

UNIVERSIDADE FEDERAL DA BAHIA  
ESCOLA POLITÉCNICA  
*DEPARTAMENTO DE ENGENHARIA ELÉTRICA*  
*PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA*  
*ELÉTRICA*

DISSERTAÇÃO DE MESTRADO

**Avaliação da Influência do Ruído Ambiente em Sistema  
Sonar Passivo utilizando Análise de Componentes  
Independentes**

**Autor:** Raphael Melo de Amorim

**Orientador:** Marcela Silva Novo, Dr.

**Coorientador:** Eduardo Furtado de Simas Filho, Dr.

Salvador-BA

14 de dezembro de 2016

Modelo de ficha catalográfica fornecido pelo Sistema Universitário de Bibliotecas da UFBA para ser confeccionada pelo autor

AM523 Melo de Amorim, Raphael  
Avaliação da Influência do Ruído Ambiente em Sistema Sonar Passivo utilizando Análise de Componentes Independentes / Raphael Melo de Amorim. -- Salvador, 2016.  
99 f. : il

Orientadora: Marcela Silva Novo.  
Coorientador: Eduardo Furtado de Simas Filho.  
Dissertação (Mestrado - Programa de Pós Graduação em Engenharia Elétrica) -- Universidade Federal da Bahia, Escola Politécnica, 2016.

1. Sistema de Sonar Passivo. 2. Separação Cega de Fontes. 3. Análise de Componentes Independentes. 4. Ruído Ambiente Marinho. I. Silva Novo, Marcela. II. Furtado de Simas Filho, Eduardo. III. Título.

**Avaliação da Influência do Ruído Ambiente em Sistema  
Sonar Passivo utilizando Análise de Componentes  
Independentes**

Raphael Melo de Amorim

Dissertação de Mestrado submetida ao Colegiado do Programa de  
Pós-Graduação em Engenharia Elétrica da Universidade Federal da  
Bahia como parte dos requisitos necessários para obtenção do Título  
de MESTRE EM ENGENHARIA ELÉTRICA.

Examinada por:



Prof. Marcela Silva Novo, D.Sc. (UFBA)



Prof. Eduardo Furtado de Simas Filho, D.Sc. (UFBA)



Prof. Antônio Cezar de Castro Lima, Ph.D. (UFBA)



Prof. Antônio Carlos Lopes Fernandes Júnior, D.Sc. (UFBA)



Prof. Edgar Silva Júnior, D.Sc. (UEFS)

Salvador-BA

14 de dezembro de 2016

# Agradecimentos

Agradeço aos professores Marcela Novo e Eduardo Simas pela orientação e dedicação para o desenvolvimento do trabalho. Aos amigos do Programa de Graduação em Engenharia Elétrica - UFBA pelo apoio. Ao Instituto de Pesquisas da Marinha (IPqM) pela parceria que permitiu a realização deste trabalho. Aos meus familiares que me incentivaram em todas as etapas de construção deste trabalho. Sobretudo à Deus.

Resumo da Dissertação apresentada à PPGEE/UFBA como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

AVALIAÇÃO DA INFLUÊNCIA DO RUÍDO AMBIENTE EM SISTEMA  
SONAR PASSIVO UTILIZANDO ANÁLISE DE COMPONENTES  
INDEPENDENTES

Raphael Melo de Amorim

Dezembro 2016

Orientadores: Marcela Silva Novo, D.Sc.

Eduardo Furtado de Simas Filho, D.Sc.

Programa: Engenharia Elétrica

A tecnologia e as estratégias aplicadas nas operações de submarinos vêm sendo cada vez mais estudadas pela comunidade científica ao longo das últimas décadas. Para detectar e identificar alvos desconhecidos, o submarino é equipado com sistemas de sonar passivo que captam ondas sonoras propagadas no meio ambiente marinho. Esses sistemas encontram dificuldades em identificar múltiplos alvos próximos e também quando o ruído ambiente é elevado. Por isso, é necessário o uso de *softwares* e *hardwares* sofisticados para identificação e classificação. O problema da identificação de múltiplos alvos já foi abordado previamente na literatura através do uso da separação cega de fontes. Este método é capaz de reduzir o efeito da interferência cruzada nos hidrofones adjacentes. No entanto, é conhecido que o desempenho de métodos de separação cega é severamente influenciado pelo ruído aditivo do meio ambiente. Este trabalho testa a robustez de um método de separação cega de fontes, a análise de componentes independentes (ICA - *Independent Component Analysis*), aplicado em sistemas de sonar passivo para reduzir a interferência do ruído ambiente. O algoritmos JADE, FastICA e GI-ICA foram utilizados para avaliação do desempenho de separação de sinais considerando diferentes valores da relação sinal-ruído.

Abstract of Dissertation presented to PPGEE/UFBA as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

EVALUATION OF AMBIENT NOISE INFLUENCY ON PASSIVE SONAR  
SYSTEM USING INDEPENDENT COMPONENT ANALYSIS

Raphael Melo de Amorim

December 2016

Advisors: Marcela Silva Novo, D.Sc.

Eduardo Furtado de Simas Filho, D.Sc.

Department: Electrical Engineering

The technology and the strategies applied in submarine operations have been increasingly studied by the scientific community over the last decades. To detect and identify unknown targets, the submarine is equipped with passive sonar systems that capture sound waves propagated in the marine environment. These systems have difficulty to identify multiple nearby targets and also when the ambient noise is significative. Therefore it's necessary the use of sophisticated softwares and hardwares for identification and classification. The problem of multiple target identification has been previously discussed in the literature through the use of Blind Signal Separation. This method is capable of eliminating interference between adjacent hydrophones. However, it is known that the performance of blind separation methods is severely affected by noise environment. This paper tests the robustness of a blind signal separation method, the independent component analysis (ICA), when it is applied in passive sonars to reduce interference from ambient noise. ICA algorithms JADE, FastICA and GI-ICA were used to evaluate the signal separation performance considering different values of signal-to-noise ratio.

# Sumário

<b>Lista de Figuras</b>	<b>v</b>
<b>Lista de Tabelas</b>	<b>ix</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Motivação . . . . .	3
1.2 Objetivos da Dissertação . . . . .	4
1.3 Metodologia . . . . .	4
1.4 Organização do Trabalho . . . . .	6
<b>2 Ambiente Acústico Marinho</b>	<b>7</b>
2.1 Onda sonora . . . . .	8
2.2 Ruído Acústico no Ambiente Marinho . . . . .	10
2.2.1 Ruídos Sísmicos . . . . .	11
2.2.2 Turbulência dos Oceanos . . . . .	12
2.2.3 Ruído de Embarcações . . . . .	12
2.2.4 Ruído das Ondas marítimas . . . . .	12
2.2.5 Ruído Térmico . . . . .	13
2.3 Modelos Matemáticos dos Ruídos . . . . .	13
2.3.1 Modelos de Análise do Ruído Ambiente . . . . .	13
2.3.2 Modelos Estatísticos de Ruído de Feixe . . . . .	14
<b>3 Sistema de Sonar Passivo</b>	<b>16</b>
3.1 Introdução . . . . .	16
3.2 Descrição do Sistema de Sonar Passivo . . . . .	17
3.3 Equação de um Sistema de Sonar Passivo . . . . .	21

3.4	Técnicas de Inteligência Computacional e Processamento Estatístico aplicadas a Sonar Passivo . . . . .	23
<b>4</b>	<b>Tratamento dos Dados</b>	<b>27</b>
4.1	Separação Cega de Fontes . . . . .	27
4.2	Análise de Componentes Independentes . . . . .	29
4.2.1	Independência Estatística . . . . .	30
4.2.2	Pré-Processamento da ICA . . . . .	34
4.2.3	Algoritmo JADE . . . . .	35
4.2.4	Algoritmo FastICA . . . . .	36
4.3	ICA com Ruído . . . . .	38
4.3.1	Estimação da Matriz de Misturas . . . . .	39
4.3.2	Estimação dos Componentes Independentes Livres de Ruído .	42
4.3.3	Algoritmo GI-ICA . . . . .	42
<b>5</b>	<b>Metodologia de Análise</b>	<b>44</b>
5.1	Base de Dados . . . . .	44
5.2	Metodologia . . . . .	46
5.2.1	Simulação do Ruído Ambiente . . . . .	47
5.2.2	Métricas de desempenho . . . . .	48
<b>6</b>	<b>Resultados</b>	<b>49</b>
6.1	Resultados da Análise . . . . .	49
6.1.1	Algoritmo JADE . . . . .	50
6.1.2	Algoritmo FastICA . . . . .	59
6.1.3	Algoritmo GI-ICA . . . . .	67
<b>7</b>	<b>Conclusões e Perspectivas</b>	<b>77</b>
	<b>Referências Bibliográficas</b>	<b>79</b>
<b>A</b>	<b>Publicações</b>	<b>86</b>
A.1	Artigos em Congressos . . . . .	86



# Lista de Figuras

1.1	Detecção de alvos por um submarino [1]. . . . .	2
1.2	Metodologia proposta para o trabalho. . . . .	5
2.1	Relação entre experimentos e modelagem acústica [2]. . . . .	8
2.2	Espectro do ruído no oceano profundo . . . . .	11
2.3	Espectro do ruído no oceano profundo . . . . .	11
2.4	Campo de ruído usado no modelo RANDI . . . . .	14
3.1	Tipos de sistemas de sonar passivo [1]. . . . .	17
3.2	Diagrama de bloco do sistema de sonar passivo [3]. . . . .	18
3.3	Análise de banda larga de um sonar passivo em feixe $\times$ tempo [3]. . .	19
3.4	Análise de banda larga de um sonar passivo em frequência $\times$ tempo [1].	19
3.5	Análise de banda estreita de um sonar passivo em frequência $\times$ tempo [3]. . . . .	20
3.6	Diagrama de blocos da análise LOFAR. . . . .	20
3.7	Diagrama de blocos da análise DEMON. . . . .	21
3.8	Análise DEMON [1]. . . . .	22
5.1	Cenário da simulação. . . . .	45
5.2	Análise DEMON do contato 1. . . . .	45
5.3	Análise DEMON do contato 2. . . . .	46
5.4	Diagrama de Blocos da metodologia de análise. . . . .	46
5.5	Padrão de ruído ambiente para modelagens acústicas e análises [4]. .	47
6.1	Espectro de Frequência da última janela temporal na marcação 1. . .	50
6.2	Espectro de Frequência da última janela temporal na marcação 2. . .	50
6.3	Espectro das marcações no domínio do tempo usando algoritmo JADE.	51

6.4	Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 0 dB. . . . .	52
6.5	Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 5 dB. . . . .	52
6.6	Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 10 dB. . . . .	53
6.7	Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 15 dB. . . . .	53
6.8	Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 20 dB. . . . .	54
6.9	Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 25 dB. . . . .	54
6.10	Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 30 dB. . . . .	55
6.11	Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 35 dB. . . . .	55
6.12	Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 40 dB. . . . .	56
6.13	Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 45 dB. . . . .	56
6.14	Relação sinal-interferência nas marcações e nos componentes do algoritmo JADE. . . . .	57
6.15	Relação sinal-ruído nas marcações e nos componentes do algoritmo JADE. . . . .	58
6.16	Espectro das marcações no domínio do tempo usando algoritmo FastICA. . . . .	60
6.17	Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 0 dB. . . . .	60
6.18	Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 5 dB. . . . .	61
6.19	Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 10 dB. . . . .	61

6.20	Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 15 dB. . . . .	62
6.21	Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 20 dB. . . . .	62
6.22	Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 25 dB. . . . .	63
6.23	Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 30 dB. . . . .	63
6.24	Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 35 dB. . . . .	64
6.25	Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 40 dB. . . . .	64
6.26	Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 45 dB. . . . .	65
6.27	Relação sinal-interferência nas marcações e nos componentes do algoritmo FastICA. . . . .	65
6.28	Relação sinal-ruído nas marcações e nos componentes do algoritmo FastICA. . . . .	67
6.29	Espectro das marcações no domínio do tempo usando algoritmo GI-ICA. . . . .	69
6.30	Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 0 dB. . . . .	69
6.31	Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 5 dB. . . . .	70
6.32	Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 10 dB. . . . .	70
6.33	Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 15 dB. . . . .	71
6.34	Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 20 dB. . . . .	71
6.35	Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 25 dB. . . . .	72

6.36	Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 30 dB. . . . .	72
6.37	Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 35 dB. . . . .	73
6.38	Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 40 dB. . . . .	73
6.39	Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 45 dB. . . . .	74
6.40	Relação sinal-interferência nas marcações e nos componentes do algoritmo GI-ICA. . . . .	75
6.41	Relação sinal-ruído nas marcações e nos componentes do algoritmo GI-ICA. . . . .	76

# Lista de Tabelas

6.1	Tabela dos valores das marcações e dos componentes do algoritmo JADE para relação sinal-interferência. . . . .	58
6.2	Tabela dos valores das marcações e dos componentes do algoritmo JADE para relação sinal-ruído. . . . .	59
6.3	Tabela dos valores das marcações e dos componentes do algoritmo FastICA para relação sinal-interferência. . . . .	66
6.4	Tabela dos valores das marcações e dos componentes do algoritmo FastICA para relação sinal-ruído. . . . .	68
6.5	Tabela dos valores das marcações e dos componentes do algoritmo GI-ICA para relação sinal-interferência. . . . .	75
6.6	Tabela dos valores das marcações e dos componentes do algoritmo GI-ICA para relação sinal-ruído. . . . .	76

# Capítulo 1

## Introdução

Os estudos no setor naval tem se tornado cada vez mais evidentes na comunidade científica, com destaque para a área tecnológica [5–7]. Nesta área, várias pesquisas tem sido produzidas no âmbito da detecção e classificação de embarcações marítimas. Em relação aos navios de superfície, o sistema usado para tal pode ser o RADAR (***R**Adio **D**etection **A**nd **R**anging*) [8], composto por dispositivos que utilizam ondas eletromagnéticas, uma vez que a mesma possui uma atenuação muito baixa quando o canal de propagação é o ar. Entretanto, as embarcações submersas já não são detectadas facilmente com o radar pois a atenuação das ondas eletromagnéticas no mar é grande. Sendo assim, o melhor recurso disponível para esse objetivo é a utilização de ondas acústicas, já que elas se propagam no meio marítimo por longas distâncias com baixa atenuação na faixa de 20Hz a 60kHz [2]. A onda acústica propagada por uma embarcação na superfície pode ser usada para sua identificação e classificação por um submarino e as embarcações de superfícies também podem utilizá-las para localização de submarinos.

O sistema que utiliza ondas acústicas para detecção e classificação de sinais no meio aquático é conhecido como sistema de SONAR (***S**Ound **N**avigation **R**anging*) [9]. Existem dois tipos de sistemas de sonar, o ativo e o passivo. O sistema de sonar ativo transmite ondas acústicas no ambiente marinho por meio de hidrofones para depois captar a reflexão dessas ondas quando se encontram com um alvo e assim detectar e classificar navios ou submarinos. Já os sistemas de sonar passivo não emitem ondas acústicas, apenas captam elas no ambiente. O sistema ativo é geralmente utilizado por navios anti-submarinos e o passivo por submarinos, uma

vez que a localização dos navios é visível, ou seja, não tem como se esconder, então eles podem emitir ondas acústicas para localizar os submarinos com antecedência e por sua vez os submarinos precisam se camuflar dentro da água para não revelar sua localização pois são mais vulneráveis a qualquer dano causado em sua estrutura, utilizando assim o sonar passivo.

O fundo do mar é caracterizado por ser um ambiente acusticamente ruidoso, tornando-se objeto de estudo para o desenvolvimento de diversas técnicas de detecção e classificação de sinais a partir do sistema de sonar passivo [2, 4]. Por isso, sistemas de *hardware* e *software* sofisticados são constantemente empregados. Além do ambiente ruidoso, existe a interferência causada entre as embarcações marítimas, chamadas de contatos. Com isso, devem-se posicionar os hidrofones apropriadamente para que sejam capazes de captar os sinais dos contatos em todas as direções e assim possam ser classificados pelo operador sonar (OS) e pelos classificadores automáticos. A Figura 1.1 mostra o diagrama de um submarino detectando dois alvos, um outro submarino e um navio, a partir das ondas acústicas emitidas por eles.




Figura 1.1: Detecção de alvos por um submarino [1].

O processamento de sinais é um dos recursos mais importantes de apoio à detecção e classificação. Tradicionalmente a classificação é realizada pelo OS a partir da análise de áudio e de características no domínio da frequência, que são disponibilizadas em tempo real. Recentemente, técnicas avançadas de aprendizagem de máquina (*machine learning*) e processamento estatístico de sinais vêm sendo utili-

zadas para fornecer informação de suporte à decisão do OS. No entanto, as técnicas mais modernas de processamento podem apresentar dificuldades na detecção e classificação de um contato devido a alguns fatores: interferência entre contatos (alvos) e interferência do ruído ambiente.

Pesquisas recentes buscam melhorar o desempenho dos sistemas de detecção de sinais de sonar passivo com ênfase na melhoria da relação sinal-ruído e na atenuação da interferência entre os contatos [10–13]. Para isso, técnicas de processamento de sinais são extremamente necessárias. Dentre as técnicas mais utilizadas está a Análise de Componentes Independentes (ICA - *Independent Component Analysis*) que tem uma boa resposta na separação de sinais independentes, com base em cálculos estatísticos na sua análise.

## 1.1 Motivação

Os primeiros sistemas de sonar passivos foram utilizados na primeira guerra mundial e consistiam de um operador sonar escutando o ruído ambiente captado por um hidrofone. O operador sonar tinha que ser capaz de identificar os sinais de possíveis inimigos antes de ser identificado, uma tarefa extremamente importante executada por um sistema passível de muitas falhas. A partir disso, surgiu a necessidade de sofisticação nesse sistema de identificação de alvos. Foram desenvolvidas novas tecnologias de apoio aos operadores sonar partindo das pesquisas feitas a partir das análises de dados obtidas pelos primeiros sonares [1].

A estimação da direção de interesse DOA (*Direction Of Arrival*), a detecção e classificação são as principais funções inerentes à um sistema sonar passivo. Para se determinar a direção de interesse, ou seja, a direção de onde vem o sinal do alvo, utilizam-se algoritmos de conformação de feixes [14]. Para a identificação de contatos, normalmente são feitas duas análises espectrais de processamento do sinal: LOFAR e DEMON. A análise LOFAR (*Low Frequency Analysis and Recording*) faz uma leitura em toda banda de frequência do sinal. Esta análise identifica o ruído da maquinaria do alvo. Já a análise DEMON (*DEtection MODulation on Noise*) busca identificar a quantidade de eixos, a frequência de rotação dos eixos e o



número de pás do contato através da detecção da envoltória do ruído de cavitação<sup>1</sup>. Diferente da LOFAR, a DEMON é uma análise de banda estreita.

Os recursos que um sistema de sonar passivo apresenta podem não ser suficientes para uma detecção e identificação apurada pelo operador. Em situações onde é intenso o ruído ambiente causado por fenômenos naturais (animais marinhos, chuva, abalos sísmicos, corrente marinha, etc.) ou por equipamentos criados pelo homem (como uma usina petrolífera no mar por exemplo), podem ocorrer interferências relevantes na estimação da direção de chegada. Para que o operador sonar não tenha tanta dificuldade na detecção e classificação dos contatos, são utilizadas técnicas inteligentes no processamento dos sinais. Por isso, o estudo dessas técnicas é importante para investigar seu desempenho no sistema de sonar passivo.

## 1.2 Objetivos da Dissertação

O objetivo geral deste trabalho foi avaliar a influência do ruído ambiente em um sistema de sonar passivo que utiliza a análise de componentes independentes para a redução da interferência mútua em cenários de múltiplos contatos de interesse. Com isso, busca-se melhorar a relação sinal/interferência (SIR) e a relação sinal/ruído (SNR) do sistema sonar otimizando a detecção e classificação de contatos, o que facilita a identificação por parte do operador.

Desta forma teve-se como objetivos específicos:

- Estudar a influência do ruído ambiente no sistema sonar passivo;
- Simular o funcionamento do sistema sonar passivo com influência do ruído ambiente;
- Avaliar a influência do ruído na redução da interferência entre os contatos usando ICA;

## 1.3 Metodologia

Este trabalho segue a metodologia utilizada no trabalho [1], que consiste na utilização de algoritmos de separação cega de fontes como pré-processamento do sis-

---

<sup>1</sup>Vaporização do líquido devido à redução de pressão, durante seu movimento.




Figura 1.2: Metodologia proposta para o trabalho.

tema de sonar passivo com o objetivo de melhorar a detecção e classificação dos sinais. Além disso, será inserido junto ao sinal captado pelo sonar um outro sinal que simula a interferência que o ruído ambiente marinho causa no sistema de sonar passivo. A Figura 1.2 mostra o diagrama de blocos do pré-processamento feito pela separação cega de sinais no sonar passivo.

O sinal avaliado neste trabalho foi simulado e fornecido pela Marinha do Brasil. Consiste em dois navios em posições diferentes (marcações  $M_1$  e  $M_2$ ) se aproximando de um submarino. Para a avaliação da influência do ruído ambiente, o mesmo foi gerado a partir do ruído branco utilizando um filtro passa baixa com frequência de corte em 500 Hz, onde se encontram as frequências que mais interferem na identificação e classificação dos contatos uma vez que é a faixa de frequência de navegação. A partir da coleta dos dados, é feita uma análise espectral utilizando as análises DEMON e LOFAR. Em seguida, os algoritmos de separação cega de fontes são utilizados com o propósito de estimar os componentes de interesse para o Operador sonar, no caso os sinais dos contatos. Com isso, é verificado se houve alguma melhora na relação sinal/ruído entre os contatos que se encontram separadas. Para a avaliação da separação cega, serão utilizadas análises dos sinais no domínio do tempo, as relações de sinal - ruído e de sinal - interferência entre contatos.

A separação cega de sinais pode ser realizada com vários tipos de algoritmos entre os quais pode-se destacar a análise de componentes independentes [15], a análise de componentes esparsos [16], a fatoração de matrizes não negativas [17], etc. Neste trabalho, foram utilizados algoritmos para a separação usando análise de componentes independentes.

## 1.4 Organização do Trabalho

O presente capítulo apresenta uma breve introdução ao trabalho, destacando a motivação para o desenvolvimento do projeto, os objetivos a serem alcançados, além de uma visão geral do trabalho. No segundo capítulo é abordado o ambiente acústico marinho, apresentando como as ondas acústicas se comportam nesse meio. O terceiro capítulo apresenta o sistema sonar passivo, destacando aspectos relacionados ao seu funcionamento. O quarto capítulo aborda o método de separação cega de fontes e os algoritmos da análise de componentes independentes utilizados neste trabalho. O quinto capítulo apresenta a base de dados utilizada bem como a metodologia de análise do trabalho. O sexto capítulo mostra os resultados encontrados com os algoritmos de análise de componentes independentes na remoção do ruído ambiente através da detecção e classificação dos contatos. O sétimo capítulo apresenta as conclusões e as perspectivas geradas a partir das análises realizadas.

# Capítulo 2

## Ambiente Acústico Marinho

Neste capítulo, são abordados os aspectos principais do ambiente acústico marinho, levantando os pontos principais para o estudo do ruído neste meio.

Durante as últimas décadas o ambiente acústico marinho tem sido extensamente estudado com o objetivo de atender à demanda da área sonar naval, comunicação subaquática [18, 19], navegação autônoma [20], comunidade marinha de sismologia [21, 22], etc. Trabalhos realizados desenvolveram modelos matemáticos de análise dos dados experimentais [23, 24].

A ciência que estuda a acústica marinha desenvolve modelos matemáticos a partir da coleta de informações no campo experimental. Esses modelos são utilizados para prever as condições acústicas em um experimento de campo com o objetivo de otimizar o desempenho do sistema sonar [2]. No entanto, a transição entre esses estágios não é simples, pois as observações de modo direto são limitadas, o que pode resultar num modelo de predição imperfeito.

A modelagem é o principal mecanismo para que se possa simular o desempenho de um sonar em condições de laboratório sem que haja um enorme gasto de recursos com observações de campo. Além disso, ela fornece uma grande eficiência no desenvolvimento de sonares em diversos tipos de ambientes [2, 25, 26]. Já as medições experimentais geralmente são onerosas devido ao custo operacional dos equipamentos. Para se obter dados da acústica marinha é necessário um alto investimento, devido à utilização de navios, submarinos e em certos casos até aeronaves. Com isso, utiliza-se muito as medições de campo já existentes. No entanto, muitos pesquisadores afirmam que para se ter uma descoberta fidedigna é necessário partir das

observações de campo. A Figura 2.1 mostra a relação entre análises experimentais e modelagens na acústica marinha.

