna evidente, em comparação ao sinal de uma engrenagem em condições normais.

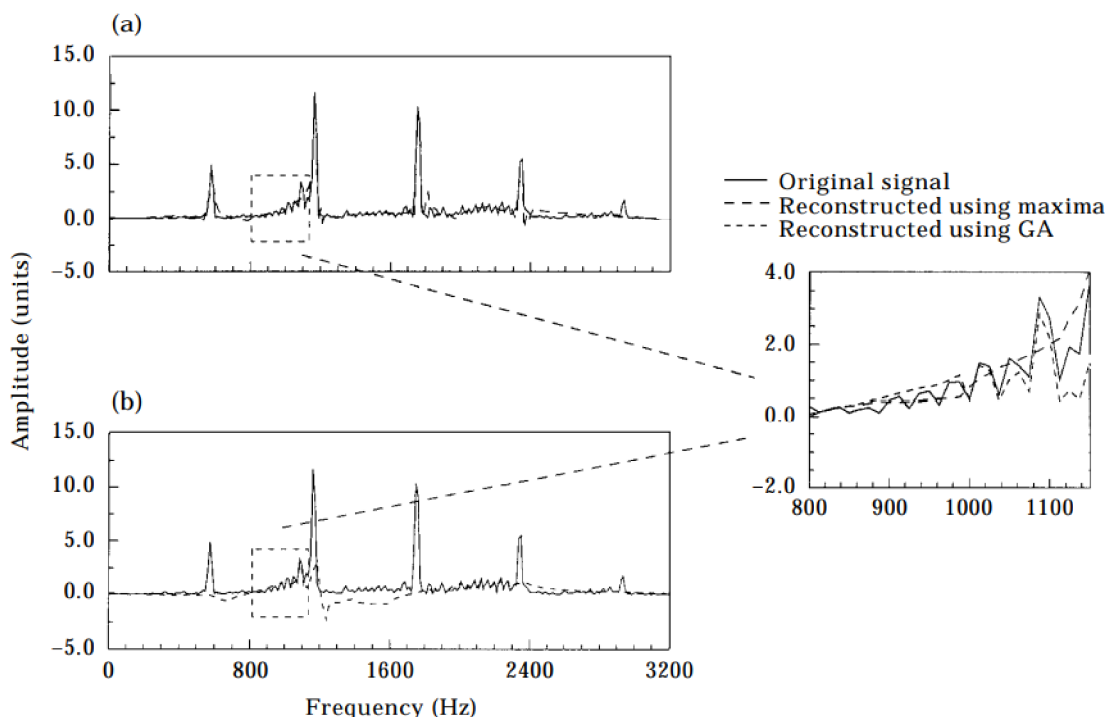
Figura 7 – Sinal temporal de engrenagem reconstruído após *thresholding* dos coeficientes wavelet para preservação dos coeficientes mais relevantes: (a) Engrenagem normal; (b) Engrenagem com falha nos dentes



Fonte: STASZEWSKI (1998)

Além disso, o autor propôs um método de encontrar os coeficientes ótimos de compressão a partir de um algoritmo de otimização GA (*Genetic Optimization Algorithm*) (STASZEWSKI, 1997). Para tal, utilizou os mesmos dados de falha em engrenagem mostrados na Figura 7 e buscando preservar as bandas laterais ao segundo componente espectral. O espectro do sinal reconstruído a partir da metodologia utilizando GA é mostrado na Figura 8, em conjunto com o sinal original e com o sinal reconstruído a partir de uma técnica simples de *thresholding*. O zoom na região mostra o sucesso em preservar as bandas de interesse. O MSE alcançado em (a) foi de 82.0% avaliando de 800–1150 Hz, enquanto em (b), MSE=24.7%.

Figura 8 – Espectro de engrenagem defeituosa com: (a) *thresholding* simples e (b) *thresholding* por GA *versus* sinal original

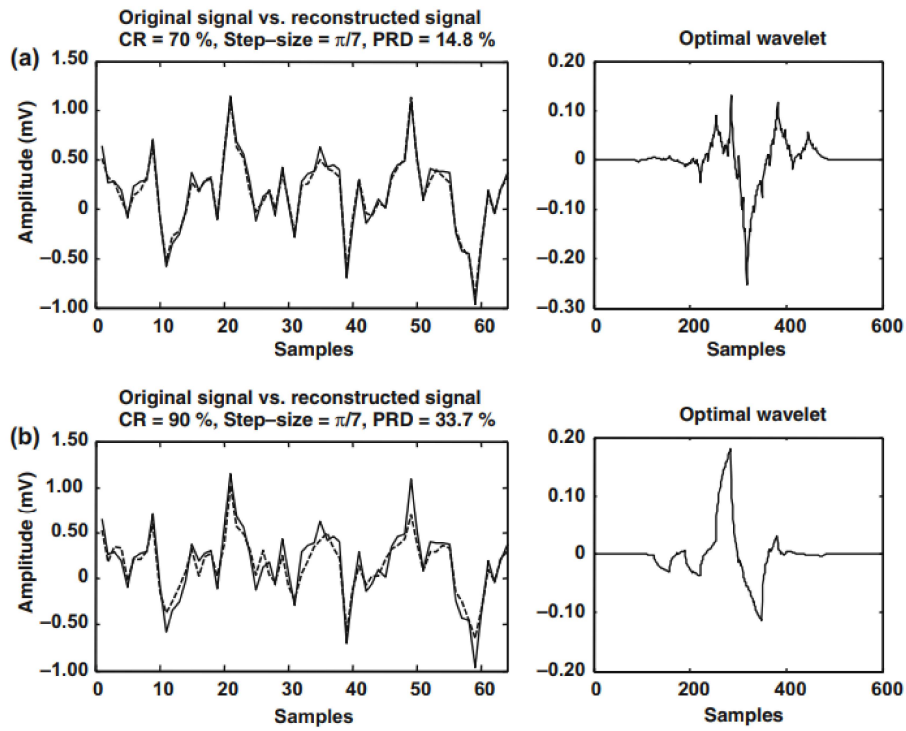


Fonte: STASZEWSKI (1997)

Nielsen demonstrou em seus trabalhos (NIELSEN ET AL., 2006a), (NIELSEN ET AL., 2006b), a utilização do método de compressão baseado em DWT para compactação de sinais de ECG (Eletrocardiograma), utilizando um otimizador para obter a wavelet-mãe ótima, e buscando aumentar CR e reduzir a distorção.

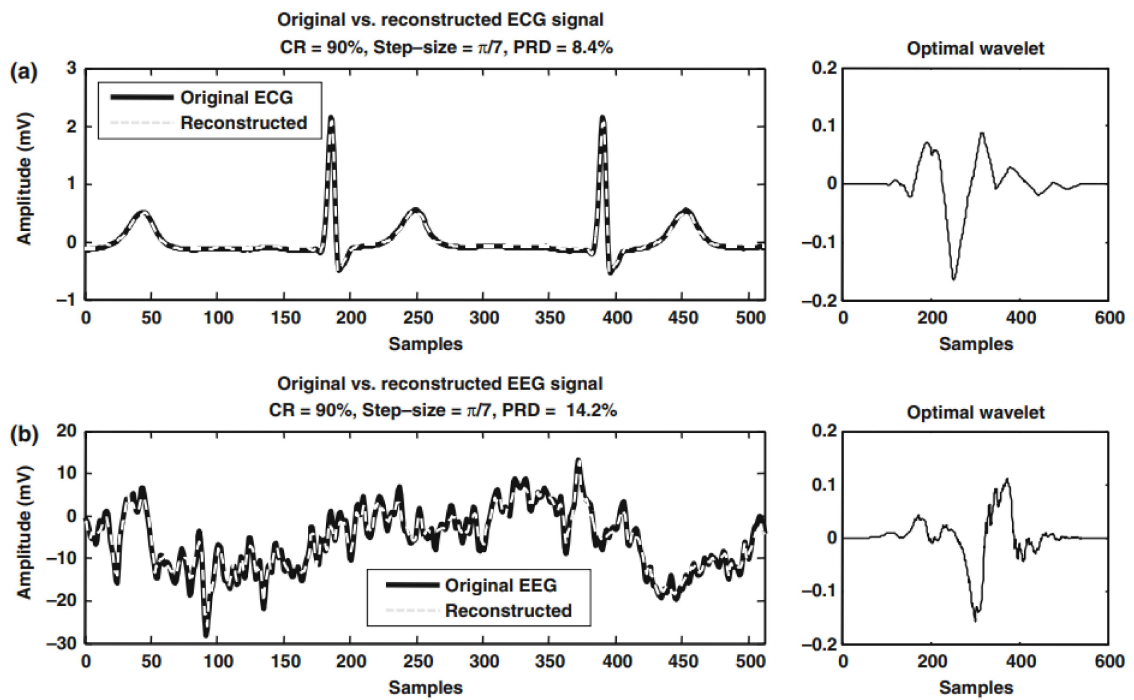
Os resultados da Figura 9 e Figura 10 demonstraram elevada dependência entre a família/forma de wavelet-mãe escolhida e a eficiência de compressão para determinados tipos de sinal, destacando que determinada família de wavelets podem performar a compressão melhor para certos tipos de sinais que para outros.