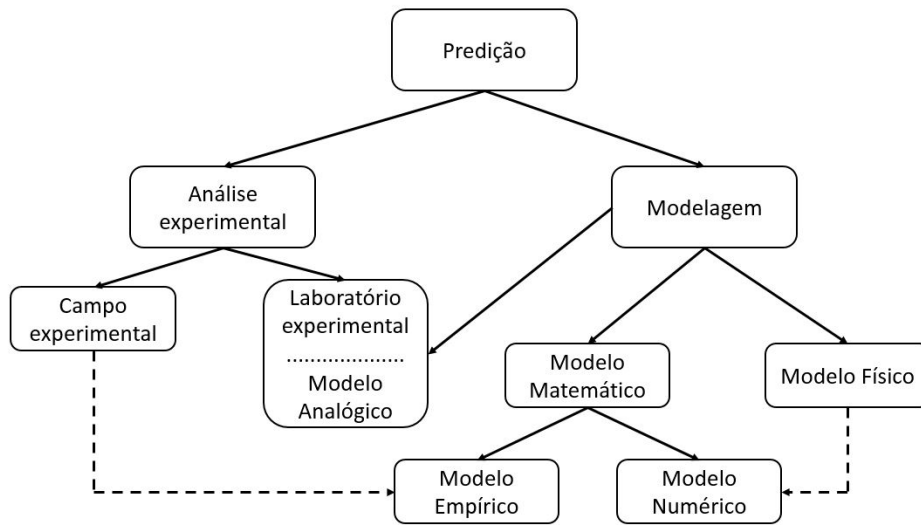


Figura 2.1: Relação entre experimentos e modelagem acústica [2].

Os modelos físicos formam a base para os modelos numéricos enquanto que as observações experimentais formam a base para os modelos empíricos. Além do mais, a modelagem analógica é representada como uma forma de experimentos de laboratório [2].

## 2.1 Onda sonora

Uma onda sonora é produzida quando um objeto vibra e transmite energia mecânica para as moléculas do meio em que se encontra. Enquanto esse objeto vibra, o meio ao redor é comprimido e expandido, resultando numa série de compressão e expansão fazendo com que a onda se propague [3]. As ondas sonoras são ondas longitudinais, ou seja, produzidas por uma sequência de pulsos longitudinais. Além disso, são ondas mecânicas pois necessitam de um meio material para ser propagado.

A velocidade do som está relacionada ao movimento longitudinal das ondas sonoras no meio de acordo com seu comprimento e sua frequência através da equação:

$$c = f\lambda \quad (2.1)$$

Onde  $f$  é a frequência da onda e  $\lambda$  representa seu comprimento. A velocidade de propagação do som  $c$  no mar é igual a  $1.5 \times 10^3 \text{ m/s}$  [3].

Em uma onda plana, a pressão varia apenas na direção de propagação do som, todos os pontos no plano normal ao de propagação possuem a mesma pressão. A onda plana tem sua pressão definida por:

$$p = (\rho c)u \quad (2.2)$$

Sendo  $p$  a pressão medida em  $\text{Pa}$  ou  $\text{N/m}^2$ ,  $u$  a velocidade da partícula em  $\text{m/s}$  e  $\rho$  a densidade do fluido ( $10^3 \text{ kg/m}^3$  para a água do mar). Na equação 2.2 tem-se a impedância acústica específica que é  $Z = \rho c$ , equivalente a  $1.5 \times 10^6 \text{ kg/m}^2\text{s}$  para a água do mar.

As ondas sonoras possuem uma energia mecânica que ocorre em forma de energia cinética das partículas que as carregam no meio de propagação. Quando a onda sonora se propaga, gera uma determinada quantidade de energia que flui em uma área normal à direção de propagação. Essa energia medida com o tempo é chamada de intensidade de propagação da onda, ou também, potência por unidade de área. Nas ondas planas, a Intensidade está relacionada com a pressão da seguinte forma:

$$I = p^2 / \rho c \quad (2.3)$$

No ambiente marinho, a intensidade de referência ( $I_r$ ) do som é definida pelo quadrado da raiz de uma onda plana de pressão igual a  $1 \mu \text{ Pa}$  (micro Pascal). Sendo  $p = 10^{-6}$  e  $\rho c = 1.5 \times 10^6$  tem-se que:

$$I_r = 0.67 \times 10^{-18} \text{ W/m}^2 \quad (2.4)$$

A relação entre intensidade da fonte à distância padrão de 1 metro ( $I_1$ ) e a intensidade de referência fornece o nível de uma fonte sonora ( $SL$ ):

$$SL = 10 \log\left(\frac{I_1}{I_r}\right) \quad (2.5)$$

Para uma fonte omnidirecional,  $I_1 = P/12,6 \text{ W/m}^2$ . Com isso, têm-se:

$$SL = 10 \log P + 170.8 \text{ dB} \quad (2.6)$$

Quando a projeção do som é direcional, têm-se um índice de diretividade de transmissão  $DI_t$  que é a relação entre a intensidade na direção do eixo de propagação

$I_{dir}$  e a intensidade equivalente a não direcional da projeção  $I_{omni}$ :

$$DI_t = 10 \log\left(\frac{I_{dir}}{I_{omni}}\right) \quad (2.7)$$

Com isso, têm-se:

$$SL = 10 \log P + 170.8 + DI_t \quad (2.8)$$

Sendo  $P$  a potência acústica irradiada pela fonte do sinal que é menor do que a potência elétrica  $P_e$  fornecida pelo mesmo.

## 2.2 Ruído Acústico no Ambiente Marinho

O ruído acústico do ambiente marinho é em geral prejudicial ao sistema sonar. Pode-se defini-lo como sendo o ruído residual na ausência de fontes individuais identificáveis [4]. Além disso, o ruído próprio do sonar não se enquadra nessa classificação. O ruído ambiente é típico da localização, profundidade e da época em que acontece.

A Figura 2.2 é um exemplo hipotético do espectro do ruído ambiente no oceano aberto [2]. Cinco bandas de frequências estão indicadas na Figura 2.2. A banda I, que está abaixo de 1 Hz, refere-se aos ruídos hidrostáticos ( ondas e marés) ou ruídos gerados de atividades sísmicas. A medição desses ruídos é difícil de se fazer devido à limitações nos hidrofones. Na banda II, têm-se o declive de 8 a 10 dB por oitava, na qual a fonte mais provável de ruído é a turbulência oceânica. Na banda III o espectro fica achatado aparentando ser o ruído de embarcações distantes. A banda IV tem um declive de 5 a 6 dB por oitava indicando que o ruído foi gerado na superfície do mar próxima ao ponto de medição. Acima de 50k Hz, a banda V é predominantemente originada do ruído térmico causado pela movimentação das moléculas do mar e caracterizado pela mudança positiva de 6 dB por oitava no espectro.

O espectro do ruído ambiente quando representado em diferentes condições é adequado para o estudo das predições. A figura 2.3 ilustra esse tipo de espectro. Esse gráfico recebe o nome de curva de Wenz [27] por ter sido ele o primeiro a publicá-lo. O gráfico relaciona a curva de ruído dos navios e dos ventos, os conectando em frequências intermediárias onde aparecem mais de uma fonte.




Figura 2.2: Espectro do ruído no oceano profundo




Figura 2.3: Espectro do ruído no oceano profundo

As potenciais fontes de ruído ambiente marinho serão descritas nos tópicos a seguir.

### 2.2.1 Ruídos Sísmicos

A atividade sísmica do planeta terra é constante. Erupções vulcânicas e terremotos são as maiores fontes transientes de ruídos em uma grande região de frequências. As atividades microssísmicas possuem períodos regulares de 0.14 Hz com amplitude



vertical na ordem de  $10^{-6} m$  e sua pressão acústica é igual a:

$$p = \rho c u = 2\pi \rho c f a \quad (2.9)$$

Onde  $a$  representa a amplitude de deslocamento. Utilizando-se os valores típicos para as constantes envolvidas, a equação 2.9 resulta em 124 dB relativos a  $1\mu Pa$ , mostrando que a energia da fonte se encontra em frequências extremamente baixas ELF (*Extremely Low Frequency*), abaixo de 1 Hz.

### 2.2.2 Turbulência dos Oceanos

A turbulência é a fonte de ruído dominante na faixa de baixa frequência VLF (*Very Low Frequency*), na região entre 1 a 10 Hz. O modelo teórico proposto por Wenz [27] para o cálculo do ruído referente à turbulência dos oceanos ( $Ln_{turb}$ ) é:

$$Ln_{turb} = NL_{turb} = 107 - 30 \log f \text{ dB re: } 1\mu Pa, 1 \text{ Hz} \quad (2.10)$$

Posteriormente, Sadowski [28] desenvolveu outro cálculo para o ruído advindo da turbulência dos oceanos:

$$Ln_{turb} = NL_{turb} = 108.5 - 57.6 \log f \text{ dB re: } 1\mu Pa, 1 \text{ Hz} \quad (2.11)$$

### 2.2.3 Ruído de Embarcações

Ruídos entre 10 Hz e 500 Hz são derivados do tráfego de navios. Em lugares onde o tráfego é maior, esse tipo de ruído pode chegar a frequências maiores, até de quilo-hertz. A Figura 2.3 mostra a região de frequências na qual esse tipo de ruído pode ocorrer.

### 2.2.4 Ruído das Ondas marítimas

A partir de 500 Hz chegando até 50 kHz, as fontes predominantes de ruído são as ondas e os ventos. Esse tipo de ruído também recebe o nome de *sea state*, ou "estado do mar".

### 2.2.5 Ruído Térmico

Ruído térmico é predominante em frequências maiores que 50 kHz. Esse ruído é produzido pela agitação térmica das moléculas da água pela corrente elétrica dos hidrofones.

O ruído térmico é dado por:

$$N_{ter} = -15 + 20 \log f \quad (2.12)$$

Sendo  $N_{ter}$  em dB re 1  $\mu$ Pa e  $f$  dado em kHz.

## 2.3 Modelos Matemáticos dos Ruídos

O ruído no ambiente marinho apresenta diversas fontes em variadas frequências. Na faixa de 50 a 1 kHz, a navegação e o estado do mar (*sea state*) são as principais fontes de ruídos observadas. Os modelos matemáticos de ruídos foram desenvolvidos a partir dessas duas fontes de ruído.

Os modelos matemáticos tem o objetivo mensurar a diretividade e o nível do ruído, analisando a frequência, a profundidade, a localização e a época do ano [2]. Pode-se agrupar os modelos em duas categorias, modelos de análise do ambiente e modelos estatísticos do ruído de feixe. No entanto, ambas categorias utilizam os mesmos princípios.

### 2.3.1 Modelos de Análise do Ruído Ambiente

Nessa categoria, o oceano consiste em infinitas camadas uniforme de água com um plano na superfície onde as fontes de ruídos são uniformemente distribuídas. O ruído é considerado independente da profundidade e calculado verticalmente entre os navios e o submarino [29].

As componentes de baixa frequência do ruído são mensuradas a partir dos parâmetros: densidade do sinal de navegação em função do azimute e da distância do receptor; nível da fonte do sinal para cada tipo de navio envolvido; e perda do sinal em função da distância vertical entre os navios e o submarino.

As componentes de alta frequência do ruído, derivadas das condições climáticas




Figura 2.4: Campo de ruído usado no modelo RANDI

na superfície, são generalizadas como local e isotrópicas<sup>1</sup>. Esse modelo considera apenas a velocidade do vento e o estado do mar na superfície, que são as principais fontes de ruídos para atuarem nessa categoria de frequência com um certo nível de interferência na medição do sistema sonar.

Como exemplo dessa categoria de modelo matemático pode-se citar o RANDI (*Research Ambient Noise Directionality*). O modelo RANDI calcula a direção vertical e horizontal de baixas frequências (10 a 500 Hz) em um determinado ambiente [30].

A Figura 2.4 mostra o campo de ruído modelado. O ruído da superfície é gerado por infinitas fontes de ruído distribuídas no plano horizontal, seis metros abaixo da superfície e distribuídos de forma anisotrópica. Para a análise do modelo, as fontes de ruídos são consideradas isotrópicas no receptor. Nessa figura está representada o canal SOFAR (*Sound Fixing and Ranging channel*) que indica a velocidade do som em função da profundidade.

### 2.3.2 Modelos Estatísticos de Ruído de Feixe

Os modelos estatísticos de ruído de feixe usam uma abordagem estatística para a modelagem das baixas frequências no ambiente marinho. Esse modelos utilizam características específicas dos padrões de feixe dos sistemas de sonar passivo.

O cálculo da probabilidade nesses modelos dependem da configuração do arranjo dos hidrofones, da orientação, localização e da época do ano em que está ocorrendo

<sup>1</sup>Possuem as mesmas propriedades físicas, independentemente da direção considerada.

a modelagem. A equação 2.13 desenvolvida por Moll [31] representa a potência total do ruído em uma banda específica na saída da conformação de feixes.

$$Y = \sum_{i=1}^m \sum_{j=1}^n \sum_{k=1}^{A_{ij}} S_{ijk} Z_{ijk} B_{ijk} \quad (2.13)$$

Onde  $m$  é o número de rotas na bacia oceânica;  $n$  é o quantidade de tipos de navios;  $A_{ijk}$  é a quantidade de navios do tipo  $j$  na rota  $i$  (uma variável randômica);  $S_{ijk}$  é a intensidade do ruído de navios do tipo  $j$  na rota  $i$  (uma variável também randômica que é estatisticamente independente da intensidade do ruído dos outros navios);  $Z_{ijk}$  é a relação da intensidade de transmissão entre o navio  $ijk$  e o receptor;  $B_{ijk}$  é o ganho da chegada de uma onda plana no navio  $ijk$ .

A utilização desses modelos de ruídos requer uma base de dados com muitas informações, desde rotas de navegação aos níveis de ruídos radiados por cada tipo de navio.

# Capítulo 3

## Sistema de Sonar Passivo

Aqui será mostrado como funciona um sistema de sonar passivo, apresentando os requisitos necessários para o processamento de sinais que identificam e classificam os contatos a partir da estimação da direção de interesse.

### 3.1 Introdução

O sistema sonar passivo é utilizado para estimar a localização de objetos em baixo d'água que transmitem sinais acústicos. Os sinais normalmente são captados através de um arranjo de hidrofones [32]. A Figura 3.1 mostra os principais tipos de sistemas de sonar passivo.

As sonobóias são utilizadas para detecção de submarinos. São lançadas ao mar por aeronaves que monitoram uma determinada região recebendo os sinais das sonobóias via rádio. Já o arranjo rebocável é linear e pode ser rebocado tanto por um navio quanto por um submarino. Outro tipo comum de sistema sonar passivo é o arranjo em linha, que pode monitorar toda uma região da costa litorânea.

Os sinais acústicos captados pelos arranjos de hidrofones que são gerados por embarcações, tais como navios, submarinos e torpedos, podem ser classificados em: ruído de máquinas, ruído de hélice e ruído hidrodinâmico [33].

Os ruídos de máquinas são oriundos da vibração mecânica das máquinas que operam em uma embarcação transmitida à parte da embarcação que está em contato com a água. O ruído de hélice é originado da rotação das hélices em contato direto com a água. O ruído hidrodinâmico advém do atrito entre a parte externa da em-




Figura 3.1: Tipos de sistemas de sonar passivo [1].

barcação com a água. Dentre os três tipos de ruídos produzidos pelas embarcações, apenas os ruídos gerados pelas máquinas e pelas hélices são considerados para detecção e identificação no sistema sonar passivo [33]. Além do ruído das embarcações, chegam aos hidrofones o ruído ambiente, fruto de fontes ruidosas de variados tipos, como descrito no capítulo 2 deste trabalho. Todas essas informações são processadas pelos algoritmos de sinais acústicos submarinos partindo do princípio de que o sinal é estacionário, independente e Gaussiano [34].

SOARES FILHO [35] descreve minuciosamente as fontes de ruído irradiado pelas embarcações, tais como navios, torpedos e submarinos. No mesmo trabalho são apresentados os tipos mais comuns de embarcações propulsionadas por motores Diesel-elétrico.

## 3.2 Descrição do Sistema de Sonar Passivo

O sistema de sonar passivo pode ser analisado em três etapas: detecção, classificação e localização dos contatos. Na etapa de detecção o objetivo é verificar a existência dos sinais acústicos de um contato de interesse. Após a detecção, segue-se para a etapa de classificação do contato para que seja determinado se é um contato

de interesse ou se vai ser desprezado. Sendo um contato de interesse, o sinal é assistido, em função do tempo, para que seja determinada sua localização [36,37].

A Figura 3.2 representa um sistema de sonar passivo completo. O arranjo de sensores capta sinais que são analisados pela conformação de feixes para determinar a direção de interesse (DOA) na qual será observado o contato relevante em uma determinada direção [38]. Depois de determinada a DOA, varrendo toda banda de frequência, os sinais seguem para as saídas de análise: áudio, banda larga e banda estreita. A saída de áudio terá facilidades em selecionar o feixe e ouvir a largura de banda determinada [3].

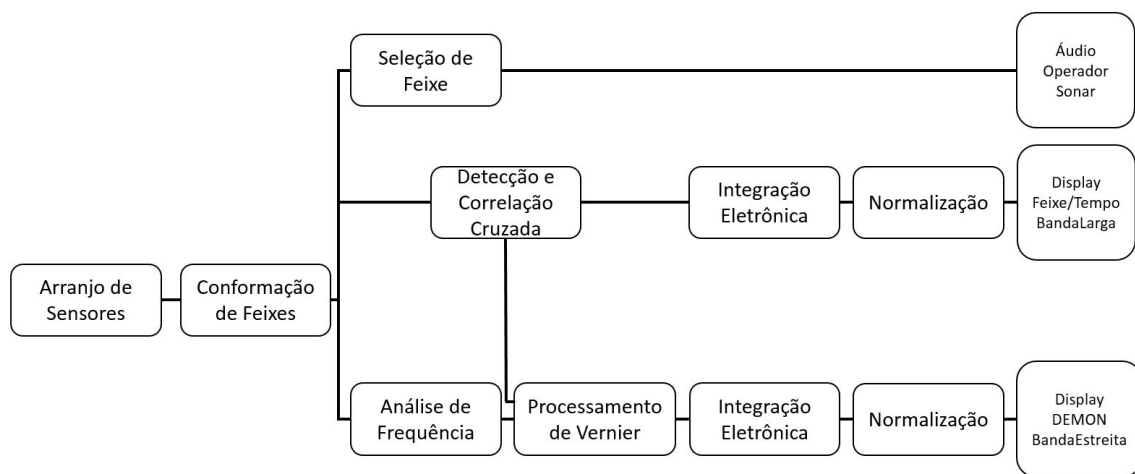


Figura 3.2: Diagrama de bloco do sistema de sonar passivo [3].

Na análise de banda larga, o sonar detecta os sinais a partir da sua energia ou utilizando técnicas de correlação cruzada. Em seguida é feita uma integração eletrônica do sinal somando-se a energia para que depois seja feita a normalização e a apresentação, geralmente é mostrada em feixe  $\times$  tempo. A análise de banda larga também pode ser apresentada em frequência  $\times$  tempo. A Figura 3.3, encontrada em [3], apresenta uma típica análise de banda larga enquanto que a Figura 3.4, encontrada em [1], apresenta uma relação de frequência  $\times$  tempo.

A análise de banda estreita faz uma varredura no espectro de frequência para converter o sinal de saída da conformação de feixes, que é uma série temporal, em potência espectral passando por duas etapas. Primeiramente é feita uma demodulação do sinal e em seguida é feita uma reamostragem, aumentando a resolução da frequência. A segunda etapa é conhecida também como processamento de Ver-




Figura 3.3: Análise de banda larga de um sonar passivo em feixe  $\times$  tempo [3].




Figura 3.4: Análise de banda larga de um sonar passivo em frequência  $\times$  tempo [1].

nier [39]. Os sinais da análise de banda estreita são mostrados comumente por LOFAGRAM (*low frequency analysis recording gram*), onde as saídas dos feixes são representadas em frequência  $\times$  tempo. A Figura 3.5, apresentada em [3], mostra um típico LOFAGRAM.



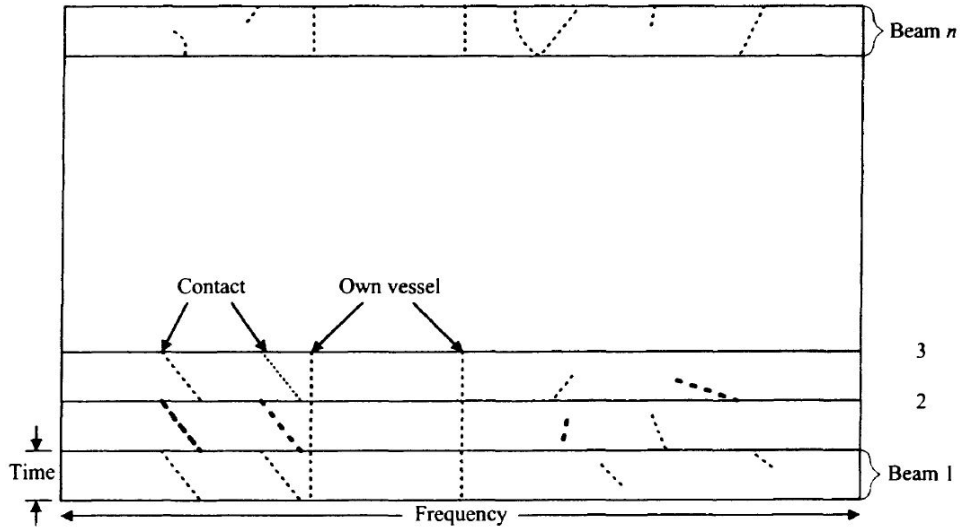


Figura 3.5: Análise de banda estreita de um sonar passivo em frequência  $\times$  tempo [3].

### Análise LOFAR

A análise LOFAR tem como objetivo evidenciar a frequência de ruído das máquinas do contato. É uma análise espectral de banda larga. A Figura 3.6 apresenta o diagrama de blocos da análise LOFAR



Figura 3.6: Diagrama de blocos da análise LOFAR.

Após definir a direção de interesse, o sinal passa pela etapa de janelamento, sendo multiplicado uma janela de Hanning [40]. Em seguida é aplicada uma transformada rápida de Fourier, a STFFT (*Short Time Fast Fourier Transform*) [41], para obter o sinal no domínio da frequência. A normalização para estimar o ruído de fundo é feita usando o algoritmo TPSW (*Two Pass Split Window*) [9, 42, 43].

## Análise DEMON

A análise DEMON é uma análise de banda estreita realizada para identificar o ruído de cavitação da propulsão do alvo [1, 44]. A Figura 3.7 apresenta o diagrama de blocos da análise DEMON.



Figura 3.7: Diagrama de blocos da análise DEMON.

O sinal, determinado pela DOA, passa por um filtro passa-faixa para que seja limitado na banda de frequência onde a cavitação é mais acentuada [36]. A faixa de frequência de cavitação pode variar de centenas até milhares de Hertz, porém, existem determinadas bandas de frequências onde o índice de modulação é mais acentuado, o que possibilita a identificação do contato. Pelo fato da frequência de amostragem do sinal ser mais elevada do que a banda de frequência da propulsão, faz-se uma reamostragem do sinal para que o mesmo seja transposto para a banda de propulsão. Em seguida, aplica-se a STFFT para adquirir o espectro do sinal. Assim como na análise LOFAR, o sinal é normalizado e apresentado.

A Figura 3.8 mostra o gráfico de uma análise DEMON. O eixo horizontal mostra a escala de rotação por minuto, rpm, e o eixo vertical mostra a amplitude do sinal em decibel. A velocidade de rotação do eixo do contato analisado é representada pela maior amplitude do sinal nesse gráfico e os harmônicos subsequentes indicam o número de pás [44].

### 3.3 Equação de um Sistema de Sonar Passivo

A equação de um sistema sonar tem como objetivo descobrir o nível da fonte de interesse que está misturada com outras fontes de sinais. Esse cálculo pode ser




Figura 3.8: Análise DEMON [1].

realizado utilizando a equação 3.1 apresentada por [45].

$$SL - TL = NL - DI + DT \quad (3.1)$$

Os parâmetros da equação 3.1 são definidos como:

- $SL$  - Nível da fonte, distante a 1 metro do centro acústico da fonte;
- $TL$  - Perda de transmissão entre a fonte e o receptor sonar;
- $NL$  - Nível de ruído no arranjo de hidrofone;
- $DI$  - Diretividade de recepção nos terminais dos hidrofones;
- $DT$  - Limiar de detecção, ou SNR necessário para que o detector tenha um desempenho específico.

Todos os parâmetros citados na equação 3.1 são calculados em decibel e possuem como referência a intensidade de uma onda plana, definida na equação 2.4.

A equação 3.1 expressa a relação entre a fonte do sinal e a perda na sua transmissão. Em seu alcance máximo de detecção, a potência do sinal recebido dividida pela potência do ruído resulta no limiar de detecção. Incertezas em alguns

parâmetros, especialmente em  $TL$  e  $NL$ , limitam a precisão da equação em alguns poucos decibéis.

Outra relação bastante utilizada é a figura de mérito (FOM - *Figure of Merit*). FOM é igual ao máximo permitido na perda de transmissão. A figura de mérito é utilizada para caracterizar o desempenho do sonar. A equação 3.2 apresenta a FOM.

$$FOM = TL = SL - [NL - DI + DT] \quad (3.2)$$

A equação 3.1 é válida quando o excesso de sinal na entrada do detector é zero. Apesar da equação 3.1 parecer simples, o cálculo de seus parâmetros são complexos e podem ser encontrados em [2].

### 3.4 Técnicas de Inteligência Computacional e Processamento Estatístico aplicadas a Sonar Passivo

Os trabalhos na área do sistema sonar passivo possuem boa parte de suas publicações restritas. Isso ocorre devido ao fato dos dados das pesquisas serem sigilosos, ligados ao interesse militar. O presente trabalho aborda um tema inovador e que possui poucas publicações com abordagem similar. Há trabalhos publicados que utilizam as mesmas técnicas aplicadas nesta dissertação, no entanto, há casos em que são utilizados em outros ambientes.

KNIGHT *et al.* [46] abordaram vários aspectos da acústica submarina relacionando-os com os impactos tecnológicos da utilização de sistemas eletrônicos digitais no desenvolvimento do sistema sonar. O trabalho, que foi produzido na década de 80, aborda o aperfeiçoamento das estruturas de *hardware* e *software* para o processamento de sinais de sonar passivo.

MARPLE e BROTHETON [47] propuseram a utilização do método de Prony na detecção e classificação de sinais acústicos. O método de Prony, técnica similar à transformada de Fourier, extrai as informações importantes de um sinal uniforme e constrói uma série amortecida de exponenciais e senoides, permitindo assim a

estimação da frequência, amplitude, fase e dos componentes amortecidos do sinal. Os autores mostram que a performance do método aplicado em sinais acústicos de curta duração supera os métodos tradicionais.

PEYVANDI *et al.* [12] propuseram um algoritmo baseado no modelo oculto de Markov (HMM - *Hidden Markov Model*) com a similaridade de Hausdorff (HSM - *Hausdorff Similarity Measure*) para a detecção e classificação de veículos submersos. Sendo o HMM um modelo estocástico de reconhecimento de voz e classificação de palavras, o mesmo foi utilizado para reconhecer sinais acústicos em ambientes ruidosos como uma boa perspectiva de classificação dos veículos submersos. O modelo foi proposto devido a dificuldade que o SONAR tem quando se faz uma classificação automatizada dos sinais acústicos baseada no espectro de frequências. Os autores conseguiram uma melhora na performance de classificação quando a SNR é baixa. Entretanto, para uma alta SNR a performance é praticamente a mesma que o SONAR, sendo que uma melhora na computação, com processadores mais rápidos, tende a favorecer o novo método proposto.

Atualmente, técnicas de inteligência computacional vem sendo bastante utilizadas em sistemas de sonar passivo para se obter melhores resultados nas questões que envolvem: direção de interesse; quantidade de alvos; e automatização da classificação dos contatos. O processamento estatístico feito a partir das técnicas de separação cega de fontes vem apresentando casos de sucesso no tratamento da interferência dos sinais e do ambiente ruidoso. CARDOSO [48] faz um estudo detalhado sobre a separação cega de fontes. Foram abordados os principais pontos para a utilização do modelo de separação cega de fontes como: o princípio da independência dos sinais; e o problema da identificação cega que é possível ser resolvido induzindo as indeterminações a partir da distribuição simétrica dos vetores dos sinais.

HYVARINEN e OJA [49] abordam o método da ICA para problemas de dados multivariáveis e vetores randômicos. Os autores fazem uma definição da ICA, mostrando suas ambiguidades, definindo e fundamentando o conceito de independência. Por fim, são ilustradas algumas aplicações para a ICA utilizando o algoritmo FastICA, também utilizado neste trabalho.

Os recentes trabalhos [1, 13, 33, 35, 50, 51] mostram que técnicas de separação cega de fontes [48], a qual será mais aprofundada no capítulo 4, implementadas no

sistema de sonar passivo produzem melhores resultados para a análise do operador sonar. Dentre as técnicas de separação cega de fontes estão entre as mais utilizadas para o processamento dos sinais no sistema sonar passivo: a análise de componentes independentes; a análise de componentes principais; e a fatoração de matrizes não negativas.

SEIXAS *et al.* [51] utilizam a análise de componentes independentes no sistema sonar passivo. A técnica de ICA apresentada no referido trabalho conseguiu melhorar a resolução do sistema sonar passivo em casos onde existe interferência cruzada.

SOARES FILHO *et al.* [13] abordam a utilização de componentes principais não-lineares (NLPCA) para a classificação de sinais no sistema sonar passivo. Os autores apresentam um método automático de detecção de classes de navios utilizando redes neurais. O uso dos componentes principais não-lineares tem como objetivo compactar a informação pré-processada que alimenta o classificador neural.

A ICA vem sendo utilizada no sistema de sonar passivo como uma forma de melhorar a relação sinal-interferência entre os contatos quando esses estão bem próximos. No entanto, quando utilizada para melhorar a relação sinal-ruído em ambientes significativamente ruidosos a ICA tem uma queda de performance. Alguns trabalhos recentes propõe o uso da ICA com ruído para esse tipo de abordagem.

BONHOMME e ROBIN [52] desenvolveram um algoritmo para utilizar a ICA em um ambiente com ruído. O autores partem de duas abordagens para a etapa de branqueamento do sinal feita pela ICA: utilização de um modelo de parametrização mais flexível para a distribuição dos erros; a outra é a substituição da análise de componentes principais (PCA - *Principal Component Analysis*) pela PCA probabilística, que deixa a parametrização da matriz de misturas mais rápida. O algoritmo proposto pelos autores é baseado no algoritmo JADE, substituindo os momentos teorizados por análises empíricas e por isso recebe o nome de Quasi-JADE.

MOULINE *et al.* [53] abordam o método da máxima verosimilhança<sup>1</sup> para a separação cega de fontes e a deconvolução de sinais com interferência de ruídos usando modelos de misturas. Os autores mostram que modelando a distribuição dos dados de entrada como distribuições gaussianas e, no caso de misturas convolutivas,

---

<sup>1</sup>Método para estimar uma população de parâmetros, como média e variância, através de dados selecionados para estimar os valores dos parâmetros maximizando a probabilidade de obtenção dos dados observados.

separando a função de verosimilhança, a implementação do método de máxima verosimilhança se torna eficiente tanto estatisticamente quanto numericamente.

HYVARINEN [54] utiliza o método estatístico da máxima verosimilhança para calcular a ICA na presença de ruídos gaussianos. O autor faz uma estimativa conjunta da matriz de mistura e dos componentes independentes, a partir de métodos consideravelmente simples e de menor exigência computacional comparado com [53].

VOSS *et al.* [55] propuseram um algoritmo de ICA para ruído gaussiano invariante. Os autores desenvolveram um algoritmo de ponto fixo que calcula a não correlação de ruídos gaussianos invariantes a partir das matrizes hessianas<sup>2</sup> das funções dos cumulantes. O algoritmo é baseado em uma forma especial de iteração de gradiente e recebe o nome de GI-ICA (*Gradient Iteration ICA*).

---

<sup>2</sup>Matrizes quadradas das derivadas parciais de segunda ordem de uma determinada função.

# Capítulo 4

## Tratamento dos Dados

No capítulo 3 foi mostrado que o ruído irradiado por um contato próximo ao submarino é captado através de hidrofones do sistema de sonar passivo chegando até o conformador de feixes com a presença de ruído de fundo composto pelo ruído próprio do submarino e pela interferência de outras marcações, em alguns casos. No caso de detecção, o OS acompanha visualmente pelo gráfico feixe  $\times$  tempo como mostrado na figura 3.3. Para a classificação, o OS dispõe do áudio da marcação bem como as análises espectrais DEMON e LOFAR, realizadas no sinal apresentadas na seção 3.2.

Com o objetivo de melhorar o tratamento dos dados para o OS, este trabalho faz o uso da técnica de separação cega de fontes. Com isso, esse capítulo aborda a etapa do tratamento dos dados realizada por algoritmos de ICA para a separação cega de fontes.

### 4.1 Separação Cega de Fontes

A separação cega de fontes [48] ( BSS - *Blind Source Separation*) tem como objetivo a recuperação de sinais não observados a partir da observação da mistura desses sinais. É uma análise feita apenas utilizando a mistura como base de dados para encontrar as fontes dos sinais que compõem essa mistura.

Para um melhor entendimento da separação cega de fontes será apresentado um exemplo existente em [15]: Os sinais de três fontes não conhecidas são observados por três receptores. Os sinais observados são chamados de  $x_1(t)$ ,  $x_2(t)$  e  $x_3(t)$ , que



são as amplitudes dos sinais adquiridos no tempo  $t$  e com  $s_1(t)$ ,  $s_2(t)$  e  $s_3(t)$  sendo os sinais originais. Os receptores captam a mistura dos três sinais sendo que cada sinal possui um coeficiente diferente para cada receptor, devido à distância entre as fontes dos sinais e os receptores.

$$\begin{aligned}x_1(t) &= a_{11}s_1(t) + a_{12}s_2(t) + a_{13}s_3(t) \\x_2(t) &= a_{21}s_1(t) + a_{22}s_2(t) + a_{23}s_3(t) \\x_3(t) &= a_{31}s_1(t) + a_{32}s_2(t) + a_{33}s_3(t)\end{aligned}\tag{4.1}$$

Os coeficientes  $a_{ij}$  são as constantes modificadoras de cada mistura que chega nos receptores, compondo a matriz de mistura  $\mathbf{A}$ .

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix}\tag{4.2}$$

Os coeficientes  $a_{ij}$  são desconhecidos, tornando o problema mais complicado de se resolver. Para solucionar o caso, deve-se encontrar os sinais originais a partir das misturas  $x_1(t)$ ,  $x_2(t)$  e  $x_3(t)$ . Esse é um caso evidente de separação cega, visto que o termo “cega” é usado pelo pouco conhecimento sobre os sinais originais.

Pode-se concluir que os coeficientes  $a_{ij}$  são suficientemente diferentes para que haja uma matriz inversível. Com isso, têm-se a matriz  $\mathbf{W}$  que é a matriz inversa de  $\mathbf{A}$ .

$$\mathbf{W} = \begin{bmatrix} w_{11} & w_{12} & w_{13} \\ w_{21} & w_{22} & w_{23} \\ w_{31} & w_{32} & w_{33} \end{bmatrix}\tag{4.3}$$

Com isso, os sinais  $s_i$  podem ser separados da seguinte forma:

$$\begin{aligned}s_1(t) &= w_{11}x_1(t) + w_{12}x_2(t) + w_{13}x_3(t) \\s_2(t) &= w_{21}x_1(t) + w_{22}x_2(t) + w_{23}x_3(t) \\s_3(t) &= w_{31}x_1(t) + w_{32}x_2(t) + w_{33}x_3(t)\end{aligned}\tag{4.4}$$

Para determinar os coeficientes de  $\mathbf{W}$ , são utilizadas propriedades estatísticas. Considerando-se que os sinais são estatisticamente independentes e sendo eles não gaussianos, pode-se determinar os coeficientes  $w_{ij}$  a partir da equação 4.5, onde:

$$\begin{aligned}y_1(t) &= w_{11}x_1(t) + w_{12}x_2(t) + w_{13}x_3(t) \\y_2(t) &= w_{21}x_1(t) + w_{22}x_2(t) + w_{23}x_3(t) \\y_3(t) &= w_{31}x_1(t) + w_{32}x_2(t) + w_{33}x_3(t)\end{aligned}\tag{4.5}$$

Sendo os sinais  $y_1(t)$ ,  $y_2(t)$  e  $y_3(t)$  estatisticamente independentes. Com isso, pode-se assumir que os sinais  $y_1(t)$ ,  $y_2(t)$  e  $y_3(t)$  representam os sinais originais, podendo estar multiplicados por uma constante escalar.

## 4.2 Análise de Componentes Independentes

A seção 4.1 mostra que a separação cega de fontes busca uma representação na qual os componentes são estatisticamente independentes. No entanto, a prática revela que a independência estatística é inexistente na maioria dos casos. Com isso, busca-se os componentes que são o mais independentes possíveis.

A ICA é um dos métodos mais utilizados para a execução da separação cega de fontes [56, 57]. O modelo generativo da ICA é mostrado na equação 4.6, onde são observadas as variáveis  $x_1, \dots, x_n$  que são compostas pela combinação linear das variáveis  $s_1, \dots, s_n$  [15].

$$x_i = a_{i1}s_1 + a_{i2}s_2 + \dots + a_{in}s_n, \quad \text{para } i = 1, \dots, n \quad (4.6)$$

É mais comum na literatura encontrar a denotação matricial para a equação 4.6.

$$\mathbf{x} = \mathbf{A}\mathbf{s} \quad (4.7)$$

Sendo  $\mathbf{W}$  a matriz inversa de  $\mathbf{A}$ , têm-se a equação 4.8.

$$\mathbf{y} = \mathbf{W}\mathbf{x} \quad (4.8)$$

Por definição, a ICA procura a transformação linear da matriz  $\mathbf{W}$ , considerando que as variáveis  $y_i, i = 1, \dots, n$  são o mais independente possíveis. É necessário o conhecimento das estatísticas de ordem superior (HOS - *High Order Statistic*) para o desenvolvimento dos algoritmos que realizam a análise de componentes independentes. Existem vários métodos matemáticos que buscam a independência estatística, sendo a decorrelação não linear e a maximização da não gaussianidade alguns dos mais aplicados [49].

O modelo de ICA possui indeterminações que podem causar mudanças na ordem de extração dos componentes independentes ou alterar os componentes estimados

devido a multiplicadores escalares. No entanto, na maioria dos casos essas indeterminações são insignificantes [15]. Sendo assim, pode-se sintetizar o problema em uma combinação linear dos sinais originais. Não é certo conseguir sempre essa representação, no entanto consegue-se chegar nos componentes que sejam o mais independente possível.

### 4.2.1 Independência Estatística

De acordo com definição do princípio da independência estatística, para que duas variáveis aleatórias  $X_1$  e  $X_2$  sejam estatisticamente independentes deve-se seguir a seguinte condição [58]:

$$p_{X_1, X_2}(x_1, x_2) = p_{X_1}(x_1)p_{X_2}(x_2) \quad (4.9)$$

sendo que  $p_{X_1, X_2}(x_1, x_2)$ ,  $p_{X_1}(x_1)$  e  $p_{X_2}(x_2)$  são respectivamente as funções de probabilidade conjunta e marginais (pdf) das variáveis aleatórias  $X_1$  e  $X_2$ . Considerando que as funções  $g(\cdot)$  e  $h(\cdot)$  são absolutamente integráveis, obtêm-se uma condição equivalente a partir da seguinte equação:

$$E\{g(x_1)h(x_2)\} = E\{g(x_1)\}E\{h(x_2)\} \quad (4.10)$$

onde  $E\{\cdot\}$  é o operador de expectância [58]. Devido à pouca informação disponível sobre estatística dos sinais originais, o uso das estimações de pdfs se torna complicado e pode ser evitado utilizando a equação 4.10, uma vez que vários algoritmos de ICA foram desenvolvidos com base na procura da decorrelação não linear.

As seguintes sub-seções abordam alguns dos princípios estatísticos.

### Não Gaussianidade

O modelo de ICA descrito na equação 4.7 pode ser reescrito da seguinte forma:

$$x_i = \sum_{j=1}^N a_{ij}s_j \quad \text{sendo } i = 1, \dots, N \quad (4.11)$$

O teorema do limite central [58] pode ser definido como: "A soma de duas variáveis aleatórias independentes é mais próxima de uma distribuição gaussiana do que as variáveis originais". Tem-se a equação 4.11 mostra que  $x_i$  é composto por

uma soma de fontes  $s_j$ , portanto,  $x_i$  tem uma distribuição mais gaussiana do que as variáveis  $s_j$ . Com isso, as variáveis independentes podem ser obtidas através da maximização da não gaussianidade.

### Descorrelação Não Linear

A descorrelação não linear é uma das maneiras que se pode verificar a independência estatística, sendo introduzida nos métodos de ICA a partir de funções não lineares. De acordo com a equação 4.10, é preciso analisar as correlações entre todas as funções não lineares. Essa análise é uma condição necessária para garantir a independência entre as variáveis aleatórias.

A garantia de que não há correlação linear na prática é obtida a partir de um conjunto finito de funções lineares. Tem-se como exemplo o algoritmo de ICA desenvolvido e apresentado por CHICHOCKI e UNBEHAUEN [59], que procura por componentes independentes enquanto faz a descorrelação entre a função polinomial e a tangente hiperbólica aplicadas aos sinais de entrada.

### Cumulantes de Ordem Superior

As características da distribuição de uma variável aleatória podem ser escritas estatisticamente por momentos e cumulantes. Sendo  $X$  uma variável aleatória,  $\alpha_k$  o momento e  $\mu_k$  o momento central de ordem  $k$  [58], tem-se que:

$$\alpha_k = E\{x^k\} = \int_{-\infty}^{\infty} x^k p_X(x) dx \quad (4.12)$$

$$\mu_k = E\{(x - \alpha_1)^k\} = \int_{-\infty}^{\infty} (x - \alpha_1)^k p_X(x) dx \quad (4.13)$$

A partir das equações 4.12 e 4.13, o primeiro momento  $\alpha_1 = m_x$  é a média de  $x$  e o segundo momento central  $\mu_2$  é a variância. Sendo assim, quando uma variável aleatória  $x$  tem média zero ou quando a média é removida ( $x \leftarrow x - m_x$ ), então  $\alpha_k = \mu_k$  para todo  $k$ .

Em alguns casos, a utilização de cumulantes possui um tratamento teórico mais simples do que os momentos. O cumulante  $\kappa_k$  de ordem  $k$  é definido como a função dos momentos [58]. Considerando uma variável aleatória  $x$  com média zero, tem-se

os quatro primeiros cumulantes definidos como:

$$\begin{aligned} \kappa_1 &= 0 \quad ; \quad \kappa_2 = E\{x^2\} = \alpha_2 \\ \kappa_3 &= E\{x^3\} = \alpha_3 \quad ; \quad \kappa_4 = E\{x^4\} - 3[E\{x^2\}]^2 = \alpha_4 - 3\alpha_2^2 \end{aligned} \quad (4.14)$$

Os cumulantes de terceira e quarta ordem são respectivamente a simetria ( $\kappa_3$ ) e a kurtose ( $\kappa_4$ ) [15]. Cumulantes acima de quarta ordem não são muito aplicados para os problemas relacionados a ICA. Dentre as propriedades dos cumulantes, destacam-se a aditiva e a invariância. Pela propriedade aditiva, se duas variáveis aleatórias  $X$  e  $Y$  são independentes, tem-se então a equação 4.15.

$$\kappa_k(X + Y) = \kappa_k(X) + \kappa_k(Y) \quad (4.15)$$

Pela propriedade da invariância, uma mudança na variável aleatória  $X$  (adição de uma constante  $c$ ) muda o cumulante de primeira ordem (a média) e não afeta os outros cumulantes, como mostrado na equação 4.16.

$$\begin{aligned} \kappa_1(X + c) &= \kappa_1(X) + c \\ \kappa_k(X + c) &= \kappa_k(X) \quad \text{para } k \geq 2 \end{aligned} \quad (4.16)$$

Partindo da propriedade da invariância, quando a variável aleatória  $X$  possui distribuição gaussiana, pode-se dizer que  $\kappa_k(X) = 0$  para  $k \geq 2$ . Com isso, tem-se que os cumulantes de ordem maior que dois podem ser utilizados para estimar a gaussianidade dos dados. No caso da simetria,  $\kappa_3 = 0$  indica que a função de densidade de probabilidade é simétrica. Quando a kurtose é zero, ( $\kappa_4 = 0$ ), no intervalo de  $[-2, \infty)$  tem-se um indicativo de variável gaussiana. Para valores negativos da kurtose, a variável aleatória possivelmente é sub-gaussiana e para valores positivos, super-gaussiana. A desvantagem do uso da kurtose é a influência que ela sofre em seu cálculo dos *outliers*, observações que se encontram numericamente distantes do resto dos dados. O cálculo da kurtose pode ser feito por uma pequena quantidade de pontos em situações extremas [60].

## Teoria da Informação

A teoria da informação [61] é outra alternativa de se medir a gaussianidade de uma variável aleatória. Seus parâmetros podem ser aplicados na busca por componentes

independentes. Um importante parâmetro é a entropia, que pode ser definida para uma variável aleatória  $x$  discreta como:

$$H(x) = \sum_i p(x = a_i) \log_b p(x = a_i) \quad (4.17)$$

onde  $a_i$  são os possíveis valores de  $x$  e  $p(x = a_i)$  é a probabilidade de  $x = a_i$ .

A entropia é um dos conceitos básicos da teoria da informação que quantifica a incerteza de uma variável aleatória. Na equação 4.17  $H(x)$  expressa um comprimento mínimo de código que valida a representatividade da variável aleatória  $x$ . Outro parâmetro da teoria da informação é a negentropia [61].

$$J(x) = H(x_{gauss}) - H(x) \quad (4.18)$$

sendo  $x_{gauss}$  uma variável gaussiana aleatória com a média e a variância iguais à da variável  $x$ .

Dentre variáveis de mesma variância, as gaussianas são as que possuem máxima entropia. Por isso, entropia e negentropia são utilizadas para o cálculo de gaussianidade. O uso da negentropia, equação 4.18, se mostra vantajoso devido ao fato dos valores de  $J(x)$  serem não negativos para qualquer variável  $x$  ou ser zero para quando a variável  $x$  for gaussiana. Nas aplicações de separação cega de fontes,  $J(x)$  e  $H(x)$  apresentam problemas com a estimação da pdf. Para evitá-los, são feitas aproximações utilizando cumulantes de ordem superior ou funções não polinomiais.

A negentropia pode ser estimada usando momentos de ordem superior.

$$J(x) \approx \frac{1}{12} E\{x^3\}^2 + \frac{1}{48} kurt(x)^2 \quad (4.19)$$

Por não ser um operador robusto para os *outliers*, pode-se evitar o uso da kurtose utilizando aproximações baseadas no princípio da máxima entropia, proposta por HYVARINEN [62]

$$J(x) \propto [E\{\mathbf{G}(x)\} - E\{\mathbf{G}(\nu)\}]^2 \quad (4.20)$$

sendo  $\nu$  uma variável gaussiana de média zero e variância unitária.

Para garantir que haja máxima distribuição de entropia  $\mathbf{G}$  não deve crescer mais rápida do que a função quadrática de  $|x|$  e deve conter aspectos da distribuição de

$x$  que sejam pertinentes à estimação da entropia. Algumas escolhas recomendadas de  $\mathbf{G}$  [62]:

$$G_1(\mu) = \frac{1}{a_1} \log \cosh a_1 \mu \quad , \quad G_2(\mu) = -\exp(-\mu^2/2) \quad (4.21)$$

onde  $a_1$  é uma constante situacional (geralmente  $1 < a_1 < 2$ ).

## 4.2.2 Pré-Processamento da ICA

O modelo padrão de ICA tem a mesma quantidade de sinais fontes e observados na mistura do sistema. O ruído adicional ambiente não é considerado nos cálculos. Com isso, são utilizadas etapas de pré-processamento de ICA para melhorar sua performance.

### Centralização

A centralização de  $\mathbf{x}$  é um pré-processamento básico e necessário. A centralização ocorre com a retirada da média pelo vetor  $\mathbf{m} = E\{\mathbf{X}\}$  fazendo com que  $X$  seja uma variável de média zero. Com isso, tem-se que  $\mathbf{s}$  também terá média zero, de acordo com a equação 4.7.

Esse pré-processamento é realizado para simplificar os algoritmos de ICA, não significando que a média não possa ser estimada. Após a estimação da matriz de misturas  $\mathbf{A}$  com os dados centralizados, pode-se adicionar novamente as médias de  $\mathbf{s}$  para sua estimação. O vetor médio  $\mathbf{s}$  é dado por  $\mathbf{A}^{-1}\mathbf{m}$ , sendo  $\mathbf{m}$  a média subtraída no pré-processamento [15].