Figura 9 – Wavelets-mãe ótimas para o mesmo sinal e diferentes valores de CR



Fonte: NIELSEN et al. (2006a) e NIELSEN et al. (2006b)

Figura 10 – Reconstrução de dois sinais diferentes




Fonte: NIELSEN et al. (2006a) e NIELSEN et al. (2006b)

A partir disto, (WU, TSUNG-CHING ET AL., 2013), propôs um método de compactação de sinais de ECG baseado em wavelet utilizando um algoritmo genético de otimização para definição dos *thresholdings* em 11 camadas de decomposição wavelet. Os algoritmos genéticos de otimização são característicos pela busca de um mínimo global com base em uma população inicial de indivíduos, a partir dos quais os melhores indivíduos são selecionados e cruzados, além de sofrerem mutações; desta forma, as melhores características são repassadas à geração seguinte até o valor ótimo.

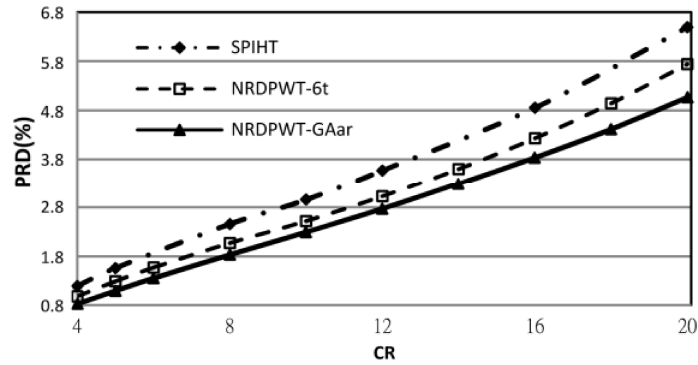
O autor utilizou a métrica PRD como método de avaliação do erro de reconstrução (também conhecido como distorção). Ao final da otimização e após obtenção dos melhores valores para 11 sinais de treinamento, foi realizado um método de ajuste de curvas, e os valores de *threshold* nos 11 níveis de decomposição são determinados genericamente em função de apenas uma variável ( $QF$ ). O autor encontrou uma relação de proporcionalidade entre o aumento de CR e PRD, o que também foi notado em trabalhos de outros autores, como (NIELSEN ET AL., 2006a) e (NIELSEN ET AL., 2006b). As Figuras 11 e 12 ilustram os resultados obtidos.

Figura 11 – Valor das escalas de quantização (*thresholds*) dos coeficientes nas diferentes camadas de decomposição. As quatro curvas descrevem quatro valores  $c_g$  impostos: 2, 4, 8 e 16



Fonte: WU, TSUNG-CHING et al. (2013)

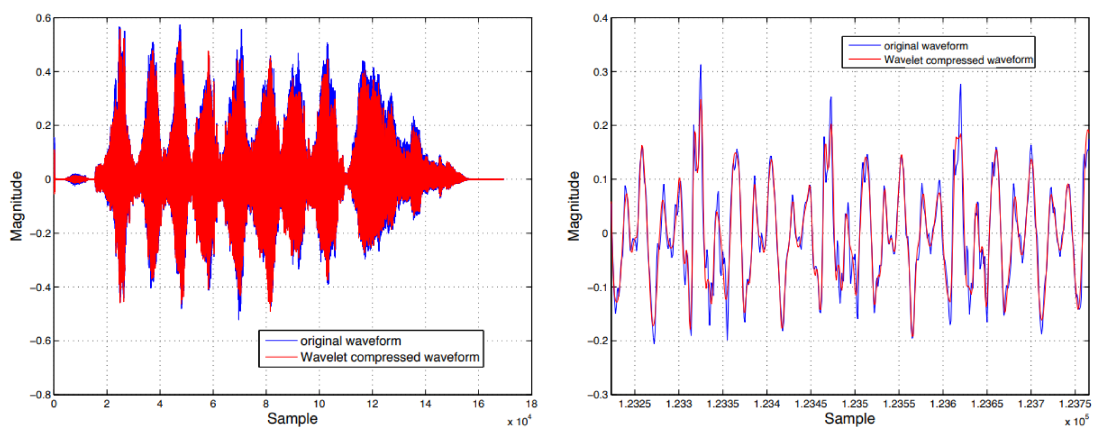
Figura 12 – Relação entre CR e o erro PRD para a metodologia proposta (NRDPWT-GAar) e outras duas metodologias de compressão de sinais de ECG



Fonte: WU, TSUNG-CHING et al. (2013)

Por fim, é importante ressaltar o trabalho de (KHALIFA ET AL., 2008) e (ROMANO ET AL., 2016) no campo de compressão de sinais de áudio. Romano propôs uma compressão de sinais de áudio em tempo real, graças à um sistema processamento paralelo orientado à GPU, que atingiu alta velocidade no processamento dos dados. O tamanho do arquivo obtido ao final da compressão foi aproximadamente 10 vezes menor que o arquivo de sinal original (CR=90%). A Figura 13 traz uma comparação entre o sinal original e o sinal após compressão.

Figura 13 – Sobreposição do sinal original (azul) sobre o sinal comprimido (vermelho). À esquerda, sinal completo e à direita, detalhe de um segmento do sinal



Fonte: ROMANO et al. (2016)

## 4 FUNDAMENTAÇÃO TEÓRICA


### 4.1 TRANSFORMADA WAVELET

A Transformada Wavelet, bem como a Transformada de Fourier, são ferramentas para representação de uma função integrável. Não obstante, as wavelets são vistas como detentoras de algumas vantagens frente às transformadas de Fourier para certos conjuntos de dados.

Uma grande desvantagem dos algoritmos baseados em Transformada de Fourier (como FFT ou STFT) é que eles capturam informações de frequência global ou semi-locais, ou seja, frequências que persistem em um sinal inteiro ou em janelas de processamento. Esse tipo de decomposição de sinal pode não servir bem a todas as aplicações, por exemplo, Eletrocardiografia (ECG) onde os sinais têm intervalos curtos de oscilação característica, ou ainda sinais com variação de frequência no tempo (sinais transientes). Uma abordagem alternativa é a Transformada Wavelet, que decompõe uma função em um conjunto de wavelets.

Uma Wavelet é uma oscilação ondulatória localizada no tempo. As wavelets têm duas propriedades básicas: escala e localização. A escala (ou dilatação) define quão “esticada” ou “comprimida” uma wavelet está. Esta propriedade está relacionada com a frequência definida para o sinal. Já a localização define onde a wavelet está posicionada no tempo (ou espaço). A Figura 14 exemplifica como uma wavelet pode decompor um sinal puramente senoidal.

Figura 14 – Representação de uma wavelet a decompor um sinal senoidal.




Fonte: Autoria Própria

Tal característica permite às wavelets adaptar a janela temporal aplicada ao sinal de acordo com a escala de frequência analisada, ao contrário das transformadas de Fourier, onde a janela temporal permanece fixa ao longo da decomposição do sinal. A Figura 15 traz uma comparação ao caso da STFT utilizando a janela de Gabor (uma teoria comumente utilizada para convolucionar um sinal temporal em uma janela gaussiana de escala fixa,



a fim de transformá-lo em um espectrograma (*frequência vs tempo*), segundo (GABOR, 1946)) e a decomposição wavelet.

Figura 15 – Comparação entre decomposição STFT (GABOR, 1946) e wavelet



Fonte: MATLAB (2022)

Há dois tipos de Transformada Wavelet: Contínua e Discreta. A principal diferença entre esses dois tipos é que a Transformada Wavelet Contínua (CWT) usa um número infinito de escalas e localizações. Enquanto a Transformada Wavelet Discreta (DWT) usa um conjunto finito de wavelets, definido em um determinado conjunto de escalas e localizações.

#### 4.1.1 Transformada Wavelet Contínua


A CWT (*Continuous Wavelet Transform*) é definida como:

$$\psi_{ab}(t) = \frac{1}{\sqrt{a}} \psi \left( \frac{t-b}{a} \right) \quad (1)$$

Sendo o parâmetro  $a$  relacionado à escala da wavelet, e  $b$  relacionado à localização da mesma. O termo  $\psi$  da equação se refere à wavelet-mãe utilizada.

A wavelet-mãe  $\psi$  de (1) é definida de acordo com a família wavelet (formato fundamental de onda) desejada para decomposição do sinal. Há uma série de famílias quanto à uma variedade de aplicações, diferindo quanto à ortogonalidade, biortogonalidade, capacidade de decompor melhor certos tipos de sinal, entre outras características. As wavelets mais comuns são: *Haar*, *Daubechies*, *Symlets*, *Coiflets*, *Biorthogonal*, "*Chapéu-mexicano*" e *Morlet*.