### Branqueamento

A etapa de branqueamento dos sinais observados é uma estratégia importante no pré-processamento da ICA. Os sinais observados  $\mathbf{x}$  são descorrelacionados e suas variâncias se tornam unitárias, obtendo um novo vetor  $\tilde{\mathbf{x}}$ . A matriz de covariância de  $\tilde{\mathbf{x}}$  é igual a matriz identidade [15].

$$E\{\tilde{\mathbf{x}}\tilde{\mathbf{x}}^T\} = \mathbf{I} \quad (4.22)$$

O método mais utilizado para a realização do branqueamento é a decomposição em autovalores (EVD - *Eigen Value Decomposition*) da matriz de covariância  $E\{\mathbf{x}\mathbf{x}^T\} = \mathbf{E}\mathbf{D}\mathbf{E}^T$ , sendo  $\mathbf{E}$  a matriz ortonormal dos autovalores de  $E\{\mathbf{x}\mathbf{x}^T\}$  e  $\mathbf{D}$  a matriz diagonal dos autovalores,  $\mathbf{D} = \text{diag}(d_1, \dots, d_n)$ . Sendo assim, o branqueamento pode ser feito de acordo com a equação 4.23.

$$\tilde{\mathbf{x}} = \mathbf{E}\mathbf{D}^{-1/2}\mathbf{E}^T\mathbf{x} \quad (4.23)$$

As equações 4.7 e 4.23 mostram que o branqueamento transforma a matriz de misturas em uma nova matriz  $\tilde{\mathbf{A}}$ .

$$\tilde{\mathbf{x}} = \mathbf{E}\mathbf{D}^{-1/2}\mathbf{E}^T\mathbf{A}\mathbf{s} = \tilde{\mathbf{A}}\mathbf{s} \quad (4.24)$$

A nova matriz  $\tilde{\mathbf{A}}$  é ortogonal, propriedade que pode ser vista na equação 4.25.

$$E\{\tilde{\mathbf{x}}\tilde{\mathbf{x}}^T\} = \tilde{\mathbf{A}}E\{\mathbf{s}\mathbf{s}^T\}\tilde{\mathbf{A}}^T = \tilde{\mathbf{A}}\tilde{\mathbf{A}}^T = \mathbf{I} \quad (4.25)$$

O branqueamento reduz a quantidade de parâmetros que precisam ser estimados. A estimação é feita na nova matriz de misturas ortogonal  $\tilde{\mathbf{A}}$ , ao invés de ser feita para  $n^2$  parâmetros da matriz de misturas original  $\mathbf{A}$ . Para grandes dimensões, a matriz ortogonal contém aproximadamente a metade de parâmetros de uma matriz arbitrária. Por ser um processo simples, o branqueamento consegue reduzir a complexidade do problema.

### 4.2.3 Algoritmo JADE

O algoritmo JADE (*Joint Approximate Diagonalization of Eigenmatrices*) é uma das formas de solucionar o problema de separação cega de fontes. Esse algoritmo realiza a ICA utilizando cumulantes tensoriais de quarta ordem.

O tensor cumulante [63] é um operador linear de quarta ordem obtido pelo cruzamento dos cumulantes de quarta ordem dos dados analisados:  $\text{cum}(x_i, x_j, x_k, x_l)$ . Sendo a transformação linear do tensor feita no espaço de  $n \times n$  matrizes, os elementos da matriz de covariância  $\text{cov}(x_i, x_j)$  são dados pela equação 4.26

$$\mathbf{F}_{ij}(\mathbf{M}) = \sum_{kl} m_{kl} \text{cum}(x_i, x_j, x_k, x_l) \quad (4.26)$$



sendo  $m_{kl}$  os elementos da matriz  $\mathbf{M}$ .

O tensor cumulante é um operador linear simétrico e por isso pode-se aplicar a decomposição de autovalores. Com isso, define-se como automatrizes do tensor a matriz  $\mathbf{M}$ .

$$\mathbf{F}(\mathbf{M}) = \lambda \mathbf{M} \quad (4.27)$$

tendo como exemplo de automatriz  $\mathbf{F}_{ij}(\mathbf{M}) = \lambda \mathbf{M}_{ij}$  onde  $\lambda$  é um autovalor escalar.

O branqueamento é feito pelo cumulante de segunda ordem

$$z = \mathbf{V} \mathbf{A} s = \mathbf{W}^T s \quad (4.28)$$

sendo  $\mathbf{V}$  a matriz de branqueamento, no caso utilizando a decomposição de autovalores  $\mathbf{V} = \mathbf{E} \mathbf{D}^{-1/2} \mathbf{E}^T$  e  $\mathbf{W}^T$  a matriz de mistura branqueada, que é ortogonal. A matriz  $\mathbf{W}$  pode diagonalizar  $\mathbf{F}(\mathbf{M})$  para qualquer  $\mathbf{M}$ .

$$\mathbf{Q} = \mathbf{W} \mathbf{F}(\mathbf{M}_i) \mathbf{W}^T \quad (4.29)$$

A matriz  $\mathbf{W}$  não altera a soma dos quadrados da matriz  $\mathbf{F}(\mathbf{M}_i)$ . Com isso, tem-se que:

$$\mathcal{J}_{JADE}(\mathbf{W}) = \sum_i \|\text{diag}(\mathbf{W} \mathbf{F}(\mathbf{M}_i) \mathbf{W}^T)\|^2 \quad (4.30)$$

A maximização de  $\mathcal{J}_{JADE}$  é equivalente a maximização da soma dos quadrados dos elementos da diagonal, que é um método de aproximação da diagonalização de  $\mathbf{F}(\mathbf{M}_i)$  [15].

#### 4.2.4 Algoritmo FastICA

O princípio mais simples de estimação do modelo de ICA é de que os componentes independentes devem ter distribuição não gaussiana. O algoritmo FastICA é baseado nesse princípio, buscando a maximização da não gaussianidade.

O algoritmo FastICA pode ser aplicado utilizando a kurtose ou a negentropia [15]. A kurtose é o cumulante de quarta ordem de uma variável aleatória que pode ser obtida através da equação 4.31,

$$kurt(y) = E\{y^4\} - 3(E\{y^2\})^2 \quad (4.31)$$

sendo que para simplificar o cálculo, considera-se  $y$  normalizada tendo média igual a um:  $E\{y^2\} = 1$ .

Para o cálculo da maximização do valor absoluto da kurtose, utiliza-se um vetor de ponderação  $\mathbf{w}$  baseado nas amostras  $\mathbf{z}(1), \dots, \mathbf{z}(T)$  computando a direção onde o valor absoluto da kurtose de  $y = \mathbf{w}^T \mathbf{z}$  está em ascensão. O gradiente do valor absoluto da kurtose é calculado pela equação 4.32.

$$\frac{\partial |kurt(\mathbf{w}^T \mathbf{z})|}{\partial \mathbf{w}} = 4 \text{sign}(kurt(\mathbf{w}^T \mathbf{z})) [E\{\mathbf{z}(\mathbf{w}^T \mathbf{z})^3\} - 3\mathbf{w}\|\mathbf{w}\|^2] \quad (4.32)$$

Sabendo-se que os dados passaram por um processo de branqueamento, tem-se  $E\{(\mathbf{w}^T \mathbf{z})^2\} = \|\mathbf{w}\|^2$  e a otimização dessa função resulta em  $\|\mathbf{w}\|^2 = 1$ . Com isso, obtém-se o seguinte algoritmo de gradiente:

$$\Delta \mathbf{w} \propto \text{sign}(kurt(\mathbf{w}^T \mathbf{z})) E\{\mathbf{z}(\mathbf{w}^T \mathbf{z})^3\} \quad (4.33)$$

$$\mathbf{w} \leftarrow \mathbf{w} / \|\mathbf{w}\| \quad (4.34)$$

O algoritmo FastICA é uma iteração de ponto fixo derivado do algoritmo de gradiente, só que com maior rapidez e eficiência. A partir da equação 4.32 tem-se:

$$\mathbf{w} \leftarrow E\{\mathbf{z}(\mathbf{w}^T \mathbf{z})^3\} - 3\mathbf{w} \quad (4.35)$$

Outro método no qual pode ser utilizado o algoritmo FastICA é a negentropia. A maximização da não gaussianidade pela negentropia baseia-se nos cumulantes de ordem superior, usando expansões de densidade polinomial resultando na seguinte aproximação:

$$J(y) \approx \frac{1}{12} E\{y^3\}^2 + \frac{1}{48} kurt(y)^2 \quad (4.36)$$

Para resolver a equação 4.36 pode-se fazer uma aproximação do cumulante de alta ordem utilizando expansões polinomiais tais como  $G(y) = \log[\cosh(y)]$  ou  $-\exp(\frac{x^2}{2})$  [64]. Sendo assim, derivando o algoritmo do gradiente para a maximização da negentropia obtêm-se

$$\Delta \mathbf{w} \propto \gamma E\{\mathbf{z}g(\mathbf{w}^T \mathbf{z})\} \quad (4.37)$$

$$\mathbf{w} \leftarrow \mathbf{w} / \|\mathbf{w}\| \quad (4.38)$$

onde  $\gamma = E\{G(\mathbf{w}^T \mathbf{z})\} - E\{G(\nu)\}$  e  $\nu$  é uma variável aleatória gaussiana. Para o algoritmo FastICA, a iteração de ponto fixo é obtida a partir da equação 4.39.

$$\mathbf{w} \leftarrow E\{\mathbf{z}g(\mathbf{w}^T \mathbf{z})\} - E\{g'(\mathbf{w}^T \mathbf{z})\}\mathbf{w} \quad (4.39)$$

### 4.3 ICA com Ruído

O modelo de ICA proposto na seção 4.2 contempla uma abordagem considerando um ambiente não ruidoso. No caso do ambiente marinho há presença de ruído advindo de várias fontes, como mostrado no capítulo 2. Além disso, o ruído pode corresponder aos ruídos físicos dos dispositivos de medição. Portanto, é compreensível a proposta de incluir o termo ruído no modelo de ICA.

A ICA com ruído possui a estimação da matriz de mistura diferente. O modelo ruidoso não é inversível, o que requer novos métodos para estimação dos componentes livres do ruído. Considerando a adição no novo termo ao modelo de ICA, têm se que:

$$\mathbf{x} = \mathbf{A}\mathbf{s} + \mathbf{n} \quad (4.40)$$

Sendo  $\mathbf{n} = [n_1, \dots, n_n]^T$  o vetor que representa o ruído. Deve-se considerar que o ruído é gaussiano e independente dos componentes independentes. Além disso, a matriz de covariância do ruído é conhecida.

As mesmas restrições do modelo básico de ICA devem ser garantidas para a identificação da matriz de misturas do modelo de ICA com ruído: o princípio da independência; e a não gaussianidade. No entanto, os componentes independentes não podem ser mais completamente separados do ruído.

Assumindo que a covariância do ruído é  $\Sigma = \sigma^2\mathbf{I}$  a equação 4.40 pode ser considerada como ruído do sensor, pois as variáveis do ruído são adicionadas em cada variável  $x_i$ . Outra abordagem é feita quando o ruído é adicionado aos componentes independentes. Essa abordagem recebe o nome de ruído da fonte, sendo modelada de acordo com a equação 4.41.

$$\mathbf{x} = \mathbf{A}(\mathbf{s} + \mathbf{n}) \quad (4.41)$$

Considerando os componentes independentes com ruído dados por  $\tilde{s}_i = s_i + n_i$ , a equação 4.41 pode ser reescrita como:

$$\mathbf{x} = \mathbf{A}\tilde{\mathbf{s}} \quad (4.42)$$

A equação 4.42 retrata o modelo básico da ICA com os componentes independen-

tes modificados. É importante ressaltar que os componentes de  $\tilde{\mathbf{s}}$  são independentes e não gaussianos, mesma premissa da ICA sem ruído. Com isso, pode-se estimar o modelo da equação 4.42 utilizando qualquer método de ICA. A matriz de misturas e os componentes independentes com ruído também são obtidos pelos algoritmos de ICA sem ruído. No entanto, o problema reside na identificação dos componentes independentes sem ruído.

### 4.3.1 Estimação da Matriz de Misturas

O cálculo da matriz de misturas na ICA sem ruído já se configura como um desafio. O ruído é geralmente negligenciado para se obter algoritmos mais simples. Em alguns casos, assumir que os sinais observados podem ser separados entre ruído e sinais de interesse não é possível. No entanto, existem algumas maneiras de tratar o problema de estimação da matriz de misturas, que serão mostrados a seguir.

#### Técnicas de Remoção de Viés

As técnicas de remoção de viés são as abordagens mais utilizadas para o cálculo da ICA com ruído. O método de resolução da ICA sem ruído é modificado para eliminar ou reduzir os desvios gerados pelo ruído. Considerando os dados  $\mathbf{v}$  livres de ruídos, tem-se:

$$\mathbf{v} = \mathbf{A}\mathbf{s} \quad (4.43)$$

Com o objetivo de se obter a não gaussianidade, as projeções descritas por  $\mathbf{w}^T \mathbf{v}$  são localmente maximizadas para o branqueamento dos dados tendo como limitante  $\|\mathbf{w}\| = 1$ . Essas direções oferecem estimativas consistentes dos componentes independentes de acordo com a escolha correta da medição da não gaussianidade. Tendo  $\mathbf{w}^T \mathbf{x} = \mathbf{w}^T \mathbf{v} + \mathbf{w}^T \mathbf{n}$ , o objetivo é a medição da não gaussianidade de  $\mathbf{w}^T \mathbf{v}$  a partir dos dados observados  $\mathbf{w}^T \mathbf{x}$  sem ter a medição afetada pelo ruído  $\mathbf{w}^T \mathbf{n}$ .

A remoção de viés pode ser feita pela kurtose, uma vez que a mesma é imune ao ruído gaussiano. Isso se deve pelo fato da kurtose de  $\mathbf{w}^T \mathbf{x}$  ser igual a kurtose de  $\mathbf{w}^T \mathbf{v}$ , facilmente provado a partir das propriedades da kurtose. No entanto, o efeito do ruído na etapa de branqueamento deve ser observado. Sendo  $\mathbf{C} = E\{\mathbf{x}\mathbf{x}^T\}$

a matriz de covariância dos dados ruidosos observados, o branqueamento feito no processo normal deve ser substituído pela seguinte operação:

$$\tilde{\mathbf{x}} = (\mathbf{C} - \Sigma)^{-1/2} \mathbf{x} \quad (4.44)$$

Sendo assim, a matriz de covariância  $\mathbf{C} - \Sigma$  dos dados livres de ruídos deverá ser utilizada no processo de branqueamento, substituindo a matriz de covariância  $\mathbf{C}$ . Essa operação é chamada de *quasi-whitening* [15]. Depois dessa operação, tem-se os dados  $\tilde{\mathbf{x}}$  de acordo com o modelo de ICA com ruído:

$$\tilde{\mathbf{x}} = \mathbf{B}\mathbf{s} + \tilde{\mathbf{n}} \quad (4.45)$$

onde  $\mathbf{B}$  é ortogonal e  $\tilde{\mathbf{n}}$  a transformada linear do ruído da equação 4.40.

Outra forma de remoção de viés é realizada pelas medições de não gaussianidade. Essas medições contém propriedades estatísticas melhores que a kurtose. Tem-se então, a seguinte medição:

$$J_G(\mathbf{w}^T \mathbf{v}) = [E\{G(\mathbf{w}^T \mathbf{v})\} - E\{G(\nu)\}]^2 \quad (4.46)$$

onde  $G$  é uma função não quadrática suficientemente regular e  $\nu$  uma variável gaussiana padronizada. Para que a medição de  $J_G(\mathbf{w}^T \mathbf{v})$  seja possível em dados com ruídos, deve-se escolher  $G$  como sendo uma função de densidades de variável gaussiana com média zero [65]. Esse momento não polinomial é chamado de momento gaussiano, sendo escrito da seguinte forma:

$$\mu_c(x) = \frac{1}{c} \mu\left(\frac{x}{c}\right) = \frac{1}{\sqrt{2\pi}c} \exp\left(-\frac{x^2}{2c^2}\right) \quad (4.47)$$

Os componentes independentes podem ser estimados de sinais com ruídos maximizando a função de contraste da equação 4.46 onde a estimação direta das estatísticas de  $E\{G(\mathbf{w}^T \mathbf{v})\}$  dos dados livres de ruído é possível utilizando  $G(u) = \mu^{(k)}(u)$  [65]. A forma estatística  $E\{\mu_c^{(k)}(\mathbf{w}^T \mathbf{v})\}$  é o momento gaussiano do sinal. Com isso, o *quasi*-branqueamento do sinal  $\tilde{\mathbf{x}}$  é feita a maximização da função de contraste:

$$\max_{\|\mathbf{w}\|=1} [E\{\mu_{d(\mathbf{w})}^{(k)}(\mathbf{w}^T \tilde{\mathbf{x}})\} - E\{\mu_c^{(k)}(\mathbf{w}^T \mathbf{v})\}]^2 \quad (4.48)$$

## Métodos de Cumulantes de Ordem Superior

A estimação da matriz de misturas pode ser realizada utilizando apenas os métodos de cumulantes de ordem superior. Esses cumulantes não são afetados por ruídos gaussianos o que leva a imunidade desses métodos para tais ruídos. No entanto, os métodos de cumulantes mais utilizados são de sexta ordem. Sabendo-se que os cumulantes de ordem superior são sensíveis aos *outliers*, o uso desses métodos acima da quarta ordem se torna impraticável.

A maioria dos métodos baseados em cumulantes podem ser modificados para o uso em casos com ruídos, maximizando o valor da kurtose [15].

## Métodos de Máxima Verossimilhança

Outra abordagem para a estimação da matriz de misturas são os métodos de máxima verossimilhança. Nessa abordagem, pode-se fazer a maximização da verossimilhança conjunta da matriz de misturas e dos componentes independentes, dada pela equação 4.49.

$$\log L(\mathbf{A}, s(1), \dots, s(T)) = - \sum_{t=1}^T \left[ \frac{1}{2} \|\mathbf{A}s(t) - x(t)\|_{\Sigma^{-1}}^2 + \sum_{i=1}^2 f_i(s_i(t)) \right] + C \quad (4.49)$$

sendo que  $\|\mathbf{m}\|_{\Sigma^{-1}}^2$  é definido por  $\mathbf{m}^T \Sigma^{-1} \mathbf{m}$  os sinais  $s(t)$  representam os componentes independentes e  $C$  uma constante. A função  $f$  são os logaritmos das funções de densidade de probabilidade (pdf's) dos componentes independentes. No entanto, a maximização conjunta exige muito processamento computacional.

Outro método utilizado é a maximização marginal da verossimilhança da matriz de mistura. Esse método aproxima a densidade dos componentes independentes como misturas gaussianas para tornar possível a aplicação de algoritmos de maximização das expectativas (*EM-Expectation - Maximization*). Contudo, a complexidade computacional da utilização do algoritmo EM aumenta exponencialmente com o aumento da dimensão dos dados.

A utilização das técnicas de remoção de viés para o algoritmos de maximização da verossimilhança mostram-se consistentes em sinais com ruídos. Tais métodos foram utilizados por CICHOCKI [66].

### 4.3.2 Estimação dos Componentes Independentes Livres de Ruído

A estimação da matriz de misturas não é suficiente para resolver o problema da ICA com ruído. A matriz inversa de  $\mathbf{A}$  da equação 4.40 é obtida pela equação 4.50.

$$\mathbf{W}\mathbf{x} = \mathbf{s} + \mathbf{W}\mathbf{n} \quad (4.50)$$

Analisando a equação 4.50, percebe-se que os componentes independentes são estimados contendo ruído. No entanto, o principal objetivo é estimar os componentes independentes originais com a mínima interferência de ruído possível.

Os componentes independentes sem ruídos podem ser estimados utilizando as técnicas de maximização a *posteriori* (MAP - *Maximum a Posteriori*). O estimador MAP utiliza o gradiente da 4.50 respeitando os sinais originais e igualando a zero. Com isso, tem-se a seguinte equação:

$$\hat{\mathbf{A}}^T \boldsymbol{\Sigma}^{-1} \hat{\mathbf{A}} \hat{\mathbf{s}}(t) - \hat{\mathbf{A}}^T \boldsymbol{\Sigma}^{-1} x(t) + f'(\hat{\mathbf{s}}(t)) = 0 \quad (4.51)$$

onde a derivada da log-densidade  $f'$  é aplicada separadamente em cada componente do vetor  $\hat{\mathbf{s}}(t)$  [15].

### 4.3.3 Algoritmo GI-ICA

Os algoritmos de ICA utilizados no presente trabalho basicamente possuem duas etapas de execução:

- 1 Os dados observados são centralizados e branqueados, fazendo com que a matriz de covariância seja a matriz identidade. Esse processo é feito tipicamente pela análise de componentes principais (PCA - *Principal Component Analysis*) [67]. No procedimento os componentes independentes são ortogonalizados e redimensionados readquirindo a matriz  $\mathbf{A}$  numa matriz ortogonal desconhecida  $\mathbf{R}$ .
- 2 Recuperação da matriz  $\mathbf{R}$ .

O ruído gaussiano prejudica o branqueamento da primeira etapa da ICA. Mesmo o ruído sendo branco, que possui a matriz identidade como matriz de covariância,

o procedimento da PCA não garante o branqueamento dos componentes independentes. Alguns trabalhos [68, 69] foram desenvolvidos considerando  $\mathbf{n}$  como sendo variáveis de ruído gaussiano aditivo às variáveis independentes  $\mathbf{s}$ . O algoritmo GI-ICA (*Gradient Iteration - Independent Component Analysis*) [55] foi desenvolvido a partir de iterações de gradiente compatíveis com a etapa de *quasi*-ortogonalização mostrando ter a convergência de ordem  $r - 1$  quando cumulantes univariáveis de ordem  $r$  são implementados.

Considerando  $\mathbf{W}$  uma matriz *quasi*-ortogonalizada e definindo  $\mathbf{y} := \mathbf{W}\mathbf{x} = \mathbf{W}\mathbf{A}\mathbf{s} + \mathbf{W}\mathbf{n}$ , existe uma matriz de rotação  $\mathbf{R}$  e uma matriz diagonal  $\mathbf{D}$  tal que  $\mathbf{W}\mathbf{A} = \mathbf{R}\mathbf{D}$ . Sendo  $\tilde{\mathbf{s}} := \mathbf{D}\mathbf{s}$ , as coordenadas de  $\tilde{\mathbf{s}}$  representam os componentes independentes e o ruído gaussiano faz com que a matriz  $\mathbf{D}$  não seja recuperável. Portanto, busca-se a recuperação da matriz  $\mathbf{R}$ .

Sendo a função  $G$  composta por variáveis aleatórias univariáveis que satisfaça a propriedade aditiva e homogeneidade de grau  $r \geq 3$ , para um vetor de entrada  $v$  tem-se o cálculo do gradiente apresentado na equação 4.52.

$$\nabla_{\mathbf{v}}G(\mathbf{v} \cdot \mathbf{y}) = r \sum_{i=1}^d (\mathbf{v} \cdot R_i)^{r-1} G(\tilde{\mathbf{s}}) R_i \quad (4.52)$$

Com base no que acontece nas colunas de  $R$ , cada coordenada de  $\mathbf{v}$  é elevada a ordem  $r - 1$  e em seguida normalizada sendo levado à convergência pelas iterações do algoritmo GI-ICA, apresentada na equação 4.53.

$$\begin{aligned} \mathbf{v} &\leftarrow \nabla_{\mathbf{v}}G(\mathbf{v}^T \mathbf{y}) \\ \mathbf{v} &\leftarrow \mathbf{v} / \|\mathbf{v}\|_2 \end{aligned} \quad (4.53)$$



# Capítulo 5

## Metodologia de Análise

### 5.1 Base de Dados

Os dados utilizados nesse trabalho foram produzidos por um simulador de sistema de sonar passivo da Marinha do Brasil utilizado para o treinamento de seus operadores sonar. Esses dados fazem parte de diversos trabalhos de pesquisa [1, 10, 11, 13, 35, 50, 51] por mais de uma década.

Os dados adquiridos pela simulação contém uma frequência de amostragem em  $f_s = 31.250$  Hz com janelas temporais de 60 segundos. De acordo com [1], o tamanho da janela é para garantir uma boa resolução de frequência na função de reamostragem utilizada na análise DEMON, de 20 segundos aproximados, com uma FFT de 1.024 bins de frequências.

A figura 5.1 ilustra o cenário da simulação que consiste em dois navios, com regime de cavitação permanente, partindo de posições diferentes, sendo captados pelo sonar do submarino a partir das marcações M1 e M2, na direção de um submarino. Os navios vão se aproximando e com isso ocorre uma interferência entre os sinais adquiridos pelo sistema sonar passivo do submarino. A partir do alto índice de cavitação é possível identificar a propulsão dos contatos através da análise DEMON. Os sinais adquiridos possuem duração de aproximadamente 1.020s.

A figura 5.2 mostra a análise DEMON do contato 1 e a figura 5.3 representa a análise DEMON do contato 2. Pode-se perceber que o contato 1 produz rotações entre 470 e 480 rpm e o contato 2 entre 386 e 396 rpm. Por volta de 600 segundos, o contato um muda a rotação de 479,6 para 470,8 rpm e o contato 2 muda de

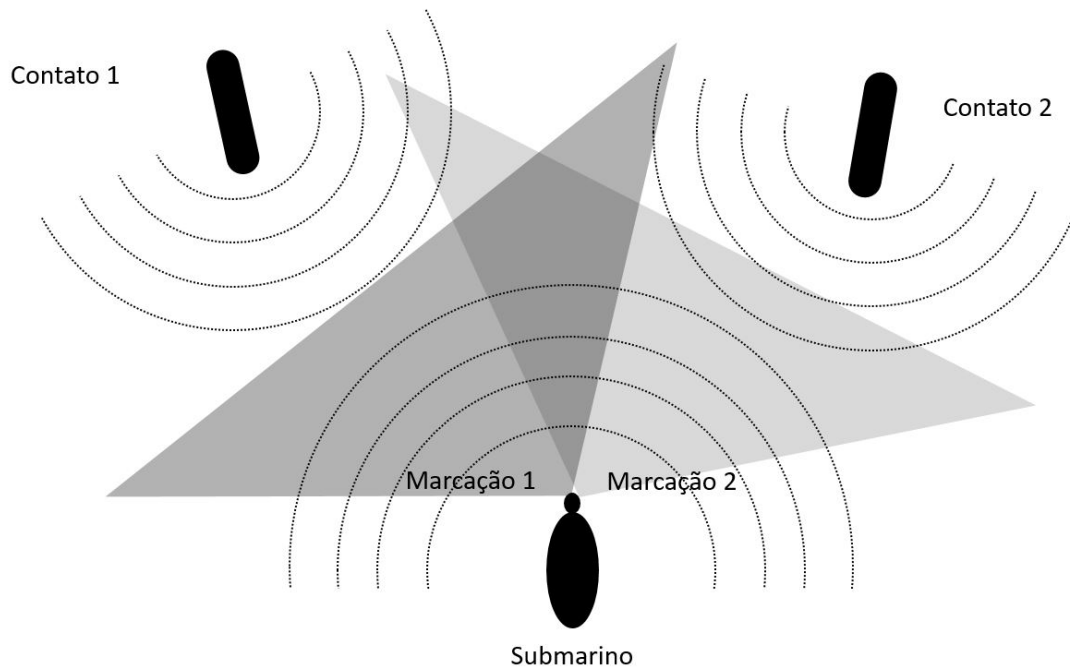


Figura 5.1: Cenário da simulação.