Figura 16 – Famílias wavelet



Fonte: Autoria Própria

A CWT decompõe uma função temporal  $f(t)$  em coeficientes  $W_f(a, b)$  por meio de:

$$W_f(a, b) = \int_{-\infty}^{\infty} \psi_{ab}(t) f(t) dt \tag{2}$$

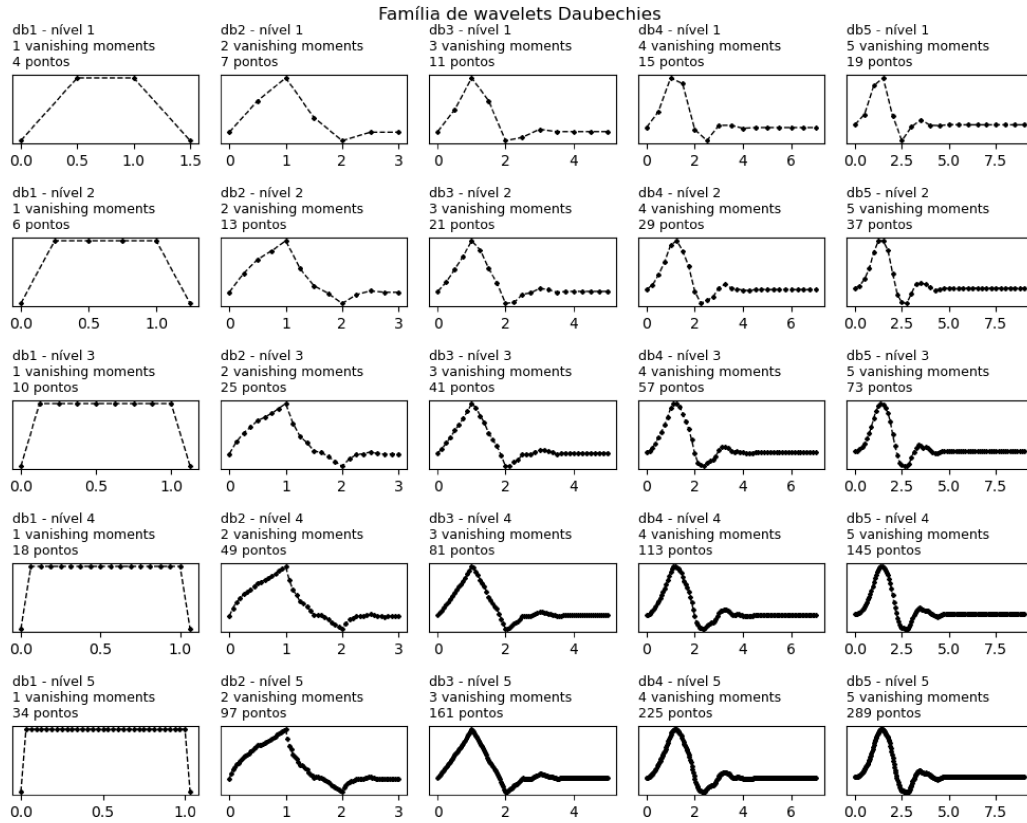
A transformação é reversível pela superposição IWT (*Integer Wavelet Transform*):

$$f(t) = \frac{1}{C_\psi} \int_{-\infty}^{\infty} \int_0^{\infty} \frac{da db}{a^2} \underbrace{W_f(a, b)}_{\text{coeficientes wavelet-mãe}} \underbrace{\psi(t)}_{\text{wavelet}} \tag{3}$$

Quanto à capacidade representação de funções pelas wavelets, cada família wavelet possui um número de "momentos de zero" ou *vanishing moments* igual a metade de sua ordem, sendo este número equivalente à quão complexa pode ser a função a ser representada. Por exemplo,  $db2$  possui 1 vanishing moment,  $db4$  possui 2, etc e conforme este valor aumenta, maior pode ser o grau de representação de uma função polinomial. Em suma, *vanishing moment* limita a capacidade das wavelets de representar comportamento ou informação polinomial em um sinal.

A Figura 17 exemplifica os vanishing moments da família de wavelets *Daubechies*.

Figura 17 – Representação da família *Daubechies* para várias ordens e níveis.



Fonte: Autoria Própria

### 4.1.2 Transformada Wavelet Discreta

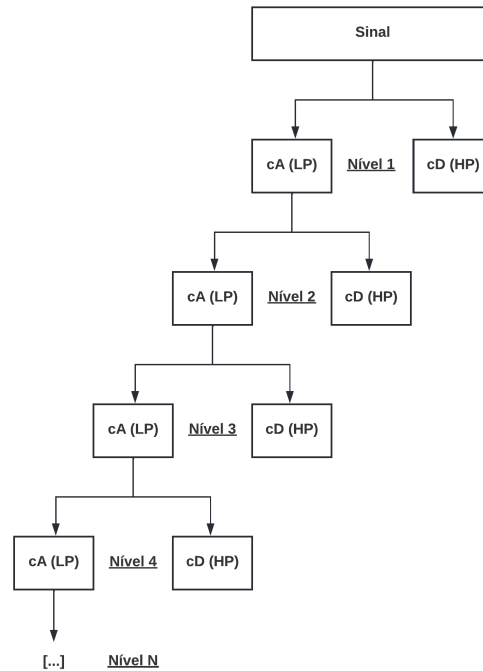
A CWT sofre de duas desvantagens: redundância e impraticabilidade. A primeira é óbvia pela natureza da transformada wavelet e a segunda pelo fato de que ambos os parâmetros de transformação são contínuos. Pode-se tentar resolver ambos os problemas amostrando os parâmetros (a, b) para obter um conjunto de funções wavelet em parâmetros discretizados.

A equação que governa a DWT (*Discrete Wavelet Transform*) é:

$$W_f(a, b) = \int_{-\infty}^{\infty} \psi_{ab}(t) f(t) dt \quad (4)$$

No entanto, este atua em níveis discretizados. A decomposição dos coeficientes ocorre na forma de um banco de filtros passa-banda. O sinal é decomposto em filtros passa-alta e passa-baixa consecutivamente a cada nível, até um nível definido, ou até o nível máximo de decomposição, a partir de onde não há mais resolução suficiente para decomposição.

Figura 18 – Decomposição do sinal em bancos de filtros HP (*High Pass* (Passa-alta)) e LP (*Low Pass* (Passa-baixa)) a cada nível.



Fonte: Autoria Própria

O resultado da operação de decomposição por meio dos filtros passa-baixa recebe o nome de *coeficientes de Aproximação (cA)*. Já para os filtros passa-alta, é dado o nome de *coeficientes de Detalhe (cD)*. A partir do primeiro nível, cA e cD são executados a partir dos resultados cA do nível anterior, reduzindo em uma oitava/nível a frequência de corte dos filtros, até o nível máximo de decomposição.

A partir da decomposição do sinal em bancos de filtros, é possível reduzir o ruído em alguma banda, ou ainda, comprimir o sinal por meio da redução de seus coeficientes em determinados níveis onde avalia-se que a dominância frente à informação desejada no sinal não é alta. À esse procedimento de remoção de coeficientes, dá-se o nome de *thresholding*, ou ainda, quantização.

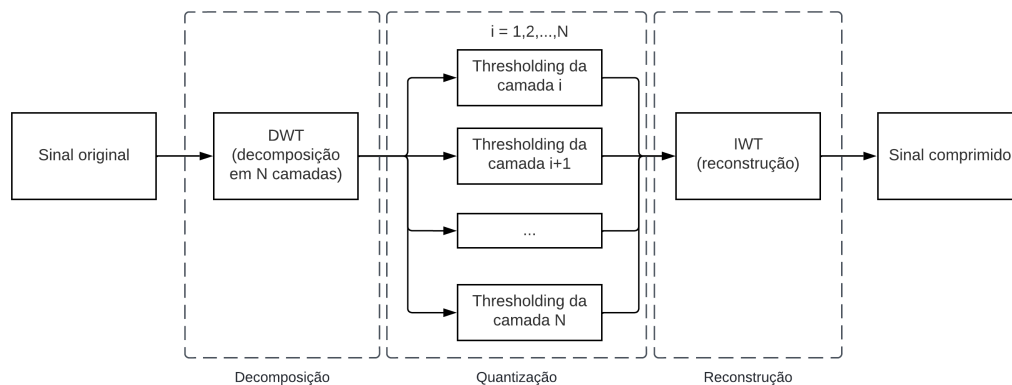
## 5 METODOLOGIA

### 5.1 MÉTODO DE COMPRESSÃO

O método de compressão implementado é composto de 3 módulos básicos:

- **Encoder:** o sinal é decomposto em camadas a partir dos parâmetros de wavelet-mãe e número de camadas desejadas;
- **Quantização:** procedimento de *thresholding* dos coeficientes;
- **Decoder:** o sinal é reconstruído por IWT (*Integer Wavelet Transform*) a partir dos coeficientes resultantes do processo de quantização;