395,3 para 386,6 rpm, mostrando que houve variação na velocidade dos contatos pelo simulador. A interferência entre os contatos é perceptível por volta dos 780 segundos da análise.




Figura 5.2: Análise DEMON do contato 1.

Esses dados foram utilizados em [1] para avaliar o desempenho de separação cega

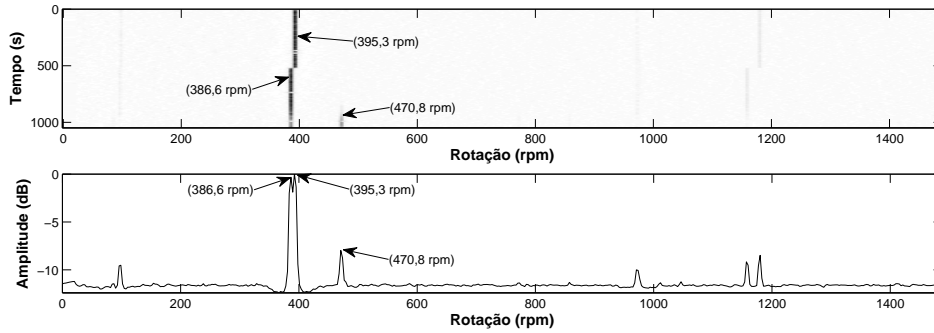


Figura 5.3: Análise DEMON do contato 2.

de fontes quando há uma grande interferência entre os contatos. O presente trabalho insere-se neste contexto, adicionando uma simulação de ruído ambiente para avaliar o desempenho dos algoritmos de ICA, como será demonstrado no capítulo a seguir.

## 5.2 Metodologia

A figura 5.4 mostra o diagrama de blocos da operação no domínio do tempo. Após serem identificadas as marcações que contém os sinais dos contatos, é inserido o ruído ambiente. Em seguida, faz-se um janelamento de 60 segundos para que seja realizada a análise DEMON. É realizada então a ICA para em seguida amostrar os sinais.

A análise deste trabalho concentrou-se na ultima janela temporal. É nessa etapa da simulação em que os contatos estão mais próximos e com isso ocorre uma maior incidência de interferência. Com isso, pode-se analisar melhor a robustez dos algoritmos de ICA.




Figura 5.4: Diagrama de Blocos da metodologia de análise.

## 5.2.1 Simulação do Ruído Ambiente

A simulação do sinal que representa o ruído ambiente foi realizada a partir de uma adaptação do ruído branco. Foi usado como base para simulação o ruído do estado do mar proposto na figura 5.5. O ruído do estado do mar tem sua maior interferência na faixa de 1 a 1kHz. Como a frequência dos propulsores dos navios estão na faixa de 10 e 500 Hz utilizou-se um filtro passa-baixa com frequência de corte de 500 Hz para criar o ruído que interferisse nos sinais.




Figura 5.5: Padrão de ruído ambiente para modelagens acústicas e análises [4].

Para análise do trabalho, este ruído ambiente simulado teve sua potência aumentada gradativamente até o momento em que os algoritmos de ICA não conseguiam mais separar os sinais.

## 5.2.2 Métricas de desempenho

Com o objetivo de avaliar a performance dos algoritmos de ICA, foram utilizados índices de desempenho. Esses índices foram medidos a partir dos espectros obtidos na análise DEMON e na separação cega.

A faixa de propulsão dos contatos varia entre 0 e 1500 rpm na análise DEMON. Os contatos simulados utilizados nesse trabalho se encontram entre 385 e 480 rpm. Com isso, em termos de análise gráfica, o processamento foi realizado entre 350 e 550 rpm. Esta configuração elimina componentes que não são de interesse para a análise.

Como índices de desempenho, foram utilizados:

- SNR - Relação sinal/ruído dos contatos.
- SIR - Relação sinal/interferência entre os contatos.

O índice SNR é usado para aferir qualitativamente se houve alguma melhora na atenuação do ruído ambiente e o índice SIR verifica se houve melhora na atenuação da interferência dos sinais dos contatos.

# Capítulo 6

## Resultados

Na simulação disponibilizada pela Marinha do Brasil, os sinais de dois navios foram captados pelo sistema de sonar passivo de um submarino em duas marcações. Para verificar a robustez da separação cega de fontes através da ICA, foi inserido um sinal simulando o ruído ambiente. A ICA foi utilizada após a análise DEMON com o propósito de detectar a propulsão dos contatos. Foi criada uma metodologia para estimar os sinais originais dos contatos com o objetivo de reduzir a influência do ruído ambiente.

### 6.1 Resultados da Análise

Para obter uma análise mais robusta, utilizou-se a janela temporal na qual a interferência cruzada fosse a maior. A janela 17 é a última janela temporal e apresenta a maior interferência cruzada, visto que neste momento os contatos estão mais próximos. Foi inserido um ruído gaussiano com frequências abaixo de 500 Hz sendo que a cada simulação feita, a amplitude desse ruído foi aumentada em 5 decibéis.

A separação cega de fontes foi realizada no domínio do tempo. O espectro de frequências obtido nas marcações são mostrados nas figuras 6.1 e 6.2.

De acordo com a análise espectral das figuras 6.1 e 6.2, a banda de frequência dos sinais se encontra entre 0 e 15.625 Hz, sendo que a banda de frequência da propulsão dos contatos se encontra entre 0 e 25 Hz. Essa faixa de frequência da propulsão resulta numa faixa de rotação de 0 a 1500 rpm.




Figura 6.1: Espectro de Frequência da última janela temporal na marcação 1.

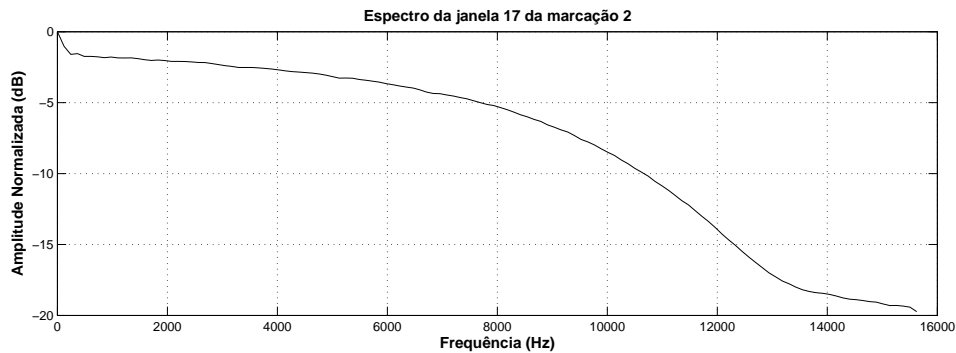


Figura 6.2: Espectro de Frequência da última janela temporal na marcação 2.

A seguir, serão apresentados os três algoritmos que compõem esse trabalho. Dois algoritmos, JADE e FastICA, foram projetados para encontrar componentes independentes sem considerar a influência de ruídos. Já o algoritmo GI-ICA leva em consideração nos seus cálculos a análise de componentes independentes com a influência de ruídos, como foi explicado na seção 4.3.

### 6.1.1 Algoritmo JADE

Os gráficos da análise DEMON das marcações serão mostrados a seguir. A figura 6.3 mostra os espectros das marcações 1 e 2 sem a interferência do ruído ambiente assim como dos componentes estimados pelo algoritmo JADE. Em cada gráfico está marcada a posição dos contatos baseado na rotação dos seus propulsores, 386,6 rpm para o contato 1 e 470,8 rpm para o contato 2. Neste gráfico, o algoritmo de JADE consegue melhorar a SIR na faixa de 10 dB.

Os gráficos da análise DEMON com a adição do ruído ambiente nos sinais das marcações são mostrados nas figuras de 6.4 a 6.13. Essas figuras representam os

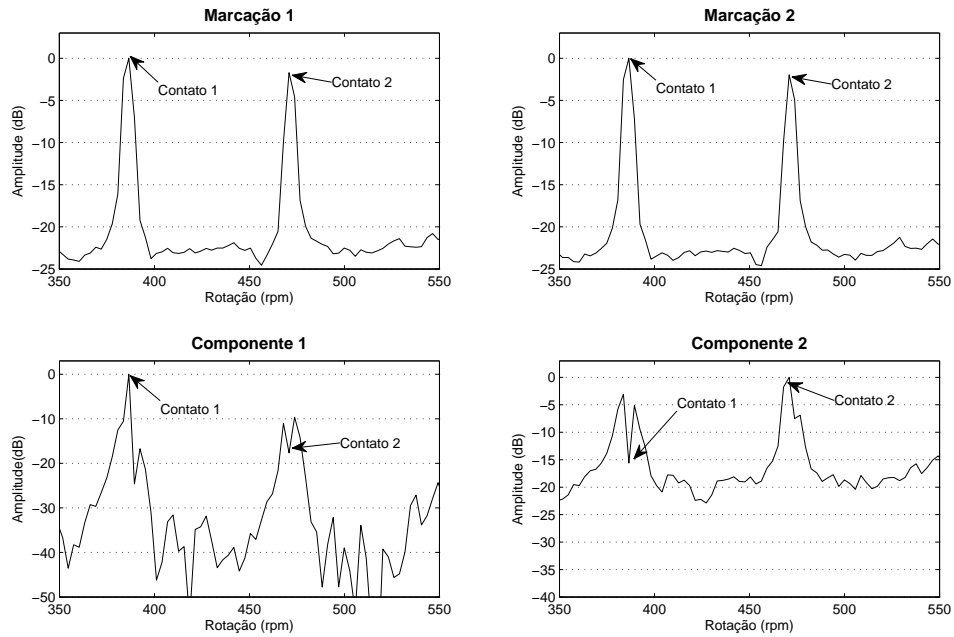


Figura 6.3: Espectro das marcações no domínio do tempo usando algoritmo JADE.

espectros dos contatos com a adição do ruído ambiente. O algoritmo JADE processa o sinal vindo da análise DEMON melhorando a relação sinal-interferência entre os contatos. Quando o ruído inserido tem sua amplitude ajustada para 45 dB, na figura 6.13, a análise DEMON não consegue diferenciar os contatos devido à forte interferência gerada por este ruído. O algoritmo JADE também não consegue diferenciar os contatos a partir de 45 dB.

Em relação ao ruído, os resultados obtidos pelo processamento do algoritmo JADE não consistem numa melhoria significativa. Como esse algoritmo não considera o ruído em seus cálculos, era esperado uma inconsistência nos resultados. Pelas análises gráficas e em relação à análise DEMON, no componente 1 tem-se uma melhora na relação sinal-ruído enquanto que no componente 2 essa relação é similar ou pior do que antes do processamento do algoritmo JADE.



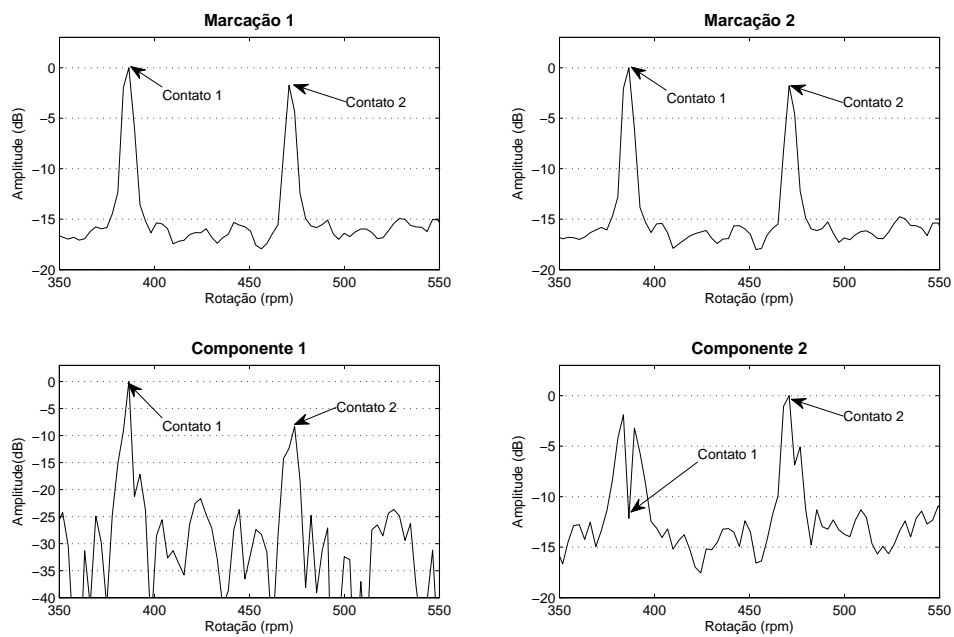


Figura 6.4: Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 0 dB.

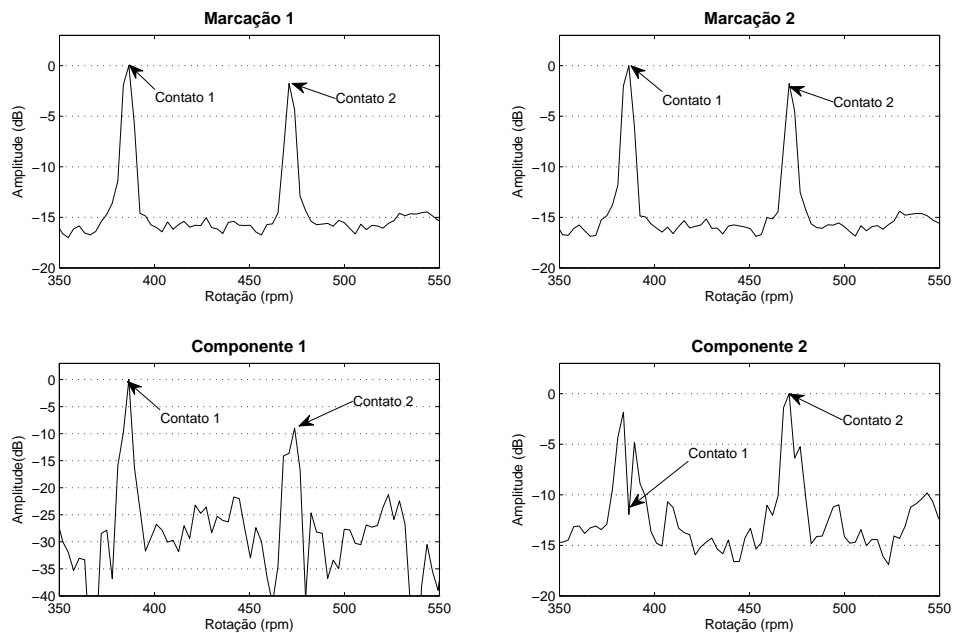


Figura 6.5: Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 5 dB.

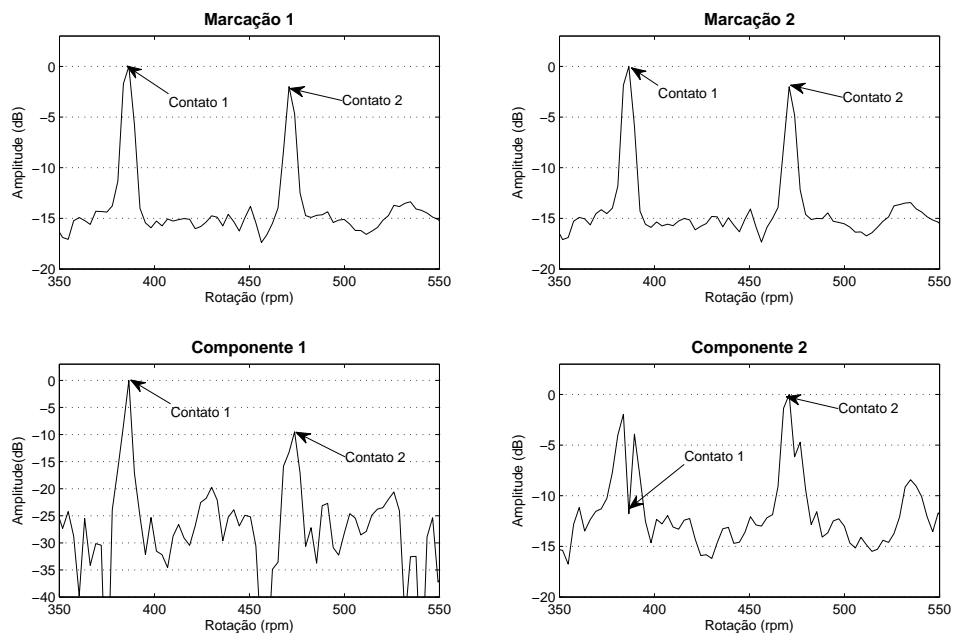


Figura 6.6: Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 10 dB.

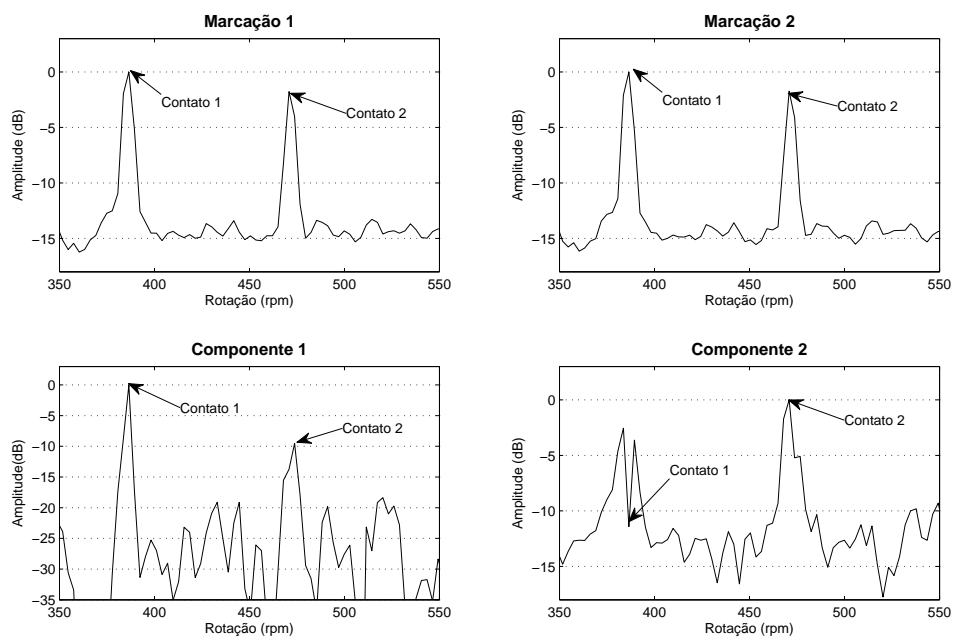


Figura 6.7: Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 15 dB.

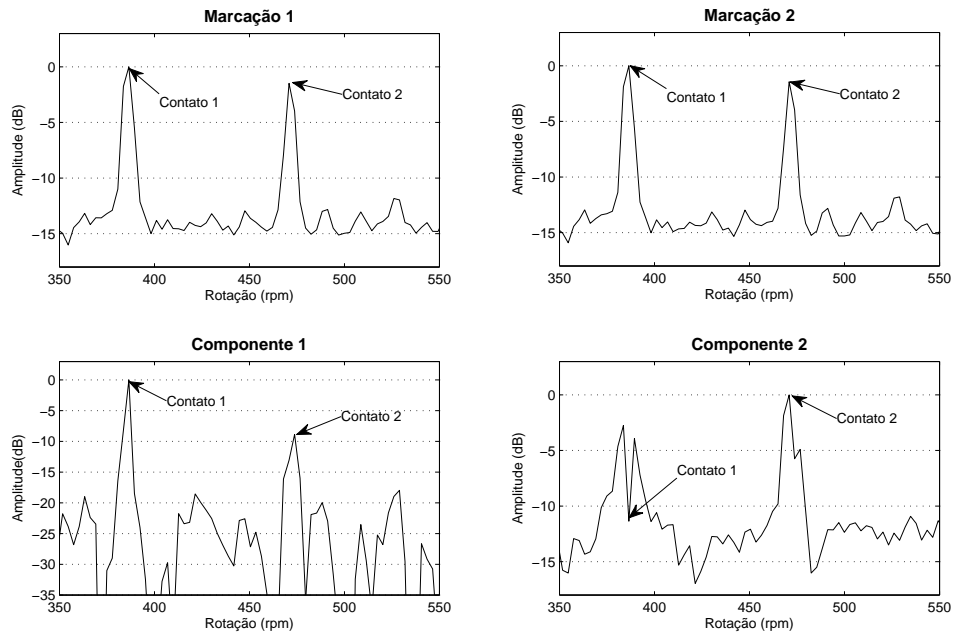


Figura 6.8: Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 20 dB.

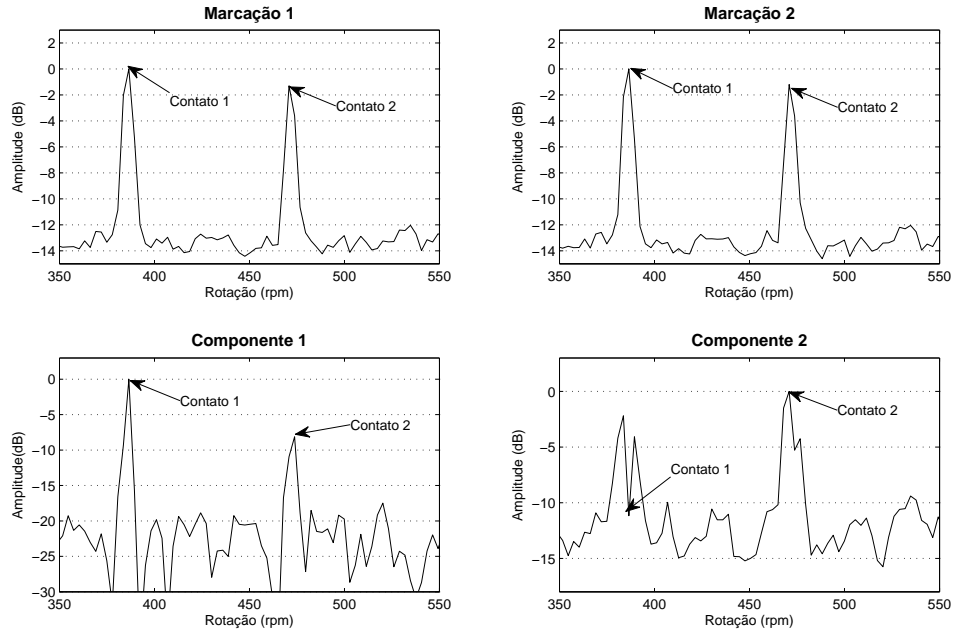


Figura 6.9: Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 25 dB.

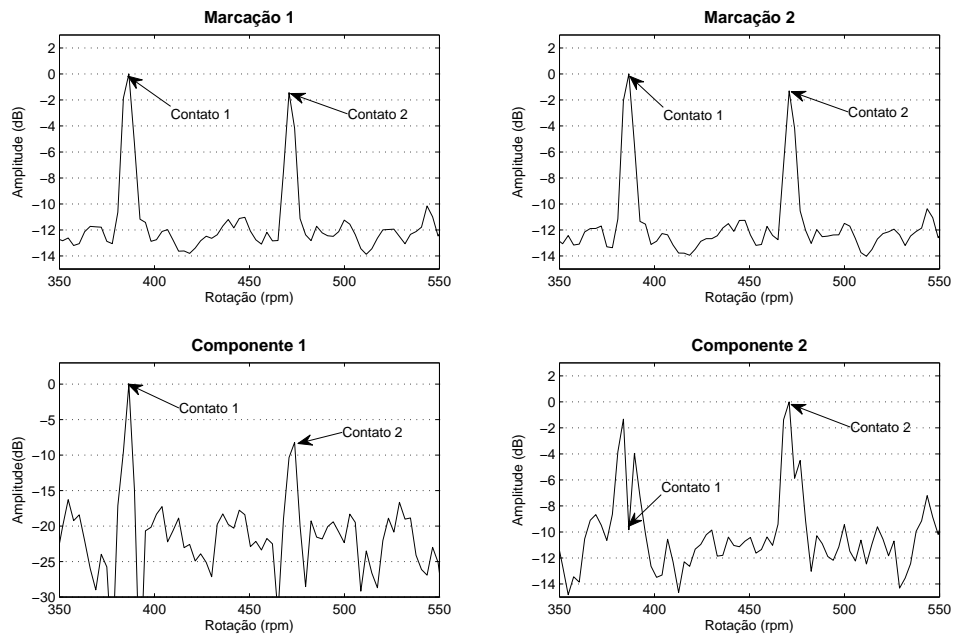


Figura 6.10: Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 30 dB.