Figura 19 – Metodologia de compressão proposta

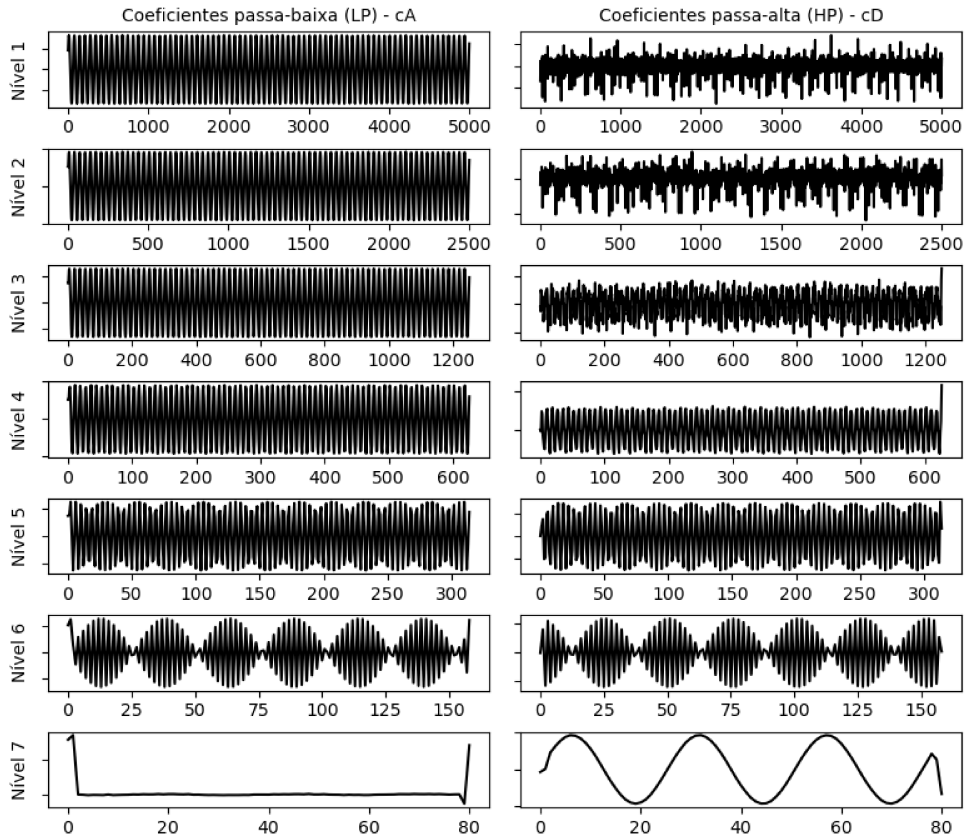


Fonte: Autoria Própria

Durante o processo de decomposição, o sinal é decomposto em  $N$  camadas, sendo este valor um parâmetro de entrada do algoritmo implementado. A função de decomposição utilizada retorna um vetor correspondente aos coeficientes da  $n$ -ésima camada do filtro de cD (Coeficientes de Detalhe: passa-alta) (HP), e  $N$  vetores correspondentes aos coeficientes de cA (Coeficientes de Aproximação: passa-baixa) (LP) da 1ª à  $n$ -ésima camada (nível).

A Figura 20 exemplifica o resultado da decomposição de um sinal (1 segundo de aquisição com  $F_s$  de 10000 Hz, amostrado em um rotor com mancais magnéticos) até sua 7ª camada. É possível observar, temporalmente, a redução da metade do domínio anterior em cada nível.

Figura 20 – Coeficientes DWT cA e cD de um sinal decomposto



Fonte: Autoria Própria

Na etapa de quantização ocorre o processo de remoção dos coeficientes proposto, na forma de *hard thresholding*, onde é fixado um valor de limiar  $\Gamma_i$  e são removidos os coeficientes menos significantes, em relação ao valor do maior coeficiente em cada camada. Os coeficientes que tiverem valor menor que o limiar  $\theta$  (*threshold*) em cada nível, são levados à zero. A equação (5) descreve este processo, e a equação (6) descreve o método adotado neste trabalho para definição do limiar  $\theta$ , sendo definido como uma relação à proporção  $\Gamma$ , dos maiores coeficientes em um nível  $i$ .

$$\begin{cases} C_{n,i} = C_{n,i}, & \text{se } |C_{n,i}| \geq \theta \\ C_{n,i} = 0, & \text{se } |C_{n,i}| < \theta \end{cases} \quad (5)$$

$$\begin{cases} C_{n,i} = C_{n,i}, & \text{se } |C_{n,i}| \geq \Gamma_i * \max(|C_{1:N,i}|) \\ C_{n,i} = 0, & \text{se } |C_{n,i}| < \Gamma_i * \max(|C_{1:N,i}|) \end{cases} \quad (6)$$

Sendo  $C_{n,i}$  o valor individual de cada coeficiente em um determinado nível,  $C_{1:N,i}$  o vetor de coeficientes,  $\theta$  o limiar e  $\Gamma_i$  o valor da proporção dos menores coeficientes a serem removidos no nível  $i$ .

Durante a etapa de compressão, o sinal também é transformado de 64 bits para 16 bits. Este processo resulta em um erro de quantização extremamente baixo, uma vez que o sinal já é amostrado em 16 bits para a maioria das placas de aquisição (inclusive a placa de aquisição utilizada para este trabalho). Esta etapa da quantização, aliada aos filtros wavelet, potencializa o CR obtido ao final do processo de compressão.

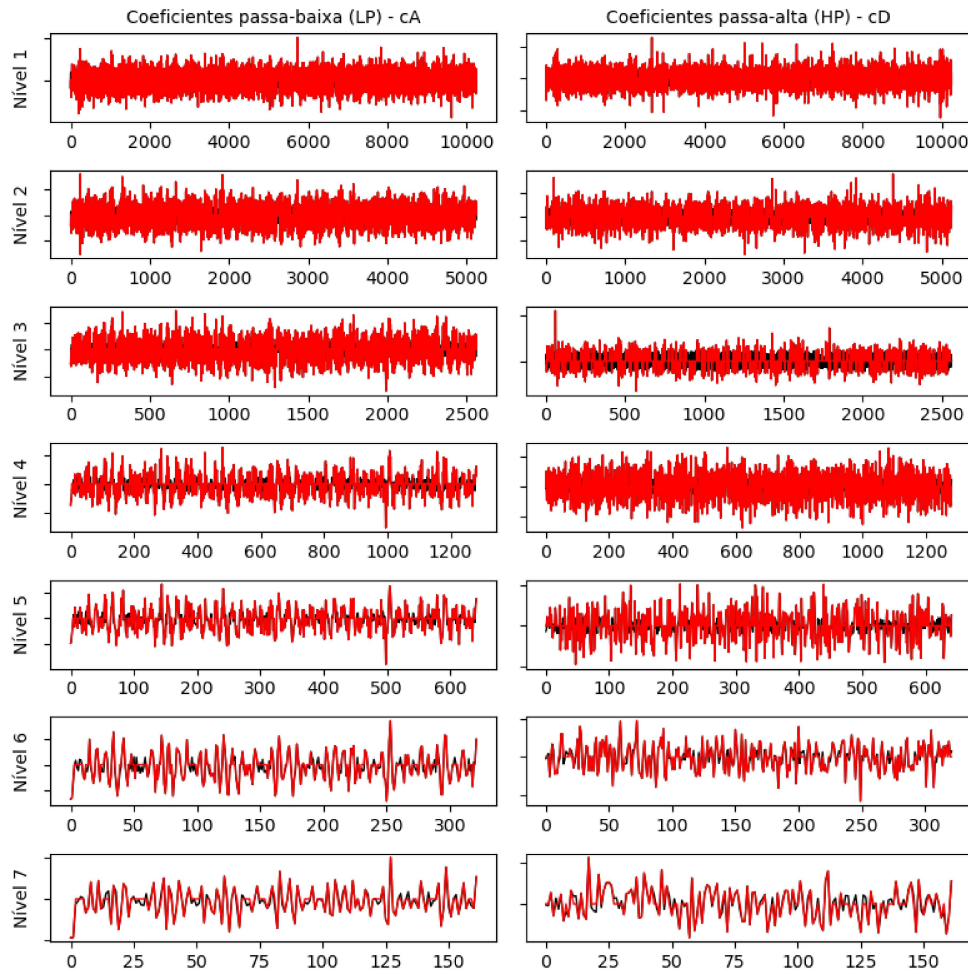
A Figuras 21 e 22 ilustram o resultado do *thresholding* para dois valores diferentes de  $\Gamma_i$  em um sinal de um compressor amostrado com  $F_s$  de 20480 Hz. Em 21, a quantização removeu os 20% coeficientes menos relevantes em todas as camadas; já na Figura 22, esse valor foi de 40%.

Pelas figuras, é possível observar a influência do *thresholding* sobre os coeficientes para a compressão. Aumentar o valor de  $\Gamma$  culminará em um arquivo com menor tamanho, no entanto com erro de reconstrução maior. O problema na definição de  $\Gamma$  é amplificado se for levado em conta o fato de que o valor ótimo de  $\Gamma$  (a melhor solução de compromisso entre o CR e o erro de reconstrução para os objetivos buscados) não é o mesmo para cada nível: utilizar a mesma razão de  $\Gamma$  em todos os níveis pode resultar na eliminação de componentes importantes do sinal.

O método de quantização, como definido acima, também é influenciado pela variabilidade dos dados ao longo do tempo: sinais com pouca variabilidade na amplitude apresentarão um *thresholding* severo (alta redução dos coeficientes) a partir de um valor de limiar, mas pouca efetividade no *thresholding* com limiares menores.

Outro problema envolve a definição do valor ótimo de limiar, já que por meio da inserção manual de  $\Gamma$ , a compressão pode ter como resultado um elevado erro de reconstrução para obter alto CR, ou ainda o oposto: baixo CR para um erro demasiadamente baixo.

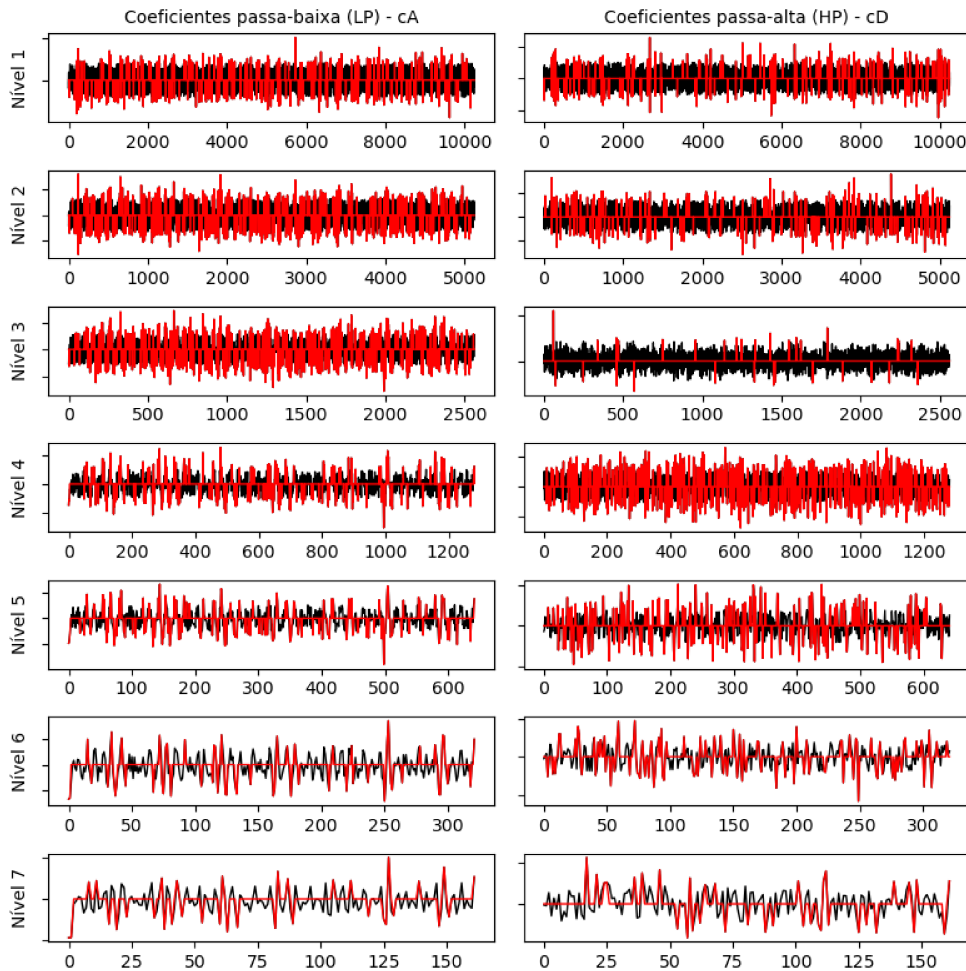
Figura 21 – Coeficientes DWT cA e cD originais (preto) e após quantização (vermelho).  $\Gamma = 20\%$  do maior coeficiente em cada nível



Fonte: Autoria Própria



Figura 22 – Coeficientes DWT cA e cD originais (preto) e após quantização (vermelho).  
 $\Gamma = 40\%$  do maior coeficiente em cada nível



Fonte: Autoria Própria

A última etapa do método proposto envolve a reconstrução do sinal a partir dos coeficientes resultantes do processo de quantização, gravação no banco de dados e cálculo das métricas de eficiência da compressão: CR (*Compression Rate*) e MSE (*Mean Squared Error*). Os dados são reconstruídos por meio de IWT (*Integer Wavelet Transform*). Para gravação no banco de dados, os dados são transformados no formato HDF5, com compressão de 9 camadas pela biblioteca GZIP. Este método não gera nenhuma perda ao sinal (*lossless compression*) e o formato de arquivo é facilmente lido por bibliotecas de linguagens de programação como *Matlab* e *Python*.

O CR (*Compression Rate*) é calculado de acordo com a Equação (7):

$$CR = \frac{N_0}{N_c} \quad (7)$$

Sendo  $N_0$  o número de bits do sinal original e  $N_c$  o equivalente, do sinal comprimido.

O MSE (*Mean Squared Error*), métrica de erro adotada por este trabalho, é calculado de acordo com a Equação (10). É ainda proposta uma normalização dos sinais pelo maior valor do sinal original para o cálculo da métrica (sendo  $y_o$  o sinal original e  $y_c$  o sinal reconstruído):

$$Y_o = \frac{y_o}{\max(|y_o|)} \quad (8)$$

$$Y_c = \frac{y_c}{\max(|y_o|)} \quad (9)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_{i,o} - Y_{i,c})^2 \quad (10)$$

É importante apontar que, para o CR ser calculado, é necessário que ele seja gravado no sistema operacional (em formato HDF5) e então tenha seu número de *bits* lido, para que haja comparação com o tamanho do sinal original.

A métrica de *redução* é equivalente ao CR, e se traduz no espaço ocupado do sinal reconstruído em relação ao sinal original.

$$\% \text{ redução} = \frac{1}{CR} * 100\% \quad (11)$$

## 5.2 OTIMIZAÇÃO DE LIMIAR

Os problemas de thresholding apresentados podem ser solucionados caso conheça-se uma função que descreve o valor ótimo do limiar ao longo de cada nível, no entanto, tal função não pode ser facilmente definida, já que depende das condições de contorno do método (família wavelet, número de camadas e característica do sinal). Outra possível solução envolve buscar o valor ótimo do limiar para os coeficientes por meio da utilização de algoritmos de otimização.

Segundo VANDERPLAATS (1999), um problema de otimização é definido como um problema onde busca-se encontrar a melhor solução dentre todas as soluções aplicáveis. Dentre as várias metodologias de otimização disponíveis, para o problema tratado neste trabalho, escolheu-se otimização por Evolução Diferencial (DE).

O algoritmo de Evolução Diferencial é um algoritmo heurístico baseado em população, onde é realizada uma distribuição populacional inicial, a partir da qual é buscada a solução ótima por meio de iterações que combinam as melhores características encontradas nas iterações entre os indivíduos da população. Uma das grandes vantagens é que não é necessário avaliação do gradiente, em consequência, a função não precisa ser diferenciável.

Alguns dos trabalhos apresentados no Capítulo 3 utilizaram algoritmos iterativos, no entanto, aqueles eram baseados em GA (*Genetic Optimization Algorithm*). Uma das vantagens de DE em relação à GA é a velocidade de otimização do modelo e os

resultados obtidos, que tendem a ser melhores a depender do problema, como mostrou CHARALAMPAKIS, TSIATAS (2019) para problemas de análise estrutural.

A metodologia de otimização proposta possui 2 objetivos, buscados por meio da busca do valor ótimo em todas as variáveis de limiar:

1. Maximizar o CR (*Compression Rate*)
2. Minimizar o MSE (*Mean Squared Error*)

Na função objetivo, os indivíduos da população são avaliados, por meio de um módulo de *thresholding* e reconstrução. Os resultados de CR e MSE para o indivíduo são calculados e a partir daí é calculado o valor de *fitness* utilizando a metodologia de Compromised Programming, que é proposta por VANDERPLAATS (1999), de modo a sintetizar o problema multi-objetivo para otimização mono-objetivo.

A função de Compromised Programming baseada em VANDERPLAATS é:

$$F(X) = \left\{ \sum_{k=1}^K \left[ \frac{W_k \{F_k(X) - F_k^*(X)\}}{F_k^{worst}(X) - F_k^*(X)} \right]^2 \right\}^{\frac{1}{2}} \quad (12)$$

Onde:

- $W_k$  é o fator de peso do objetivo  $k$ ;
- $F_k(X)$  é a  $k$ -ésima função objetivo atual;
- $F_k^*(X)$  é a  $k$ -ésima função objetivo alvo;
- $F_k^{worst}(X)$  é o pior valor conhecido para a  $k$ -ésima função objetivo.