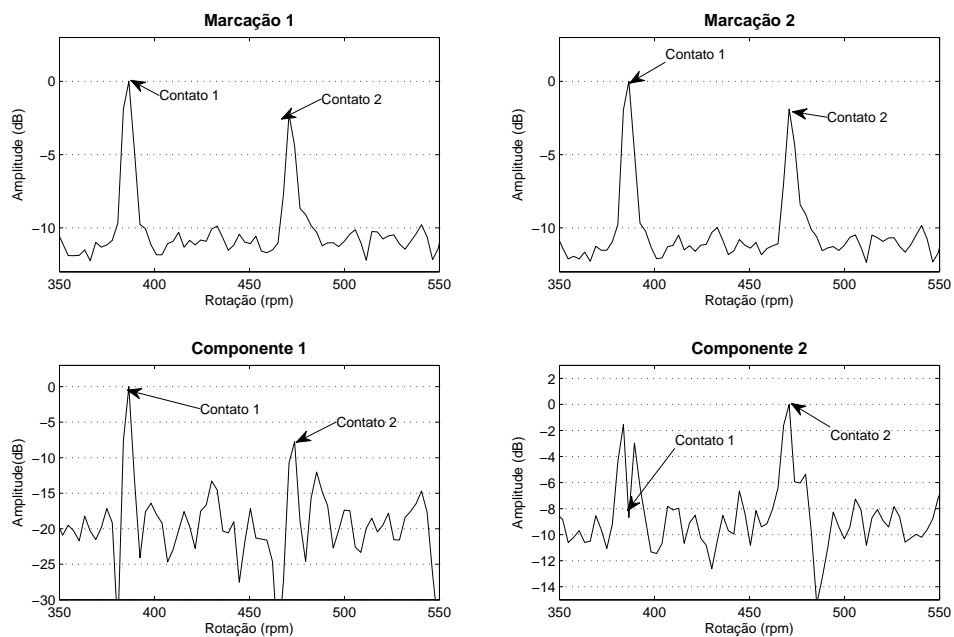


Figura 6.11: Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 35 dB.

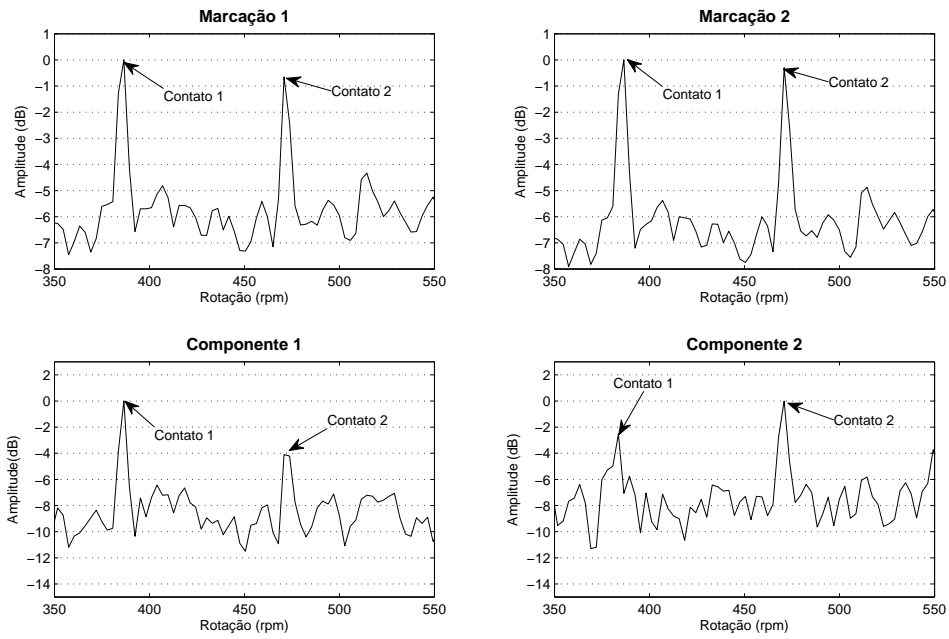


Figura 6.12: Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 40 dB.

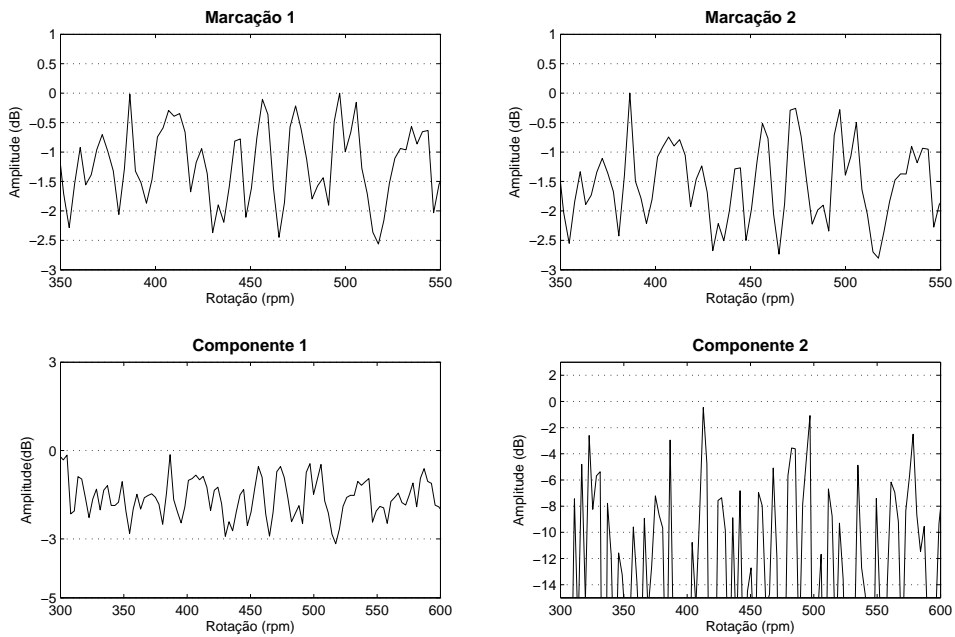


Figura 6.13: Espectro das marcações no domínio do tempo usando algoritmo JADE com ruído ambiente a 45 dB.

A figura 6.14 mostra a relação sinal-interferência (SIR) entre os contatos nas marcações e nos componentes gerados pelo algoritmo JADE. O eixo "x" da figura representa a variação da amplitude do ruído ambiente para simular um pior cenário. O eixo "y" apresenta a relação sinal-interferência entre os contatos, sendo que essa relação é feita tendo como referência o contato principal da marcação ou do componente analisado. Esse gráfico mostra que o algoritmo JADE de ICA consegue reduzir os efeitos da interferência cruzada após a execução da análise DEMON do sistema de sonar passivo. O algoritmo é utilizado após a análise DEMON. Com isso, quando a DEMON não consegue identificar os contatos, como ocorre na figura 6.13, o algoritmo JADE não consegue reduzir a interferência cruzada. A tabela 6.1 mostra os valores de SIR obtidos de acordo com a variação da amplitude do ruído ambiente para as marcações e os componentes do algoritmo JADE.




Figura 6.14: Relação sinal-interferência nas marcações e nos componentes do algoritmo JADE.

A figura 6.15 mostra a relação sinal-ruído (SNR) entre os contatos nas marcações e nos componentes gerados pelo algoritmo JADE. Percebe-se que nessa relação há uma melhoria no componente 1 e no componente 2 a SNR fica pior ou igual à SNR das marcações quando são processadas apenas pela DEMON. Esse comportamento

Ruído Ambiente	Sem Ruído	0	5	10	15
Marcação 1	1.707	1.734	1.754	1.988	1.769
Marcação 2	1.953	1.779	1.763	2.005	1.726
Componente 1	17.65	8.293	8.963	9.505	9.511
Componente 2	15.62	12.16	11.94	11.77	11.42
Ruído Ambiente	20	25	30	35	40
Marcação 1	1.476	1.291	1.439	2.255	0.6514
Marcação 2	1.429	1.196	1.304	1.888	0.297
Componente 1	8.86	8.116	8.217	7.739	4.212
Componente 2	11.36	11.17	9.835	8.681	2.526

Tabela 6.1: Tabela dos valores das marcações e dos componentes do algoritmo JADE para relação sinal-interferência.




Figura 6.15: Relação sinal-ruído nas marcações e nos componentes do algoritmo JADE.

ocorre pois o algoritmo JADE executa a análise de componentes independentes sem considerar o ruído em seus cálculos. À medida em que se aumenta a potência desse ruído, aumenta sua influência na etapa de branqueamento do sinal, tornando-

Ruído Ambiente	Sem Ruído	0	5	10	15
Marcação 1	22.56	16.16	16.02	15.35	14.44
Marcação 2	22.88	16.06	15.76	15.52	14.32
Componente 1	41.29	36.54	31.72	30.45	29.11
Componente 2	20.03	13.28	14.46	13.12	12.64
Ruído Ambiente	20	25	30	35	40
Marcação 1	14.03	12.98	12.48	10.92	6.038
Marcação 2	13.83	13.08	12.67	11.13	6.549
Componente 1	27.16	25.02	23.04	22.78	7.797
Componente 2	12.08	12.72	12.18	11.45	7.53

Tabela 6.2: Tabela dos valores das marcações e dos componentes do algoritmo JADE para relação sinal-ruído.

a inconsistente. A tabela 6.2 mostra os valores de SNR obtidos de acordo com a variação da amplitude do ruído ambiente para as marcações e os componentes do algoritmo JADE.

### 6.1.2 Algoritmo FastICA

Para o algoritmo FastICA foram aplicados os mesmos procedimentos anteriores. A figura 6.16 apresenta o comparativo entre a análise DEMON e a FastICA sem a presença do ruído ambiente simulado. O algoritmo FastICA consegue uma melhora na relação sinal-interferência entre os contatos de 20 dB em comparação com a análise DEMON.

As figuras de 6.17 a 6.26 mostram os espectros das marcações processadas pela análise DEMON e dos componentes processados pelo algoritmo FastICA após a análise DEMON com adição da simulação do ruído ambiente, a mesma utilizada para o caso do algoritmo JADE. A amplitude do ruído está sendo incrementada de 5 em 5 dB. Percebe-se pelos gráficos que o algoritmo FastICA melhora a SIR até o ponto em que a análise DEMON consegue separar os contatos do ruído ambiente. Quando o ruído ambiente tem a amplitude de 45 dB, figura 6.26, o algoritmo FastICA não consegue separar os contatos.



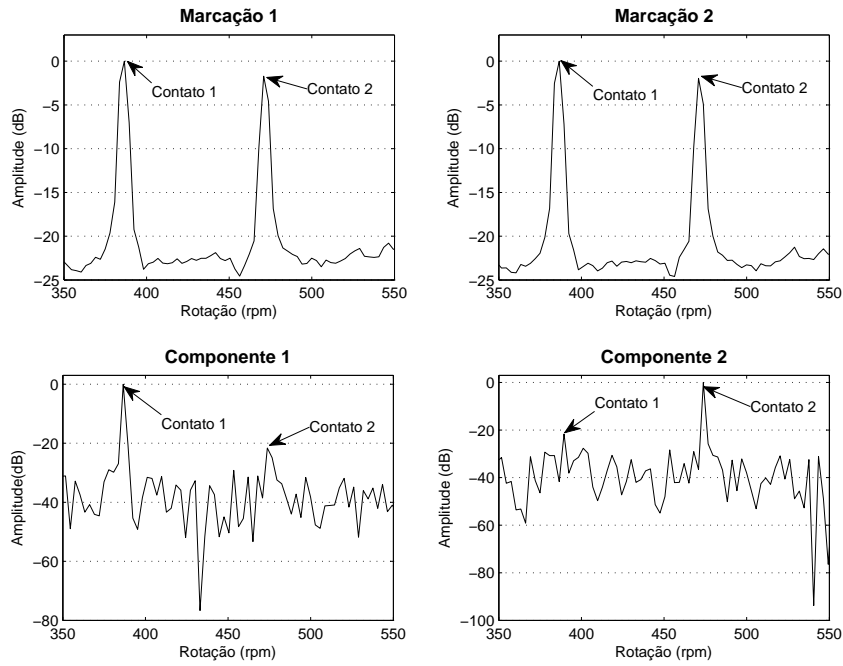


Figura 6.16: Espectro das marcações no domínio do tempo usando algoritmo FastICA.

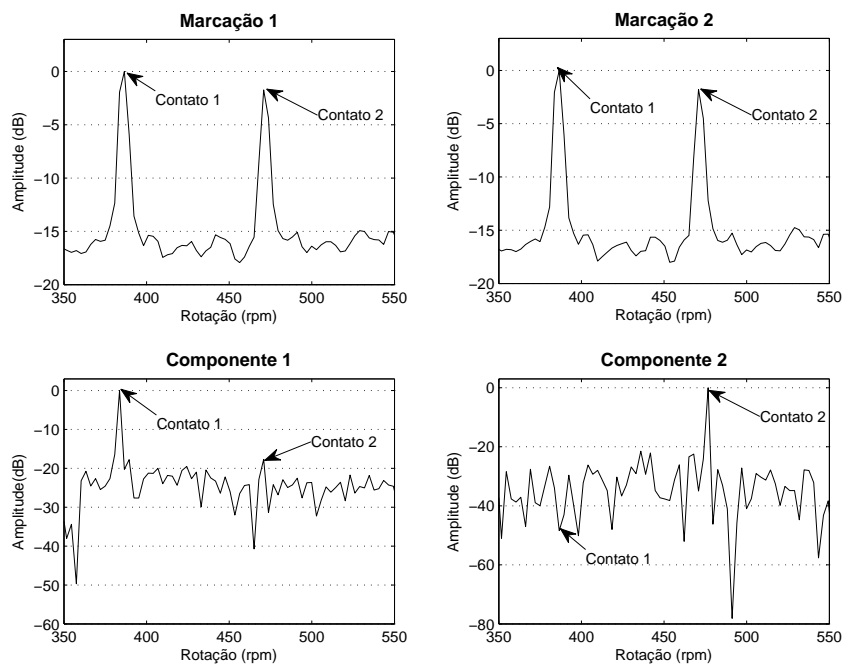


Figura 6.17: Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 0 dB.




Figura 6.18: Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 5 dB.




Figura 6.19: Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 10 dB.

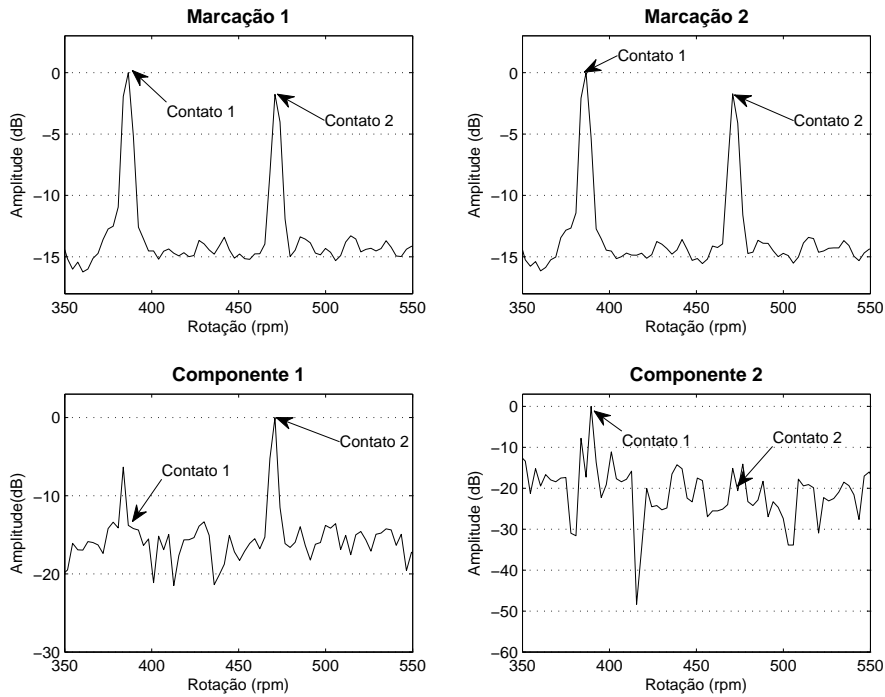


Figura 6.20: Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 15 dB.

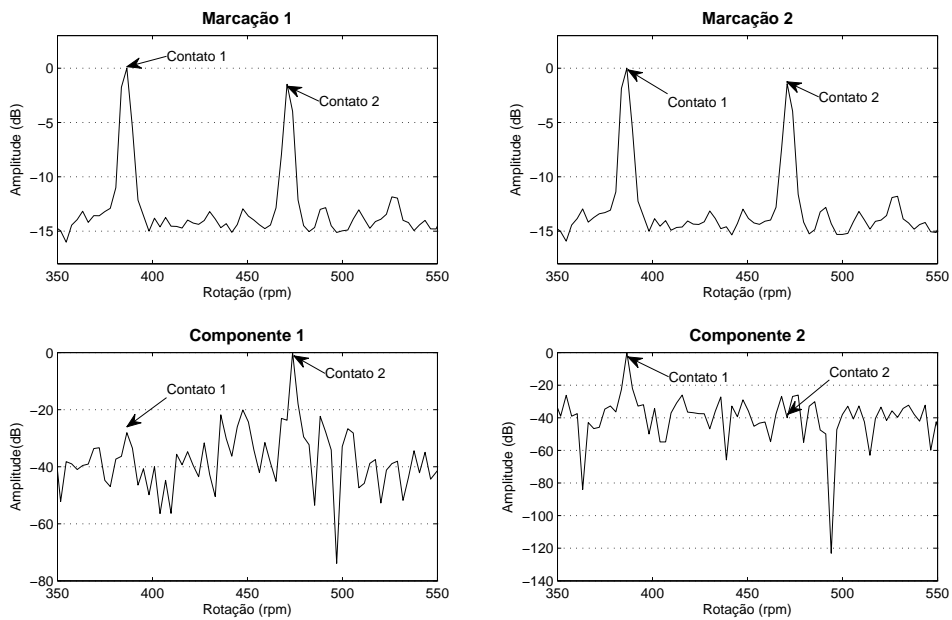


Figura 6.21: Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 20 dB.

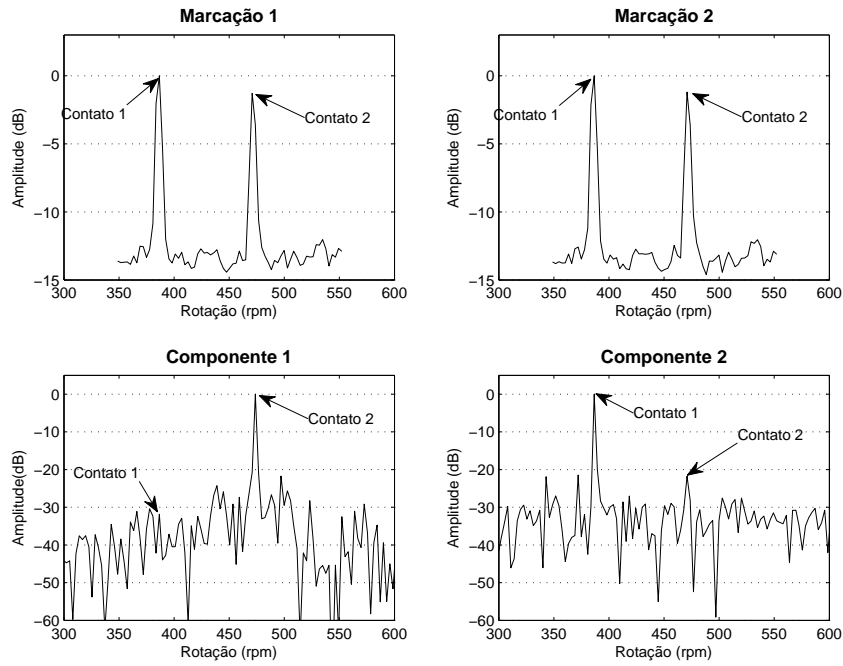


Figura 6.22: Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 25 dB.

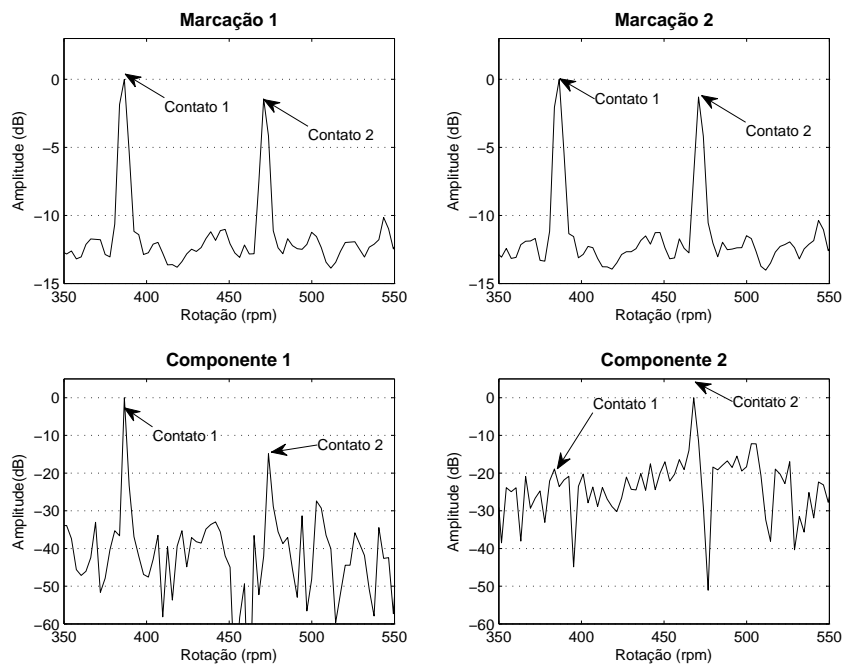


Figura 6.23: Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 30 dB.

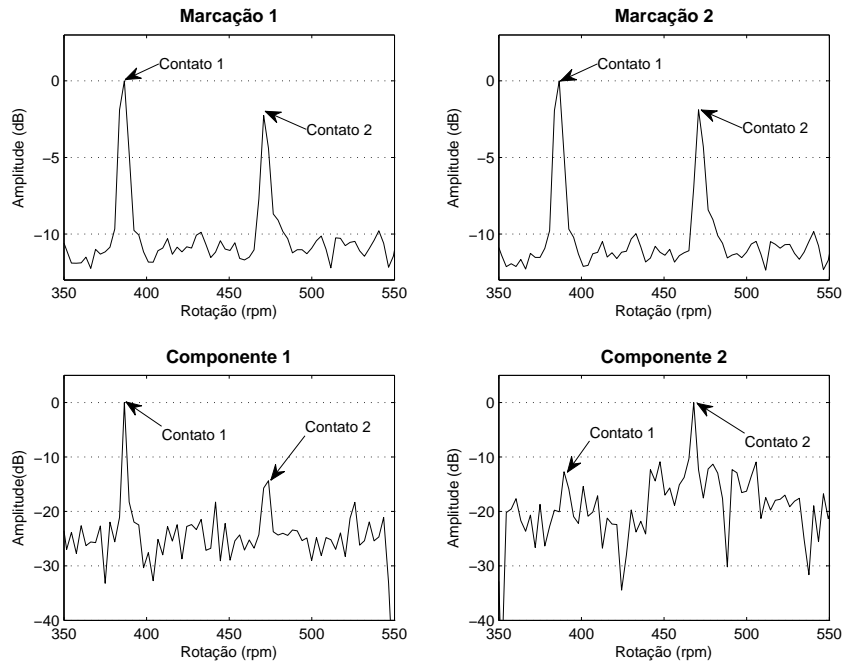


Figura 6.24: Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 35 dB.