Dessa forma, para minimizar MSE ( $k = 1$ ) e maximizar CR ( $k = 2$ ), foi proposto:

$$F(X) = \left\{ \left[ \frac{0.9 \{MSE_k(X) - 0\}}{0.99 - 0} \right]^2 + \left[ \frac{0.1 \{CR(X) - 7\}}{1 - 7} \right]^2 \right\}^{\frac{1}{2}} \quad (13)$$

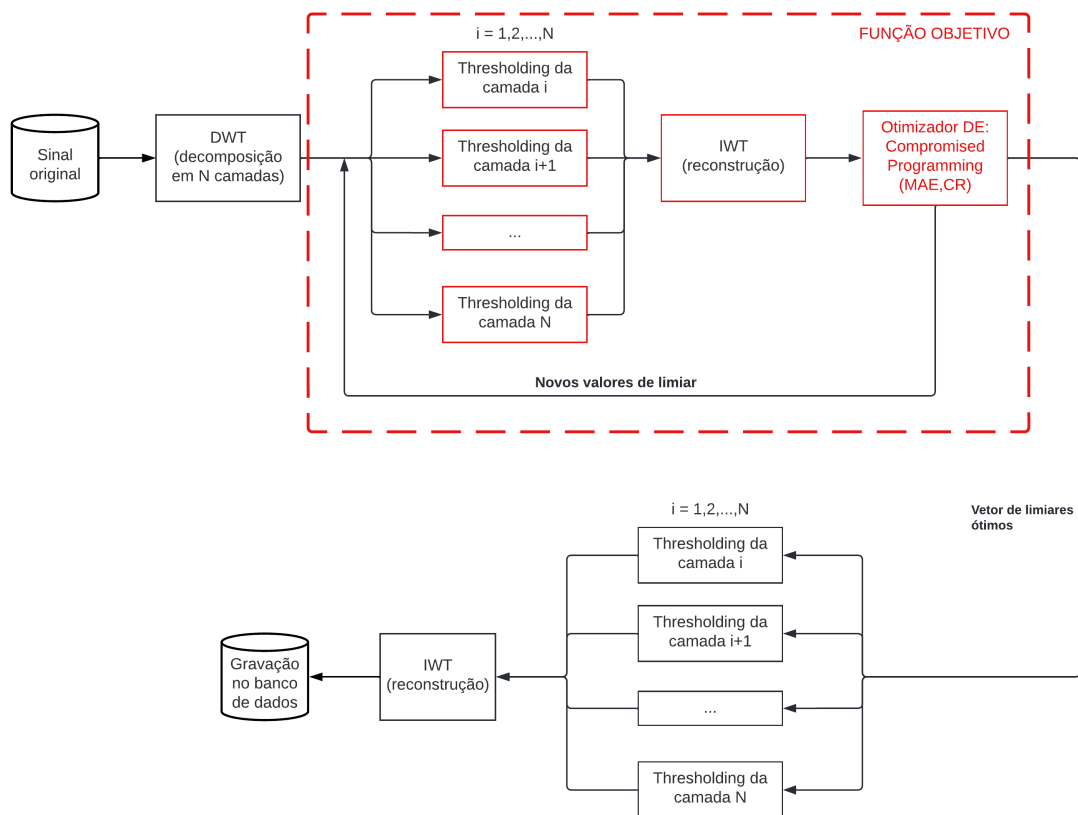
Foi dada ênfase à preservação do sinal como original após reconstrução, ou seja (obtenção de um baixo MSE), para que o conteúdo do sinal comprimido possa ser futuramente acessado, analisado, e não haja perda de informação espectral ou informação fantasma (previamente inexistente), que possam vir a descaracterizar o correto julgamento das características do sinal.

Os métodos de cálculos de MSE e CR continuam os mesmos, porém o processo de gravação de sinal ocorre duas vezes: a primeira é para avaliação iterativa da função objetivo por meio de um arquivo temporário. A segunda é o sinal comprimido obtido com coeficientes ótimos que será armazenado no conjunto de dados.

Vale ressaltar que, devido à otimização de característica multi-objetivo, a solução ótima não é única e depende dos valores fornecidos para a função de Compromised Programming.

A metodologia completa foi implementada segundo a Figura 23, sendo acoplada à metodologia proposta no subcapítulo 5.1.

Figura 23 – Metodologia de compressão acoplada ao otimizador diferencial (em vermelho)



Fonte: Autoria Própria

Para obtenção dos resultados, o tempo de execução da otimização também foi avaliado. O tempo de execução da metodologia completa pode variar em virtude das especificações do computador, já que o método proposto necessita de ler os *bits* dos arquivos original e comprimido, e dessa forma, o algoritmo de otimização funciona de forma a sobrescrever (processo de gravação) e avaliar (processo de leitura) continuamente dados no disco rígido.

Todos os algoritmos foram implementados em Python e a otimização foi executada em um computador com as seguintes especificações:

- **Processador:** 6 núcleos físicos, 12 núcleos virtuais, 3.6 MHz
- **Memória RAM:** 2x8 Gb, 3200 MHz
- **Disco Rígido:** SSD SATA 1Tb, aprox. 450 Mb/s de escrita, aprox. 520 Mb/s de leitura

## 6 RESULTADOS E DISCUSSÃO

Para discussão dos resultados, os sinais de 2 máquinas rotativas foram amostrados:

- **Rotor em Mancais Magnético:** Arquivo com 49 segundos de sinal amostrado,  $F_s = 10000$  Hz, 1 canal. Possui 3829 KB de espaço ocupado em disco;
- **Exaustor industrial:** Arquivo com 100 segundos de sinal amostrado,  $F_s = 20480$  Hz, 1 canal. Possui 16001 KB de espaço ocupado em disco;


Os sinais foram avaliados segundo a lógica implementada na Seção 5. Uma comparação entre a metodologia de compressão sem otimizador (utilizando como limiar apenas uma porcentagem dos coeficientes mais relevantes) e a metodologia de compressão com otimizador será realizada.

### 6.1 ROTOR EM MANCAL MAGNÉTICO COM ADIÇÃO DE IMPACTOS

Este sinal descreve uma máquina rotativa baseada em um rotor de bancada, sustentado por mancais magnéticos, que atua com velocidade controlada. Ao longo do perfil do sinal avaliado, foram inseridos impactos como anomalias, além de um perfil de rotação com vários patamares de rotação crescente e decrescente.


As famílias wavelet não foram otimizadas por limitação computacional relativa ao número de variáveis do algoritmo de computação. Por isso, realizou-se um estudo de qual ordem do grupo de wavelets *Daubechies* que deveria ser considerada. Para isso, avaliou-se  $\frac{CR}{MSE}$  para definir a ordem cuja razão resulta no maior valor. Por meio das Figuras 24 e 25, pôde-se escolher a família 'db1' para o método de compressão.

Figura 24 – CR (*Compression Rate*) das ordens das wavelets *Daubechies*



Fonte: Autoria Própria


Figura 25 – Avaliação da melhor ordem para as wavelets *Daubechies* por razão entre CR e MSE (quanto maior, melhor)



Fonte: Autoria Própria


Foi realizada a avaliação da compressão do sinal **sem otimizador integrado aos thresholds (limiares)**. As Figuras 26 e 27 trazem o resultado da compressão para diversos valores de  $\Gamma_i$  fixo (0.05, 0.10, 0.15 e 0.20), com método de thresholding definido de acordo com a Equação (6).

Figura 26 – Avaliação do sinal temporal após compressão, para  $\Gamma_i = 0.05$ ,  $\Gamma_i = 0.10$ ,  $\Gamma_i = 0.15$  e  $\Gamma_i = 0.20$ . Em preto: sinal original; em vermelho: sinal reconstruído



Fonte: Autoria Própria

Figura 27 – Avaliação da performance de compressão do sinal, para  $\Gamma_i = 0.05$ ,  $\Gamma_i = 0.10$ ,  $\Gamma_i = 0.15$  e  $\Gamma_i = 0.20$ .



Fonte: Autoria Própria

Pelas Figuras 26 e 27 é possível notar a sensibilidade do modelo à escolha de  $\Gamma_i$ .

Para valores a partir de  $\Gamma_i = 0.20$ , nota-se que praticamente todo o sinal é eliminado, restando apenas os picos resultantes de impacto na máquina. É possível notar, também, a evolução do erro MSE e do fator de compressão CR do sinal, ainda que o sinal tenha se tornado pouco representativo.

Em seguida, realizou-se a compressão baseada em **otimização de limiares** do sinal apresentado. A Tabela 1 apresenta as configurações de otimização utilizadas, enquanto a Tabela 2 apresenta os resultados finais da compressão. As figuras 28 e 29 apresentam o sinal original versus sinal reconstruído, em tempo e espectro, respectivamente. Já as figuras 30 e 31 representam as mesmas informações temporal e espectral, respectivamente, mas com detalhamento maior de duas condições diferentes da máquina rotativa: entre 4 e 7 segundos, representando 5 impactos consecutivos, e entre 20 e 25 segundos, representando um perfil de mudança de rotação.