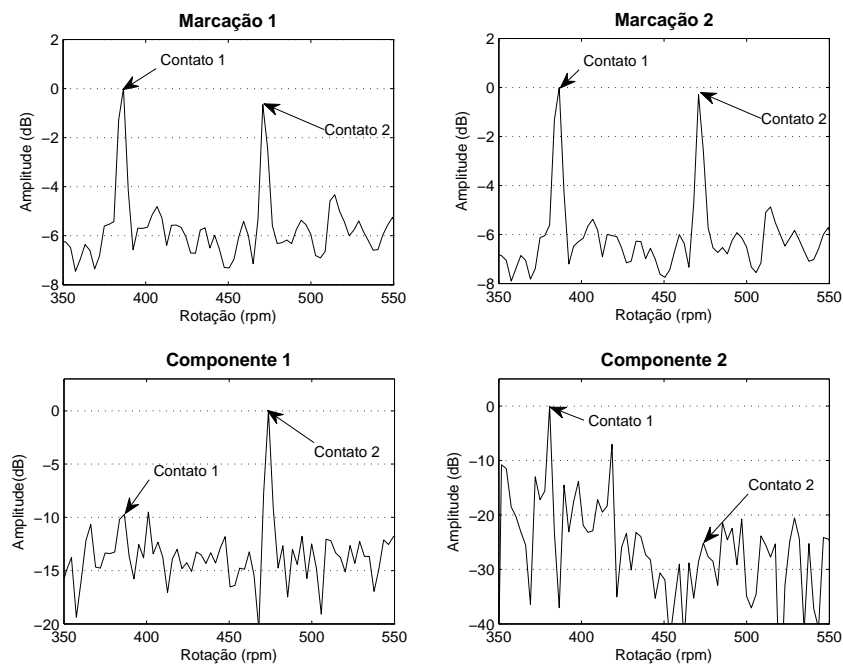


Figura 6.25: Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 40 dB.

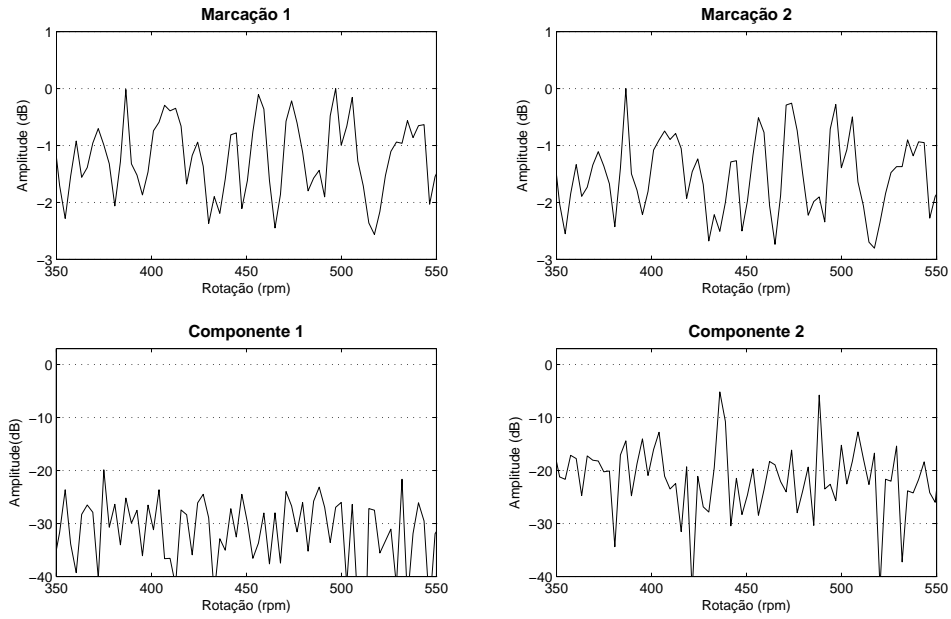


Figura 6.26: Espectro das marcações no domínio do tempo usando algoritmo FastICA com ruído ambiente a 45 dB.




Figura 6.27: Relação sinal-interferência nas marcações e nos componentes do algoritmo FastICA.

A figura 6.27 mostra a relação SIR entre os contatos nas marcações e nos componentes gerados pelo algoritmo FastICA. A legenda é a mesma utilizada na figura 6.14. O gráfico mostra que o algoritmo FastICA consegue reduzir os efeitos da interferência cruzada após a execução da análise DEMON do sistema de sonar passivo. Caso a DEMON não consiga identificar os contatos, como ocorre na figura 6.26, então o algoritmo FastICA não consegue reduzir a interferência cruzada. O algoritmo FastICA trabalha com ponto fixo, isto é, centraliza em um determinado ponto e executa as iterações para localizar os componentes independentes. Por isso, foram feitas sucessivas simulações até encontrar os pontos de iterações com resultados satisfatórios. A tabela 6.3 mostra os valores de SIR obtidos de acordo com a variação da amplitude do ruído ambiente para as marcações e os componentes do algoritmo FastICA.

Ruído Ambiente	Sem Ruído	0	5	10	15
Marcação 1	1.707	1.734	1.754	1.988	1.769
Marcação 2	1.953	1.779	1.763	2.005	1.726
Componente 1	21.61	17.70	37.81	24.07	13.79
Componente 2	21.88	48.4	48.62	26.12	20.58
Ruído Ambiente	20	25	30	35	40
Marcação 1	1.476	1.291	1.439	2.255	0.6514
Marcação 2	1.429	1.196	1.304	1.888	0.297
Componente 1	28.09	31.85	14.86	14.36	9.733
Componente 2	39.99	21.74	23.59	12.72	25.14

Tabela 6.3: Tabela dos valores das marcações e dos componentes do algoritmo FastICA para relação sinal-interferência.

A figura 6.28 mostra a SNR entre os contatos nas marcações e nos componentes gerados pelo algoritmo FastICA. Assim como o algoritmo JADE, o FastICA faz a análise de componentes independentes desconsiderando a influência do ruído em seus cálculos. Como explicado anteriormente, o efeito do ruído nesse tipo de análise é prejudicial à etapa de branqueamento do sinal. O gráfico da figura 6.28 mostra que o algoritmo FastICA proporciona uma melhora na SNR com relação à análise feita apenas pelo sonar passivo. Isso ocorre pelo fato do algoritmo ser de ponto fixo,

ou seja, escolhendo-se um ponto ótimo, as iterações são feitas próximas a esse ponto fazendo com que os dados mais distantes sejam descartados e com isso a influência do ruído nesses dados é reduzida. Pode-se observar que a SNR diminui à medida em que a potência do ruído ambiente aumenta. A tabela 6.4 mostra os valores de SNR obtidos de acordo com a variação da amplitude do ruído ambiente para as marcações e os componentes do algoritmo FastICA.




Figura 6.28: Relação sinal-ruído nas marcações e nos componentes do algoritmo FastICA.

### 6.1.3 Algoritmo GI-ICA

O mesmo sistema foi analisado utilizando algoritmo GI-ICA . A figura 6.29 apresenta o comparativo entre a análise DEMON e a GI-ICA sem a presença do ruído ambiente simulado. O algoritmo GI-ICA apresenta uma leve melhora na SIR de 4 dB em comparação com a DEMON.

As figuras 6.30 a 6.39 mostram os espectros das marcações analisados pela DEMON do sistema sonar passivo e dos componentes analisados pelo algoritmo GI-ICA



Ruído Ambiente	Sem Ruído	0	5	10	15
Marcação 1	22.56	16.16	16.02	15.35	14.44
Marcação 2	22.88	16.06	15.76	15.52	14.32
Componente 1	44.96	29.92	46.77	40.72	17.18
Componente 2	45.50	41.01	47.14	42.18	22.28
Ruído Ambiente	20	25	30	35	40
Marcação 1	14.03	12.98	12.48	10.92	6.038
Marcação 2	13.83	13.08	12.67	11.13	6.549
Componente 1	43.50	44.19	46.89	25.12	13.24
Componente 2	46.75	35.78	30.21	22.41	29.26

Tabela 6.4: Tabela dos valores das marcações e dos componentes do algoritmo FastICA para relação sinal-ruído.

após a DEMON com a adição do ruído ambiente simulado. O processo de simulação do ruído utilizado nessa parte do trabalho é o mesmo do que foi feito para os algoritmos anteriores. Os gráficos apresentados mostram que o algoritmo GI-ICA melhora levemente a interferência entre os sinais. Em relação ao ruído, o algoritmo GI-ICA entrega uma melhoria de 10 dB para quase todas as variações de potência do sinal do ruído. O algoritmo GI-ICA encontra dificuldades para identificar os contatos na análise observada figura 6.39, quando a análise DEMON não consegue mais diferenciar os sinais dos contatos devido a influência do ruído.

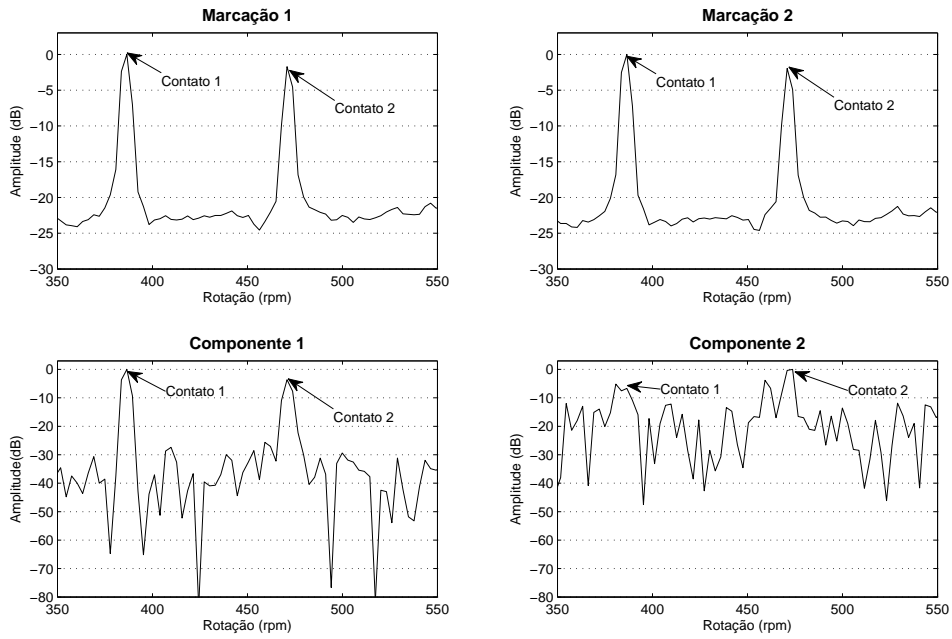


Figura 6.29: Espectro das marcações no domínio do tempo usando algoritmo GI-ICA.

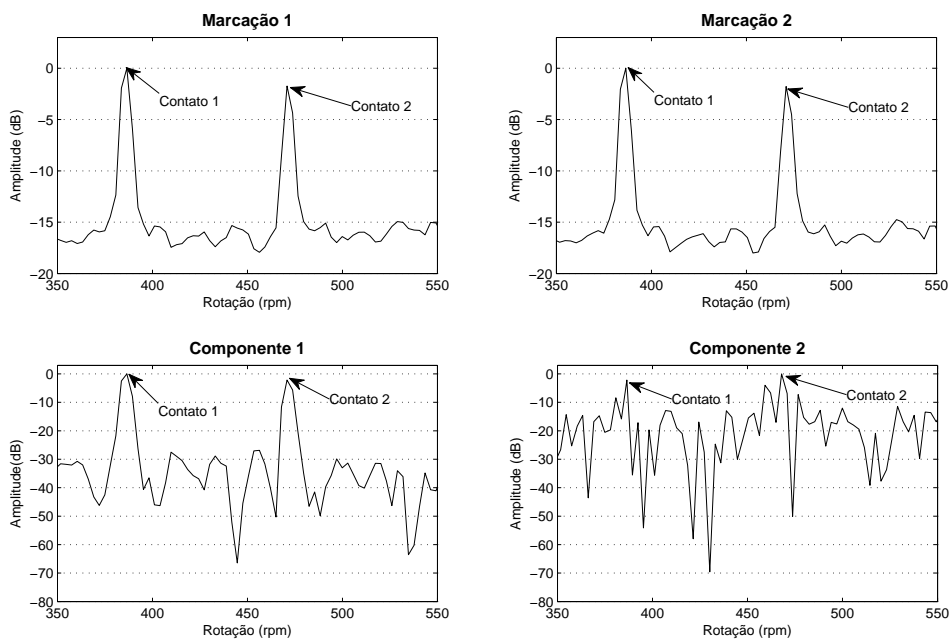


Figura 6.30: Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 0 dB.

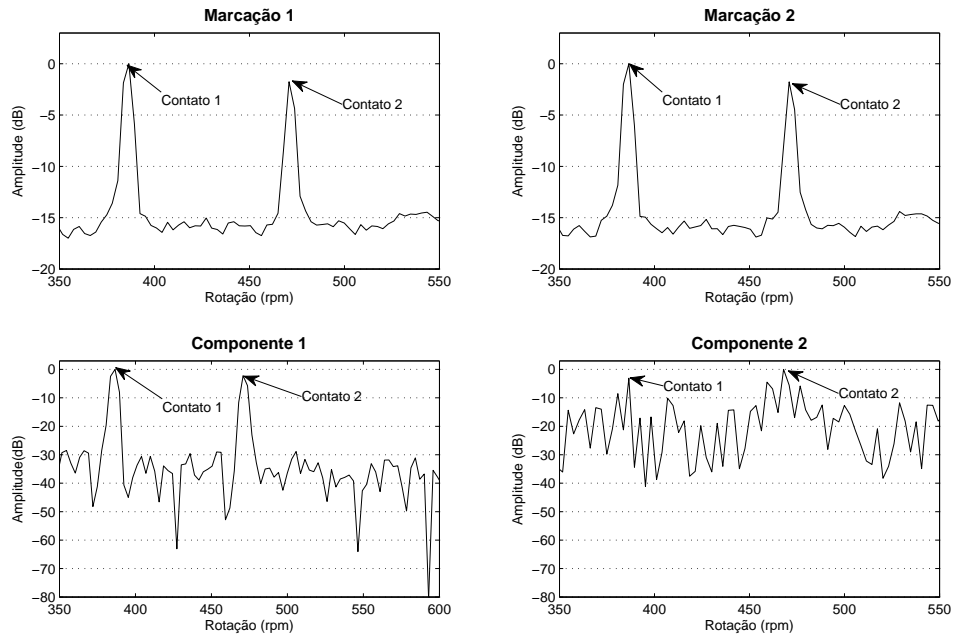


Figura 6.31: Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 5 dB.

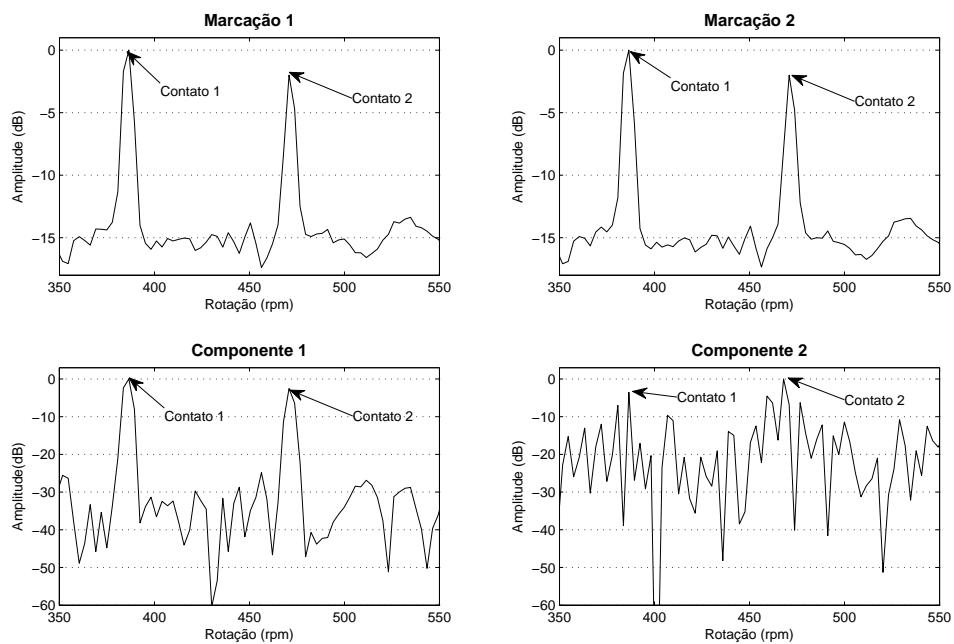


Figura 6.32: Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 10 dB.

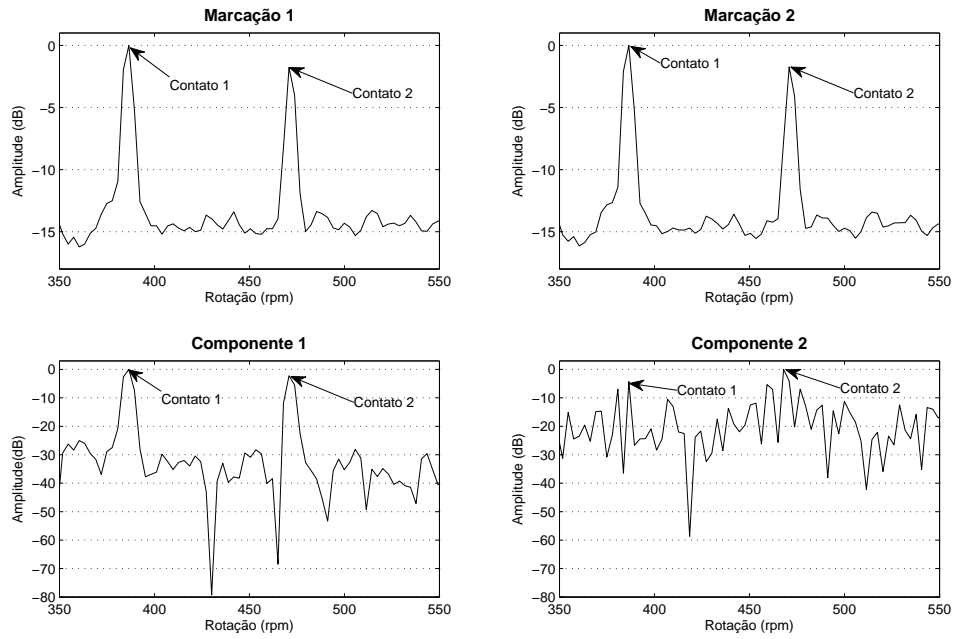


Figura 6.33: Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 15 dB.

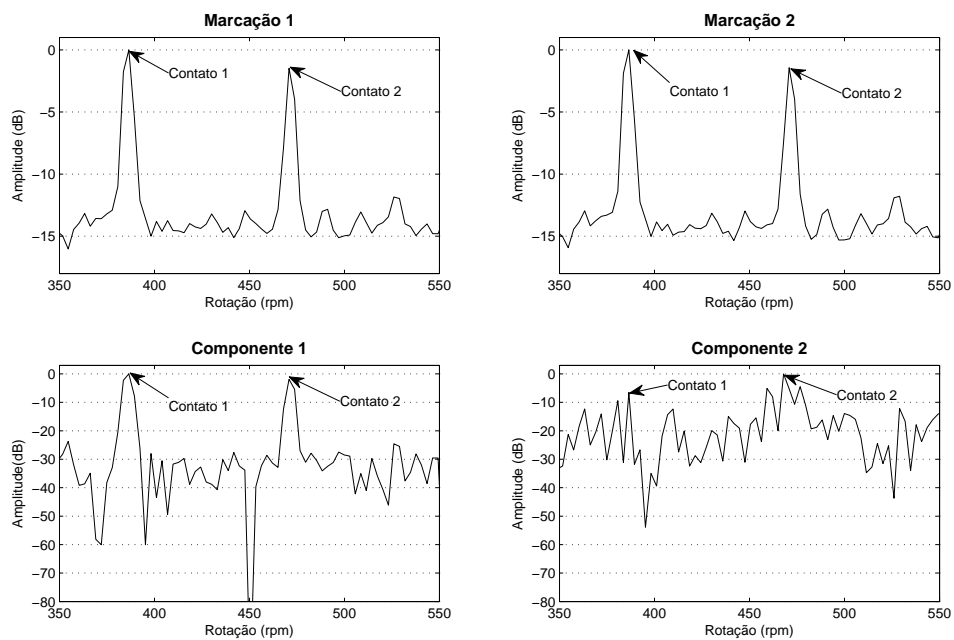


Figura 6.34: Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 20 dB.

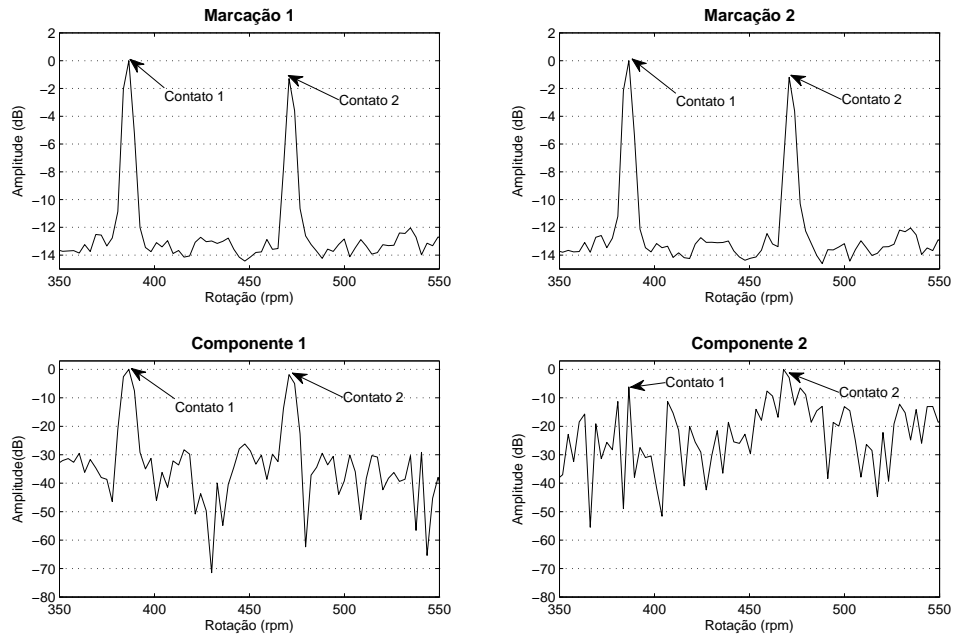


Figura 6.35: Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 25 dB.

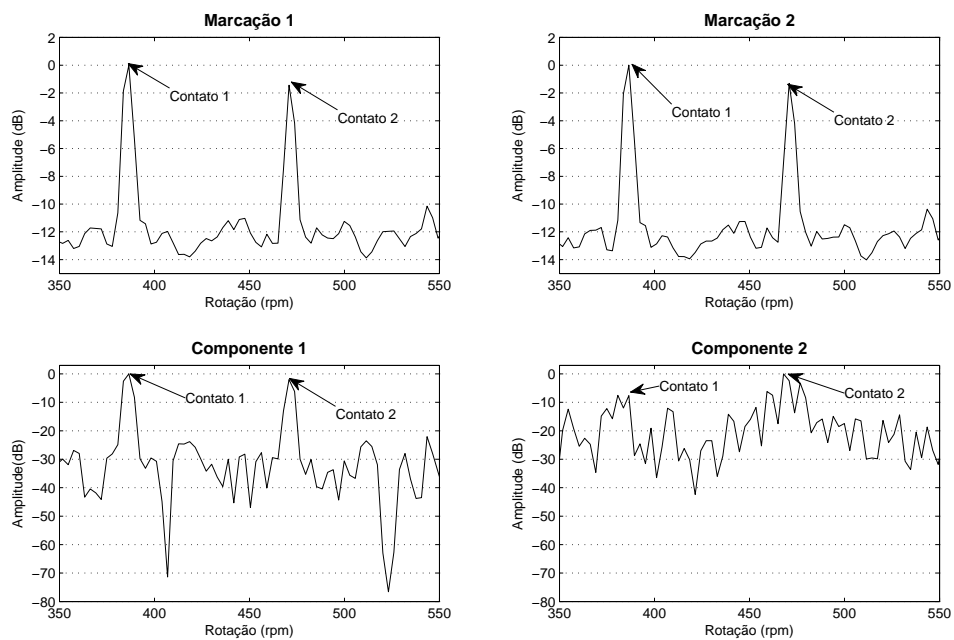


Figura 6.36: Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 30 dB.

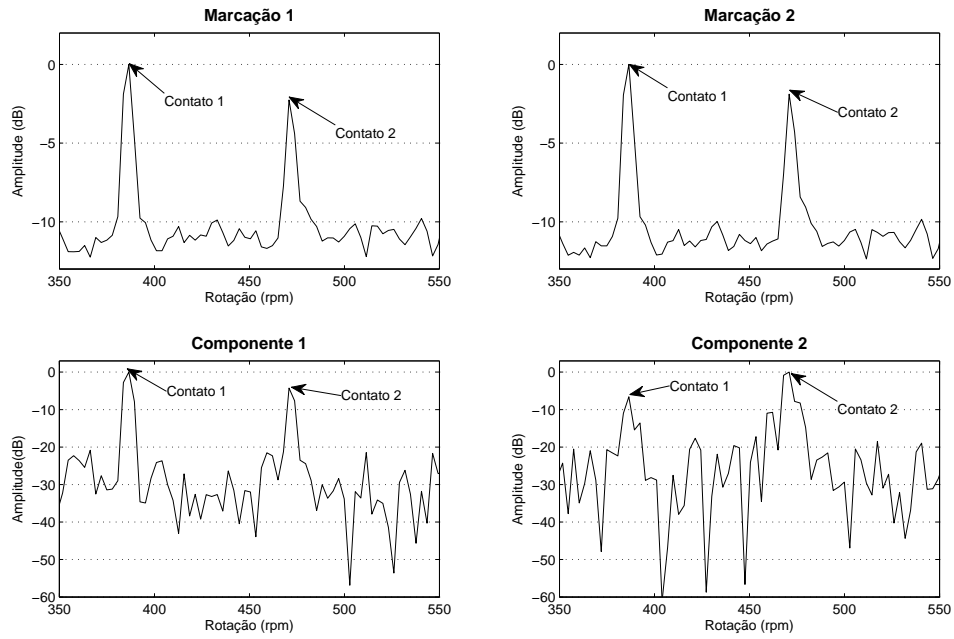


Figura 6.37: Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 35 dB.