Tabela 1 – Configurações do processo de compressão: sinal de rotor em mancal magnético

Variável	Valor
Função Objetivo	Minimizar $F(X)$ de acordo com a Equação (13)
Níveis Wavelet	5
Família Wavelet	<i>db1</i>
Variáveis de otimização	Limiares $\Gamma_{CD1}, \Gamma_{CD2}, \Gamma_{CD3}, \Gamma_{CD4}, \Gamma_{CD5}, \Gamma_{CA5}$ (6 variáveis)
Limites laterais	Entre 0 e 1 para cada variável de otimização
População	3 vezes o número de variáveis de otimização
Estratégia	DE/best/1/bin
Distribuição inicial da população	Latin Hypercube

Fonte: Autoria Própria


Tabela 2 – Resultados do processo de compressão: sinal de rotor em mancal magnético

Variável	Valor
Tamanho do sinal original [MB]	3.83
Tamanho do sinal comprimido [MB]	0.23
CR	16.13
MSE	$6.24 \cdot 10^{-6}$
Redução [%]	93.8
Tempo de otimização [seg]	7.73
Tempo total [seg]	7.81

Fonte: Autoria Própria




Figura 28 – Comparação entre o sinal original (preto) e sinal comprimido (vermelho). Por conta da semelhança nos perfis, plotou-se duas sobreposições diferentes do mesmo gráfico: vermelho/preto e preto/vermelho para facilitar encontrar as diferenças entre ambos os sinais



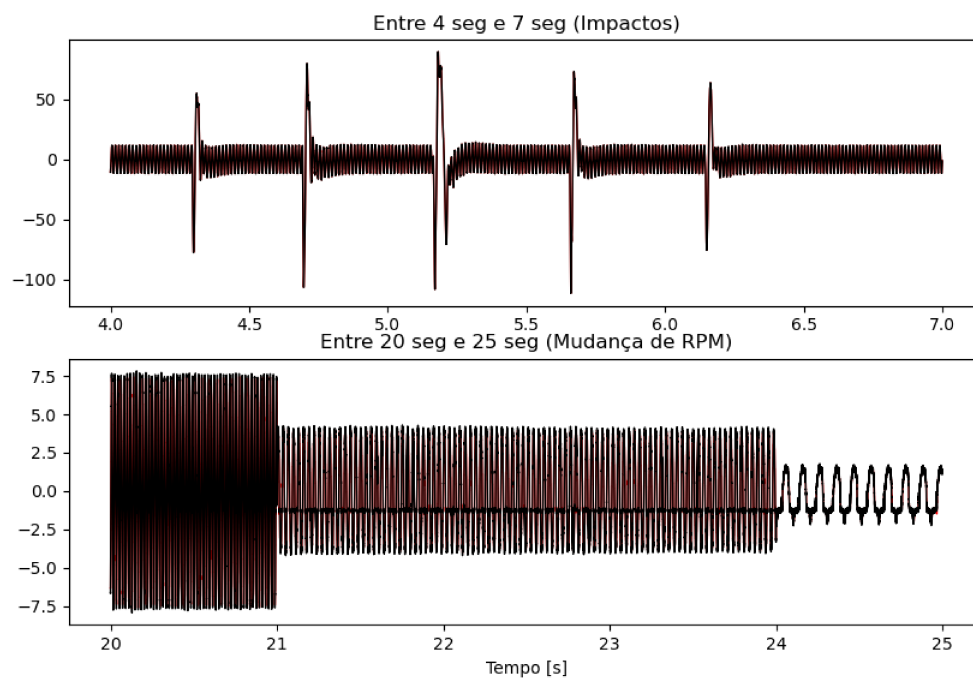
Fonte: Autoria Própria

Figura 29 – Comparação do espectro de frequências (FFT) entre o sinal original (preto) e sinal comprimido (vermelho). Por conta da semelhança nos perfis, plotou-se duas sobreposições diferentes do mesmo gráfico: vermelho/preto e preto/vermelho para facilitar encontrar as diferenças entre ambos os sinais




Fonte: Autoria Própria

Figura 30 – Comparação entre o sinal original (preto) e sinal comprimido (vermelho) em dois instantes diferentes: Entre 4 e 7 seg, representando impactos; e entre 20 e 25 seg, representando mudança de rotação.




Fonte: Autoria Própria

Figura 31 – Comparação do espectro de frequências (FFT) entre o sinal original (preto) e sinal comprimido (vermelho) em dois instantes diferentes: Entre 4 e 7 seg, representando impactos; e entre 20 e 25 seg, representando mudança de rotação.



Fonte: Autoria Própria

Figura 32 – Variação de  $\Gamma$  ao longo de cada um dos coeficientes wavelet otimizados: sinal de rotor em mancal magnético ( $\Gamma_i = X_i \cdot \max(\text{coeff}_i)$ )



Fonte: Autoria Própria

A Figura 32 mostra a variação de  $\Gamma$  ao longo dos coeficientes otimizados, lembrando que esta variável é definida como proporção do limiar encontrado em relação ao

maior coeficiente do nível equivalente. É possível notar que a maior remoção de coeficientes ocorreu, portanto, nos níveis iniciais.

Pelos resultados, nota-se que o sinal comprimido é praticamente idêntico ao sinal original. Quanto ao conteúdo em frequência, ambos apresentam enormes semelhanças, e as componentes principais (aquelas de maior amplitude) são preservadas. As diferenças em frequência são ressaltadas ao expor os gráficos à escala logarítmica, quando é possível notar diferenças de 1 ordem entre ambos, em algumas componentes em alta frequência., que é explicado pela priorização de um maior *thresholding* nos coeficientes passa-alta de níveis iniciais (responsáveis pelas maiores frequências). O  $CD_1$ , por exemplo, foi o afetado com maior proporção de *threshold*, e é responsável pela banda acima de 2500 Hz.


O MSE alcançado via otimização foi 17.4 vezes menor que quaisquer um dos valores mostrados na Figura 27, além do CR, que foi 80% maior. Por outro lado, o tempo de otimização foi significativamente alto para a otimização em apenas um canal, provavelmente inviabilizando a compressão de sinais simultaneamente ao funcionamento da máquina, principalmente se tratando de compressão de dados de acelerômetros triaxiais.

## 6.2 EXAUSTOR INDUSTRIAL

Este sinal descreve um exaustor industrial operando em condição estabilizada e regime permanente.

Primeiramente, foi realizada a avaliação da compressão do sinal **sem o otimizador integrado aos *thresholds* (limiares)**. A Figura 33 traz o resultado da compressão para diversos valores de  $\Gamma_i$ , com método de *thresholding* definido de acordo com a Equação (6).

Figura 33 – Avaliação da performance de compressão do sinal, para  $\Gamma_i = 0.05$ ,  $\Gamma_i = 0.10$ ,  $\Gamma_i = 0.15$  e  $\Gamma_i = 0.20$ .



Fonte: Autoria Própria

Em seguida, realizou-se a compressão baseada em otimização de limiares do sinal apresentado. Desta vez, buscou-se aumentar o número de variáveis de otimização, para buscar-se avaliar como o otimizador performaria, além disso, as variáveis de otimização

(limiares) foram definidos como a **proporções (constantes) que são multiplicadas pela média dos coeficientes em cada nível.**

A Tabela 3 apresenta as configurações de otimização utilizadas, enquanto a Tabela 4 apresenta os resultados finais da compressão.

Tabela 3 – Configurações do processo de compressão: sinal de exaustor industrial

Variável	Valor
Função Objetivo	Minimizar $F(X)$ de acordo com a Equação (13)
Níveis Wavelet	5
Família Wavelet	<i>db1</i>
Variáveis de otimização	Proporção das médias dos coeficientes: $X_1 \cdot \overline{CD_1}$ , $X_2 \cdot \overline{CD_2}$ , $X_3 \cdot \overline{CD_3}$ , $X_4 \cdot \overline{CD_4}$ , $X_5 \cdot \overline{CD_5}$ , $X_6 \cdot \overline{CA_5}$ (6 variáveis)
Limites laterais	Entre 0 e 30% da média dos coeficientes, por variável
População	7 vezes o número de variáveis de otimização
Estratégia	DE/best/1/bin
Distribuição inicial da população	Latin Hypercube


Fonte: Autoria Própria

Tabela 4 – Resultados do processo de compressão: sinal de exaustor industrial

Variável	Valor
Tamanho do sinal original [MB]	16.0
Tamanho do sinal comprimido [MB]	3.2
CR	5.07
MSE	$1.17 \cdot 10^{-8}$
Redução [%]	80.3
Tempo de otimização [seg]	149.1
Tempo total [seg]	149.5


Fonte: Autoria Própria

Figura 34 – Comparação entre o sinal original (preto) e sinal comprimido (vermelho). Por conta da semelhança nos perfis, plotou-se duas sobreposições diferentes do mesmo gráfico: vermelho/preto e preto/vermelho para facilitar encontrar as diferenças entre ambos os sinais




Fonte: Autoria Própria

Figura 35 – Comparação do espectro de frequências (FFT) entre o sinal original (preto) e sinal comprimido (vermelho). Por conta da semelhança nos perfis, plotou-se duas sobreposições diferentes do mesmo gráfico: vermelho/preto e preto/vermelho para facilitar encontrar as diferenças entre ambos os sinais



Fonte: Autoria Própria

Figura 36 – Variação de  $\Gamma$  ao longo de cada um dos coeficientes wavelet otimizados: sinal de exaustor industrial ( $\Gamma_i = X_i \cdot \max(\text{coeff}_i)$ )



Fonte: Autoria Própria



Devido à ordem de magnitude e variação de  $\Gamma$ , plotou-se o gráfico da Figura 36 em escala logarítmica no eixo Y. É possível notar, pelo gráfico que, ao contrário dos valores de  $\Gamma$  obtidos na compressão performada em 6.1, segundo a Figura 32, a variação de  $\Gamma$  descreveu um formato crescente para a compressão performada neste capítulo, além de encontrar resultados ótimos para valores mais baixos de  $\Gamma$ .