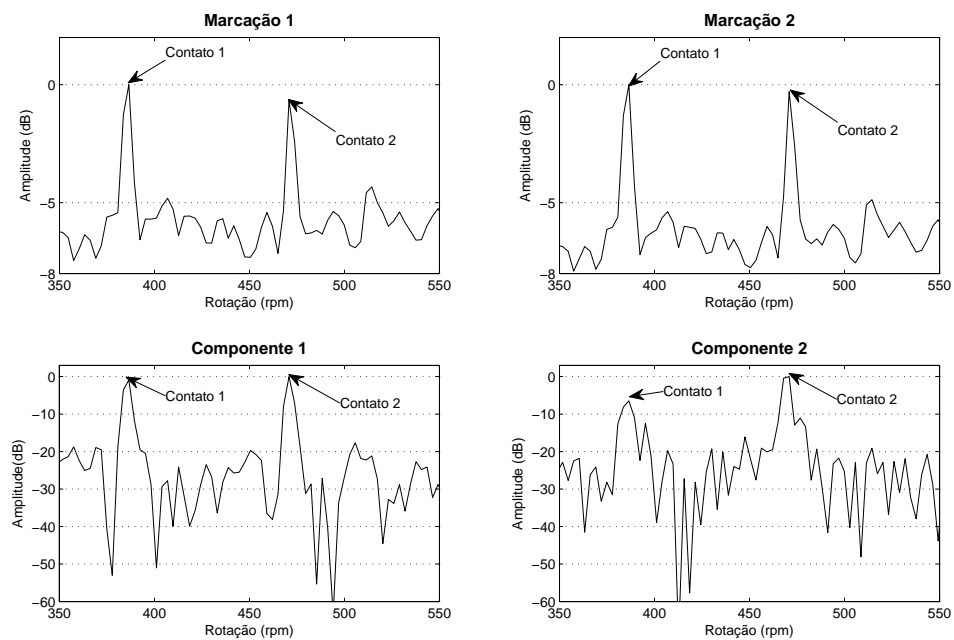


Figura 6.38: Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 40 dB.

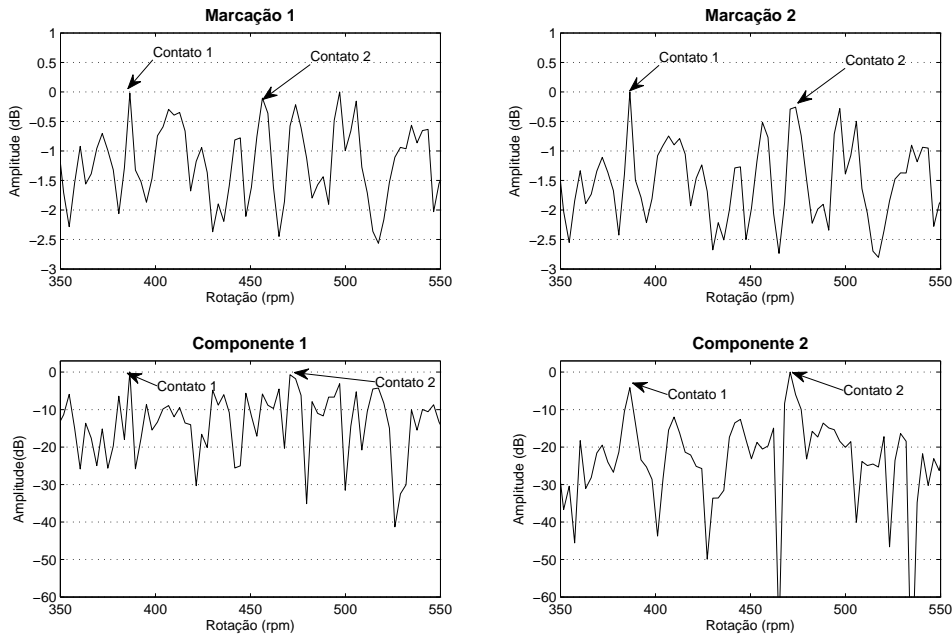


Figura 6.39: Espectro das marcações no domínio do tempo usando algoritmo GI-ICA com ruído ambiente a 45 dB.

A figura 6.40 mostra a relação SIR entre os contatos nas marcações e nos componentes gerados pelo algoritmo GI-ICA. A legenda é a mesma utilizada na figura 6.14. Esse gráfico mostra que o algoritmo GI-ICA reduz os efeitos da interferência cruzada após a execução da análise DEMON do sistema de sonar passivo. Essa redução não chega a ser tão significativa quando comparada com as reduções obtidas pelos outros dois algoritmos. No entanto, o algoritmo GI-ICA consegue identificar os contatos no caso onde o ruído está mais acentuado, apresentado na figura 6.39. O algoritmo GI-ICA tem a sua segunda etapa realizada de forma semelhante ao FastICA, trabalhando com ponto fixo. Portanto, várias simulações foram executadas para encontrar pontos de iterações com resultados satisfatórios. A tabela 6.5 mostra os valores de SIR obtidos de acordo com a variação da amplitude do ruído ambiente para as marcações e os componentes do algoritmo GI-ICA.

A figura 6.41 apresenta a SNR encontrada na análise do algoritmo GI-ICA. Observa-se que a SNR dos componentes é melhor do que a das marcações. Isso ocorre pois o algoritmo GI-ICA considera o ruído em seus cálculos buscando encontrar os componentes independentes livres da influência do ruído.




Figura 6.40: Relação sinal-interferência nas marcações e nos componentes do algoritmo GI-ICA.

Ruído Ambiente	Sem Ruído	0	5	10	15
Marcação 1	1.707	1.734	1.754	1.988	1.769
Marcação 2	1.953	1.779	1.763	2.005	1.726
Componente 1	3.626	2.158	2.183	2.526	2.236
Componente 2	6.682	2.145	3.078	3.535	4.286
Ruído Ambiente	20	25	30	35	40
Marcação 1	1.476	1.291	1.439	2.255	0.6514
Marcação 2	1.429	1.196	1.304	1.888	0.297
Componente 1	1.923	1.816	2.000	4.244	0.8785
Componente 2	6.526	6.132	7.623	6.4810	25.14

Tabela 6.5: Tabela dos valores das marcações e dos componentes do algoritmo GI-ICA para relação sinal-interferência.






Figura 6.41: Relação sinal-ruído nas marcações e nos componentes do algoritmo GI-ICA.

Ruído Ambiente	Sem Ruído	0	5	10	15
Marcação 1	22.56	16.16	16.02	15.35	14.44
Marcação 2	22.88	16.06	15.76	15.52	14.32
Componente 1	39.54	40.20	40.16	37.93	37.80
Componente 2	26.46	31.28	30.94	30.47	25.64
Ruído Ambiente	20	25	30	35	40
Marcação 1	14.03	12.98	12.48	10.92	6.038
Marcação 2	13.83	13.08	12.67	11.13	6.549
Componente 1	40.66	39.95	39.59	33.18	32.25
Componente 2	27.46	29.08	27.04	30.14	32.38

Tabela 6.6: Tabela dos valores das marcações e dos componentes do algoritmo GI-ICA para relação sinal-ruído.

# Capítulo 7

## Conclusões e Perspectivas

O sistema de sonar passivo é de suma importância para a operação de submarinos. Constantemente, ele está sujeito a interferências de fontes proveniente de diferentes direções de interesse. Outro fator importante a ser considerado é a interferência causada por diversas fontes de sinais no meio, caracterizando o chamado ruído ambiente. A utilização da separação cega de fontes no processamento de sinais é um dos métodos que pode ser utilizado para reduzir esses tipos de interferência. O presente trabalho utilizou a análise de componentes independentes (ICA) para realizar a separação cega de fontes.

A melhora no desempenho dos sistemas de sonar passivo pode ser realizada com a inserção de novas técnicas. A separação cega de fontes aplicada no sistema de sonar passivo tem como objetivo melhorar a resolução dos sinais. Com isso, o operador sonar pode contar com uma ferramenta mais precisa, facilitando seu trabalho de identificar e classificar os contatos.

Este trabalho baseou-se nos estudos realizados em [1] para verificar o comportamento da separação cega quando existe a influência do ruído ambiente. Para a separação, foram utilizados três algoritmos de ICA, o JADE, o FastICA e o GI-ICA. Todos foram testados da mesma forma, aumentando-se a potência do ruído ambiente. Para tal análise, os dados utilizados foram simulados e disponibilizados pela Marinha do Brasil excetuando-se o ruído ambiente, que foi desenvolvido especificamente para testar estes dados no sistema de sonar passivo.

A avaliação dos algoritmos foi feita através de medidas de desempenho. Chegou-se a conclusão de que os algoritmos ajudaram a reduzir a interferência entre os

contatos. No entanto, no caso da interferência causada pelo ruído ambiente os algoritmos JADE e FastICA apresentam inconsistência em seus resultados o que já era esperado visto que esses algoritmos não consideram o ruído ambiente em seus cálculos. Já o algoritmo GI-ICA apresenta um resultado mais consistente para a SNR tendo em vista que esse algoritmo foi projetado para calcular componentes independentes considerando a influência do ruído ambiente em seus cálculos.

Pela evolução gráfica, percebeu-se que o algoritmo FastICA obteve uma melhor performance na análise da SIR. Seus resultados foram gerados a partir de sucessivas tentativas em cada etapa da simulação com o ruído ambiente para encontrar um ponto ótimo para a iteração.

As perspectivas de trabalhos futuros apontam para a necessidade de se testar mais algoritmos que considerem o ruído em seus cálculos. Além disso, no caso dos algoritmos que buscam o ponto ótimo, como o FastICA e o GI-ICA, uma boa forma de se fazer mais iterações para gerar dados mais precisos é utilizar o treinamento de redes neurais para se achar o ponto ótimo.

A análise de componentes independentes utilizada para a redução da influência do ruído ambiente em sistema de sonar passivo demonstrou ser aplicável como ferramenta de auxílio ao operador sonar. Como próxima etapa, propõe-se a utilização de melhores modelos de análise de ruído ambiente.

# Referências Bibliográficas

- [1] N. N. de Moura, *Detecção e Classificação de Sinais de Sonar Passivo usando métodos de Separação Cega de Fontes*. PhD thesis, COPPE/UFRJ, 2013.
- [2] P. Etter, *Underwater Acoustic Modeling: Principles, techniques and applications, Second Edition*. Taylor & Francis, 1995.
- [3] A. Waite, *Sonar for Practising Engineers*. Wiley, 2002.
- [4] R. Hodges, *Underwater Acoustics: Analysis, Design and Performance of Sonar*. Wiley, 2011.
- [5] R. Buel, *In Irons: Britain's Naval Supremacy and the American Revolutionary Economy*. Yale University Press, 1998.
- [6] W. Dudley, *Splintering the Wooden Wall: The British Blockade of the United States, 1812-1815*. Naval Institute Press, 2003.
- [7] J. Keegan, *The Price of Admiralty: The Evolution of Naval Warfare*. A Penguin book : History, Penguin, 1990.
- [8] A. Bole and W. Dineley, *Radar and ARPA Manual*. Elsevier Science, 2016.
- [9] R. Nielsen, *Sonar Signal Processing*. Acoustics Library, Artech House, 1991.
- [10] W. S. Filho, J. M. de Seixas, and L. P. Caloba, "Principal component analysis for classifying passive sonar signals," *IEEE International Symposium on Circuits and Systems*, 2001.
- [11] J. M. de Seixas, D. O. Damazio, and W. S. Filho, "Wavelet transform as a preprocessing method for neural classification of passive sonar signals,"

*International Conference on Electronic, Circuits and Systems*, pp. 83–86, 2001.

- [12] H. Peyvandi, B. Fazaefar, and H. Amindavar, “Determining class of underwater vehicles in passive sonar using hidden markov with hausdorff similarity measure,” *Proceedings of 1998 International Symposium on Underwater Technology*, pp. 258–262, 1998.
- [13] R. C. Torres, J. M. de Seixas, and W. S. Filho, “Classificação de sinais de sonar utilizando componentes principais não-lineares,” *Learning and nonlinear models*, vol. 1, no. 4, pp. 208–222, 2004.
- [14] D. Johnson and D. Dudgeon, *Array Signal Processing: Concepts and Techniques*. Prentice-Hall signal processing series, P T R Prentice Hall, 1993.
- [15] E. Oja, A. Hyvärinen, and J. Karhunen, *Independent Component Analysis*. John Wiley and Sons Ltd., 2001.
- [16] P. Georgiev, F. Theis, A. Cichocki, and H. Bakardjian, *Sparse Component Analysis: a New Tool for Data Mining*, pp. 91–116. Boston, MA: Springer US, 2007.
- [17] A. F. Tygel, *Métodos de Fatoração de Matrizes Não Negativas para Separação de Sinais Musicais*. PhD thesis, COPPE/UFRJ, 2015.
- [18] X. Che, I. Wells, G. Dickers, P. Kear, and X. Gong, “Re-evaluation of rf electromagnetic communication in underwater sensor networks,” *IEEE Communications Magazine*, vol. 48, pp. 143–151, December 2010.
- [19] U. Chakraborty, T. Tewary, and R. P. Chatterjee, “Exploiting the loss-frequency relationship using rf communication in underwater communication networks,” in *Computers and Devices for Communication, 2009. CODEC 2009. 4th International Conference on*, pp. 1–4, Dec 2009.
- [20] S. T., “Autonomy in robots and other agents,” *Brain Cogn.*, vol. 34, June 1997 1997.

- [21] G. J. Tango, “Numerical models for vlf seismic-acoustic propagation prediction: a review,” *IEEE Journal of Oceanic Engineering*, vol. 13, pp. 198–214, Oct 1988.
- [22] H. Schmidt, “Numerical modeling in ocean seismo-acoustics,” in *OCEANS '91. Ocean Technologies and Opportunities in the Pacific for the 90's. Proceedings.*, vol. 1, pp. 84–92, Oct 1991.
- [23] A. Barkhatov, *Modeling of Sound Propagation in the Sea*. Springer US, 2013.
- [24] J. DeSanto and N. Bleistein, *Ocean acoustics. Topics in current physics*, Springer-Verlag, 1979.
- [25] H. Medwin and C. Clay, *Fundamentals of Acoustical Oceanography. Applications of Modern Acoustics*, Elsevier Science, 1997.
- [26] L. Brekhovskikh and Y. Lysanov, *Fundamentals of Ocean Acoustics*. Springer Series in Electronics and Photonics, Springer Berlin Heidelberg, 2013.
- [27] G. Wenz, “Acoustic ambient noise in the ocean: Spectra and sources,” *The Journal of the Acoustical Society of America*, vol. 34, no. 12, pp. 1936–1956, 1962.
- [28] S. W., K. R., and M. K., *Ambient Noise Standards for Acoustic Modeling and Analysis*. Naval Underwater Systems Center, 1984.
- [29] U. of California (1868-1952). Division of War Research. Sonar Data Division, C. U. D. of War Research. Sonar Data Division, and C. Eckart, *Principles of Underwater Sound*. Summary technical report of the National Defense Research Committee: Summary technical report of Division 6, NDRC, Research Analysis Group, Committee on Undersea Warfare, National Research Council, 1946.
- [30] R. A. Wagstaff, *RANDI: Research Ambient Noise Directionality Model*. Undersea Surveillance and Ocean Sciences Department, 1973.
- [31] M. M., Z. R. M., and S. W. L., *An algorithm for beam noise prediction*. Naval Research Laboratory, 1979.

- [32] W. Fan, X. Zhang, and B. Jiang, “A new passive sonar bearing estimation algorithm combined with blind source separation,” in *Computational Science and Optimization (CSO), 2010 Third International Joint Conference on*, vol. 1, pp. 15–18, May 2010.
- [33] R. R. Ramos, “Redes neurais para monitoração de estacionariedade de sinais de sonar passivo,” Master’s thesis, COPPE/UFRJ, Rio de Janeiro, 2011.
- [34] L. A. Pflug, G. E. Ioup, J. W. Ioup, and P. Jackson, “Variability in higher order statistics of measured shallow-water shipping noise,” in *Higher-Order Statistics, 1997., Proceedings of the IEEE Signal Processing Workshop on*, pp. 400–404, Jul 1997.
- [35] W. S. Filho, *Classificação do Ruído Irrradiado por Navios usando Redes Neurais*. PhD thesis, COPPE/UFRJ, Rio de Janeiro, 2001.
- [36] W. Burdick, *Underwater Acoustic System Analysis*. Prentice Hall Signal Processing Series, Pearson Education Canada, 1984.
- [37] S. R. Silva, *Advances in Sonar Technology*. I-Tech Education and Publishing, 2009.
- [38] H. Krim and M. Viberg, “Two decades of array signal processing research: the parametric approach,” *IEEE Signal Processing Magazine*, vol. 13, pp. 67–94, Jul 1996.
- [39] R. Istepanian and M. Stojanovic, *Underwater Acoustic Digital Signal Processing and Communication Systems*. Springer US, 2013.
- [40] P. Diniz, E. da Silva, and S. Netto, *Digital Signal Processing: System Analysis and Design*. Cambridge University Press, 2010.
- [41] E. Brigham, *The Fast Fourier Transform and Its Applications*. Prentice-Hall Signal Processing Series: Advanced monographs, Prentice Hall, 1988.
- [42] W. A. Struzinski and E. D. Lowe, “The effect of improper normalization on the performance of an automated energy detector,” *The Journal of the Acoustical Society of America*, vol. 78, no. 3, pp. 936–941, 1985.

- [43] W. A. Struzinski and E. D. Lowe, “A performance comparison of four noise background normalization schemes proposed for signal detection systems,” *The Journal of the Acoustical Society of America*, vol. 76, no. 6, pp. 1738–1742, 1984.
- [44] H. Van Trees, *Detection, Estimation, and Modulation Theory*. Wiley, 2004.
- [45] R. Urick, *Principles of Underwater Sound for Engineers*. McGraw-Hill, 1967.
- [46] W. C. Knight, R. G. Pridham, and S. M. Kay, “Digital signal processing for sonar,” *Proceedings of the IEEE*, vol. 69, pp. 1451–1506, Nov 1981.
- [47] L. Marple and T. Brotherton, “Detection and classification of short duration underwater acoustic signals by prony’s method,” *International Conference on Acoustics, Speech, and Signal Processing*, vol. 2, pp. 1309–1312, 1991.
- [48] J.-F. Cardoso, “Blind signal separation: Statistical principles,” *Proceedings of the IEEE*, vol. 86, no. 10, pp. 2009–2025, 1998.
- [49] A. Hyvärinen and E. Oja, “Independent component analysis: Algorithms and applications,” *Neural Netw.*, vol. 13, pp. 411–430, may 2000.
- [50] N. N. de Moura, W. S. Filho, and J. M. Seixas, “Passive classification based on independent components,” *Proceedings of the Brazilian congress of neural networks*, pp. 1–5, 2007.
- [51] N. N. de Moura, W. S. Filho, and J. M. Seixas, “Independent component analysis for optimal passive sonar signal detection,” *Seventh International Conference on Intelligent Systems Design and Applications*, pp. 671–678, 2007.
- [52] S. Bonhomme and J.-M. Robin, “Consistent noisy independent component analysis,” *Journal of Econometrics*, vol. 149, no. 1, pp. 12 – 25, 2009.
- [53] E. Moulines, J. F. Cardoso, and E. Gassiat, “Maximum likelihood for blind separation and deconvolution of noisy signals using mixture models,” in *Acoustics, Speech, and Signal Processing, 1997. ICASSP-97., 1997 IEEE International Conference on*, vol. 5, pp. 3617–3620 vol.5, Apr 1997.



- [54] A. Hyvärinen, “Independent component analysis in the presence of gaussian noise by maximizing joint likelihood,” *Neurocomputing*, vol. 22, no. 1-3, pp. 49 – 67, 1998.
- [55] J. R. Voss, L. Rademacher, and M. Belkin, “Fast algorithms for gaussian noise invariant independent component analysis,” in *Advances in Neural Information Processing Systems*, pp. 2544–2552, 2013.
- [56] P. Comon and C. Jutten, *Handbook of Blind Source Separation: Independent Component Analysis and Applications*. Academic Press, 1st ed., 2010.
- [57] J.-F. Cardoso and A. Souloumiac, “Blind beamforming for non gaussian signals,” *IEEE Proceedings-F*, vol. 140, pp. 362–370, 1993.
- [58] A. Papoulis and S. U. Pillai, *Probability, random variables, and stochastic processes*. Tata McGraw-Hill Education, 2002.
- [59] A. Cichocki and R. Unbehauen, “Robust neural networks with on-line learning for blind identification and blind separation of sources,” *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*, vol. 43, pp. 894–906, Nov 1996.
- [60] T. Kim, H. White, and S. D. D. o. E. University of California, *On More Robust Estimation of Skewness and Kurtosis: Simulation and Application to the S&P500 Index*. Discussion paper / University of California, San Diego, Department of Economics, University of California, San Diego, 2003.
- [61] T. Cover and J. Thomas, *Elements of Information Theory*. Wiley, 2012.
- [62] A. Hyvärinen, “New approximations of differential entropy for independent component analysis and projection pursuit,” in *Proceedings of the 1997 Conference on Advances in Neural Information Processing Systems 10*, NIPS ’97, (Cambridge, MA, USA), pp. 273–279, MIT Press, 1998.
- [63] L. D. Lathauwer, “A survey of tensor methods,” in *2009 IEEE International Symposium on Circuits and Systems*, pp. 2773–2776, May 2009.

- [64] A. Hyvarinen, “Fast and robust fixed-point algorithms for independent component analysis,” *IEEE Transactions on Neural Networks*, vol. 10, pp. 626–634, May 1999.
- [65] A. Hyvarinen, “Gaussian moments for noisy independent component analysis,” *IEEE Signal Processing Letters*, vol. 6, pp. 145–147, June 1999.
- [66] S. C. Douglas, A. Cichocki, and S. Amari, “Bias removal technique for blind source separation with noisy measurements,” *Electronics Letters*, vol. 34, pp. 1379–1380, Jul 1998.
- [67] I. T. Jolliffe, *Principal Component Analysis*. Berlin; New York: Springer-Verlag, 1986.
- [68] S. Arora, R. Ge, A. Moitra, and S. Sachdeva, “Provable ICA with unknown gaussian noise, and implications for gaussian mixtures and autoencoders,” *CoRR*, vol. abs/1206.5349, 2012.
- [69] M. Belkin, L. Rademacher, and J. R. Voss, “Blind signal separation in the presence of gaussian noise,” *CoRR*, vol. abs/1211.1716, 2012.
- [70] P.-L. Yeh and P.-L. Liu, “Application of the wavelet transform and the enhanced fourier spectrum in the impact echo test,” *NDT & E International*, vol. 41, no. 5, pp. 382–394, 2008.
- [71] W. A. Kuperman and F. Ingenito, “Spatial correlation of surface generated noise in a stratified ocean,” *The Journal of the Acoustical Society of America*, vol. 67, no. 6, pp. 1988–1996, 1980.

# Apêndice A

## Publicações

Segue uma descrição de trabalhos publicados.

### A.1 Artigos em Congressos

- 1 **Título:** Teste de Robustez da ICA no Pré-Processamento de Sinais em Sistema de Sonar Passivo

**Autores:** Raphael Melo de Amorim, Marcela Silva Novo, Eduardo Furtado Simas Filho, José Manuel de Seixas, Natanael Nunes de Moura

**Congresso:** XX Congresso Brasileiro de Automática, Belo Horizonte, Brasil, 2014

**Descrição:** Este trabalho apresentou um estudo sobre o sistema sonar passivo para testar a robustez ao ruído utilizando a análise de componentes independentes (ICA). A técnica de ICA após o processamento da análise DEMON executada pelo sistema de sonar passivo. Foi utilizado o algoritmo JADE para avaliação.

- 2 **Título:** Desempenho da Separação Cega de Fontes em Sonar Passivo com Inserção de Ruído Ambiente

**Autores:** Raphael Melo de Amorim, Marcela Silva Novo, Eduardo Furtado Simas Filho, José Manuel de Seixas, Natanael Nunes de Moura

**Congresso:** XI Encontro de Tecnologia em Acústica Submarina (XI ETAS), Rio de Janeiro, Brasil, 2014

**Descrição:** Este trabalho mostrou o desempenho da análise de componentes independentes (ICA) na redução do efeito do ruído ambiente no sistema de sonar passivo. Foi avaliado nesse trabalho o resultado da utilização do algoritmo JADE para melhorar o desempenho do sistema sonar sobre efeito do ruído ambiente.