A diferença no perfil de variação de  $\Gamma$  ao longo dos coeficientes, e a diferença na magnitude do *thresholding* para cada sinal, enfatizam a necessidade de um método de quantização baseado em otimização, já que os valores de limiares que obtêm os melhores resultados de compressão variam de acordo com muitas características do sinal, como família e ordem wavelet escolhidas, número de níveis de decomposição,  $F_s$ , e várias outras características do sinal.

Analisando as Figuras 34 e 35, percebe-se que o sinal final obtido é visualmente igual ao sinal original, com erro sendo proveniente de diferenças de ordens as quais não se é possível notar a olho nu. Comparando aos resultados da Seção 6.1, o CR alcançado via otimização foi menor, mas vale lembrar que as wavelets performam melhor em sinais com características transientes ou variacionais. Estas características estiveram presentes no sinal proveniente do rotor com mancal magnético, enquanto para o exaustor, a característica do sinal descreve a máquina em regime permanente. Além disso, o exaustor apresenta excitações em diversas frequências, enquanto o rotor magnético encontra energia concentrada somente nos harmônicos da frequência fundamental de rotação, dificultando um *thresholding* mais severo do exaustor em detrimento de um baixo erro de quantização.

O tempo de otimização é considerado relativamente elevado, com a otimização levando 50% mais tempo para ser performada que o próprio tempo de amostragem do sinal original - 100 seg. Isso significa que o modelo, como implementado e de acordo com as configurações mostradas, pode não ser adequado à compressão de numerosos conjuntos de sinais, principalmente conjuntos que armazenam sinais via monitoramento contínuo. Para estes casos, recomenda-se utilizar um baixo valor de  $\Gamma$  (entre  $1 \cdot 10^{-5}$  e  $1 \cdot 10^{-3}$ ) via **compressão sem otimização**, visando garantir algum nível de compressão (CR's de ordem 2 a 7), baixo erro e um curto tempo de execução do método de compactação, já que este é executado com elevada velocidade na ausência do otimizador.

## 7 CONCLUSÃO

O presente trabalho desenvolveu um método de compressão de sinais baseado em *wavelet*. Além disso, foi proposta uma metodologia de otimização com base em DE (*Differential Evolution*) para encontrar os valores ótimos de limiar (*threshold*) para a etapa de quantização do método de compressão, visando obter os valores que minimizem o MSE enquanto maximiza-se o CR.

Os resultados obtidos demonstraram que o método é capaz de comprimir os sinais com reduções da ordem de 90%, e ainda manter todas as informações espectrais, com valores de MSE na ordem de  $1 \cdot 10^{-7}$ . Entretanto, tais qualidades vêm às custas de tempo de otimização, que é significativamente elevado, podendo vir a ser maior que até mesmo o tempo de amostragem do sinal a ser comprimido.

Para trabalhos futuros, sugere-se que o modelo de otimização baseado em DE seja substituído por um método de otimização direto, como por exemplo, LBFSGS (*Limited Broyden-Fletcher-Goldfarb-Shanno*), *Basin-Hopping* ou ainda *Cobylya*. Sugere-se também que a verificação de CR pela função objetivo do otimizador seja feita dentro do ambiente das variáveis do script implementado, e não dependa dos processos de gravação e leitura em disco, processo este que pode levar à limitações de velocidade de otimização devido ao fluxo de dados gravados e lidos no disco rígido, a depender das especificações do computador onde é performada a compressão. Outro ponto negativo do método de verificação citado é que este impede que a otimização via DE realize processamento paralelo para aumentar a velocidade de otimização.

## REFERÊNCIAS

CHARALAMPAKIS, A. E.; TSIATAS, G. C. **Critical Evaluation of Metaheuristic Algorithms for Weight Minimization of Truss Structures**. Greece: Frontiers in Built Environment: Computational Methods in Structural Engineering, 2019. Disponível em: <https://doi.org/10.3389/fbuil.2019.00113>.

DAUBECHIES, Ingrid. **Ten lectures on wavelets**. Philadelphia, EUA: Society for Industrial Application of Mathematics, 1992. Disponível em: <https://doi.org/10.1137/1.9781611970104>.

EXAME. **A disrupção está mudando o mundo como o conhecemos**. São Paulo: Exame, 2020. Disponível em: <https://exame.com/revista-exame/a-disrupcao-esta-mudando-o-mundo-como-o-conhecemos/>. Acesso em: 1 jul. 2022.

GABOR, D. **Theory of Communication**. [S.l.]: Journal of the Institution of Electrical Engineers Part III, Radio and Communication, vol 93, 1946. P. 429. Disponível em: <https://doi.org/10.1049/ji-3-2.1946.0074>.

IDC - INTERNATIONAL DATA CORPORATION. **Worldwide Global Storage Sphere Forecast, 2021–2025: To Save or Not to Save Data, That Is the Question**. Boston, EUA, 2021.

KHALIFA, O. O.; HARDING, S. H.; ABDALLA HASHIM, A.-H. **Compression using wavelet transform**. [S.l.]: International Journal of Signal Processing, vol. 2, no. 5, 2008. 17–26.

MANO, Cristiane. **Indústria 4.0 e o futuro da Manutenção Preditiva**. Florianópolis: Dynamox, 2017. Disponível em: <https://dynamox.net/blog/industria-40-e-o-futuro-da-manutencao-preditiva>. Acesso em: 1 jul. 2022.

MASATOSHI, Makoto Tanaka; KATO, Sakawa Kosuke; ABE, Michiharu. **Application of wavelet transform to compression of mechanical vibration data**. Hiroshima, Japão: Cybernetics e Systems: An International Journal, 1997. 225–244. Disponível em: <https://doi.org/10.1080/019697297126164>.

MATLAB. **Continuous Wavelet Transform and Scale-Based Analysis**. [S.l.]: MathWorks Help Center. Disponível em:

<https://www.mathworks.com/help/wavelet/gs/continuous-wavelet-transform-and-scale-based-analysis.html>. Acesso em: 31 jul. 2022.

NIELSEN, M.; KAMAVUAKO, N.; ANDERSON, M.M.; LUCAS, M. **Biomedical signal compression with optimized wavelets**. 2006 IEEE International Conference: InAcoustics, Speech and Signal Processing (ICASSP), 2006. 1044–1047.

NIELSEN, M.; NLANDU, E.; ANDERSON, M.M.; FARINA, D. **Optimal wavelets for biomedical signal compression**. [*S.l.*]: Medical & Biological Engineering & Computing, 2006. 561–568.

OSADCHIY, Andrey; KAMENEV, Aleksandr; SAHAROV, Vladimir; CHERNYI, Sergei. **Signal Processing Algorithm Based on Discrete Wavelet Transform**. [*S.l.*]: MDPI Designs 2021 5, 41, 2021. Disponível em: <https://doi.org/10.3390/designs5030041>.

PENG, Z.K.; CHU, F.L. **Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography**. Beijing, China: Mechanical Systems and Signal Processing 18, 1999. Disponível em: [https://doi.org/10.1016/S0888-3270\(03\)00075-X](https://doi.org/10.1016/S0888-3270(03)00075-X).

ROMANO, Nella; SCIVOLETTO, Antony; POLAP, Dawid. **A Real-Time Audio Compression Technique Based on Fast Wavelet Filtering and Encoding**. Proceedings of the 2016: Federated Conference on Computer Science and Information Systems, 2016. 497–502. Disponível em: <https://doi.org/10.15439/2016F296>.

STASZEWSKI, Wieslaw Jerzy. **Vibration data compression with optimal wavelet coefficients**. Sheffield, Reino Unido: Second International Conference on Genetic Algorithms in Engineering Systems, 1997. 186–190. Disponível em: <https://doi.org/10.1049/cp:19971178>.

STASZEWSKI, Wieslaw Jerzy. **Wavelet based compression and feature selection for vibration analysis**. Sheffield, Reino Unido: Journal of Sound e Vibration, 1998. 735–760. Disponível em: <https://doi.org/10.1006/jsvi.1997.1380>.

UTHAYAKUMAR, J.; VENGATTARAMAN, T.; DHAVACHELVAN, P. **A survey on data compression techniques: From the perspective of data quality, coding schemes, data type and applications**. Arábia Saudita: Journal of King Saud University - Computer and Information Sciences, 2018. Disponível em: <https://doi.org/10.1016/j.jksuci.2018.05.006>.

VANDERPLAATS, Garret N. **Numerical optimization techniques for engineering design**, 3<sup>a</sup> ed. [S.l.]: Vanderplaats Research and Devepment, Inc., 1999.

WU, Tsung-Ching; HUNG, King-Chu; LIU, Je-Hung; LIU, Tung-Kuan. **Wavelet-based ECG data compression optimization with genetic algorithm**. [S.l.]: Journal of Biomedical Science e Engineering, 2013. 746–753. Disponível em: <https://doi.org/10.4236/jbise.2013.67092>.

ZONTA, Tiago; COSTA, Cristiano André da; ROSA RIGHI, Rodrigo da; LIMA, Miromar José de; TRINDADE, Eduardo Silveira da; LI, Guann Pyng. **Predictive maintenance in the Industry 4.0: A systematic literature review**. [S.l.]: Computers & Industrial Engineering 150, 2020. Disponível em: <https://doi.org/10.1016/j.cie.2020.106889>.