



DETECÇÃO E CLASSIFICAÇÃO DE SINAIS DE SONAR PASSIVO USANDO
MÉTODOS DE SEPARAÇÃO CEGA DE FONTES

Natanael Nunes de Moura

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

Orientador: José Manoel de Seixas

Rio de Janeiro
Abril de 2013

DETECÇÃO E CLASSIFICAÇÃO DE SINAIS DE SONAR PASSIVO USANDO
MÉTODOS DE SEPARAÇÃO CEGA DE FONTES

Natanael Nunes de Moura

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

Examinada por:

Prof. José Manoel de Seixas, D.Sc.

Prof. Carlos Eduardo Parente Ribeiro, D.Sc.

Prof. João Baptista de Oliveira e Souza Filho, D.Sc.

Prof. João Marcos Travassos Romano , Dr. Ing.

Prof. Luis Pereira Calôba, Dr.Ing.

Prof. Sérgio Lima Netto, Ph.D.

RIO DE JANEIRO, RJ – BRASIL

ABRIL DE 2013

Nunes de Moura, Natanael

Detecção e Classificação de Sinais de Sonar Passivo usando métodos de Separação Cega de fontes/Natanael Nunes de Moura. – Rio de Janeiro: UFRJ/COPPE, 2013.

XIX, 161 p.: il.; 29, 7cm.

Orientador: José Manoel de Seixas

Tese (doutorado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2013.

Referências Bibliográficas: p. 154 – 159.

1. Inteligência Computacional. 2. Processamento de Sinais de Sonar Passivo. 3. Análise Espectral. 4. Separação Cega de Sinais. 5. Análise de Componentes Independentes. 6. Fatoração de Matrizes não Negativas. I. Manoel de Seixas, José. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

*Ora, a fé é o firme fundamento
das coisas que se esperam, e a
prova das coisas que não se
vêm.*

*Porque por ela os antigos
alcançaram testemunho.*

*Pela fé entendemos que os
mundos pela palavra de Deus
foram criados; de maneira que
aquilo que se vê não foi feito do
que é aparente.*

Hebreus 11: 1 a 3

Agradecimentos

Agradeço primeiramente a Deus por ter me colocado em uma família nuclear (pai, mãe e irmãos) maravilhosa. Agradeço aos meus pais, que sempre me motivaram a estudar, e nos momentos de dificuldades, me falavam palavras de incentivo, tais como, não desista que você vai conseguir.

Agradeço à minha esposa, Neidi, que durante todo tempo desta jornada esteve comigo, compartilhando dos meus problemas, aflições e muita das vezes da falta de atenção, mas ela compreendia. Sem este apoio incondicional eu não teria conseguido chegar até aqui. Agradeço aos meus filhos por se orgulharem do que eu estava fazendo. Em particular ao meu filho, Natanael Junior, que além de filho foi um colega que muitas vezes tirou as minhas dúvidas na confecção dos desenhos deste trabalho.

Agradeço ao Instituto de Pesquisas da Marinha, particularmente ao pesquisadores William e Cleide, pela paciência de terem me cedido os dados simulados e experimentais. Agradeço também ao ten. Goltz e ao pesquisador Stilson, por terem ido diversas vezes ao CIAMA fazer a aquisição dos dados para que os testes dos algoritmos pudessem ser realizados.

Agradeço ao professor José Manoel de Seixas, meu orientador pela calma, paciência e por sempre tentar me fazer render o melhor neste trabalho. Você foi mais do que um orientador, foi um amigo em quem pude confiar, mesmo nos momentos dos meus problemas pessoais. Muito obrigado.

Agradeço ao CNPq e a FAPERJ pelo suporte financeiro a este trabalho.

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

DETECÇÃO E CLASSIFICAÇÃO DE SINAIS DE SONAR PASSIVO USANDO MÉTODOS DE SEPARAÇÃO CEGA DE FONTES

Natanael Nunes de Moura

Abril/2013

Orientador: José Manoel de Seixas

Programa: Engenharia Elétrica

As operações de guerra naval têm sido cada vez mais estudadas em termos de estratégias e tecnologias. Na área de tecnologia, têm sido desenvolvidas várias técnicas para a detecção e classificação de navios no mar. A detecção e classificação em um sistema de sonar passivo podem ser realizadas de forma automática usando algoritmos de processamento de sinais e de inteligência computacional, para apoiar o operador sonar (OS). Apesar destes algoritmos serem eficazes na detecção e identificação de navios, a interferência entre os navios, principalmente devido à proximidade entre eles, o ruído ambiente, que é função do meio em que o sinal que se deseja identificar e o ruído do próprio navio onde os algoritmos estão instalados, podem aumentar a complexidade para a realização da detecção e classificação dos navios.

Neste trabalho foi proposto o uso de algoritmos de separação cega de fontes, foram aplicados como pré-processamento nas análises DEMON e LOFAR, com o objetivo de melhorar a relação sinal/interferência e a redução do ruído ambiente em relação ao sinal de interesse. Sinais simulados e experimentais foram usados para validar a eficiência destes algoritmos, e métodos estatísticos foram utilizados para medir o índice de desempenho dos componentes estimados pelos algoritmos.

Pelo fato dos dados simulados serem completamente controlados, foi possível verificar a eficiência dos algoritmos de análise de componentes independentes (ICA), principalmente no domínio da frequência, na melhoria da SIR (relação sinal/interferência) e da SNR (relação sinal/ruído), em relação aos resultados obtidos pelos algoritmos de fatoração de matrizes não negativas, que foram propostos neste trabalho. Foram utilizados os mesmos procedimentos, tanto para os dados simulados, quanto para os dados experimentais, e mais uma vez, foram alcançados resultados representativos com os algoritmos de ICA.

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

PASSIVE SONAR SIGNAL DETECTION AND CLASSIFICATION USING
BLIND SOURCE SEPARATION METHODS

Natanael Nunes de Moura

April/2013

Advisor: José Manoel de Seixas

Department: Electrical Engineering

The naval warfare operations have been increasingly studied in terms of strategies and technologies. In the field of technology, several techniques have been developed for the detection and classification of vessels at sea. The detection and classification in a passive sonar system can be performed automatically, using algorithms of signal processing and computational intelligence to support the sonar operator (OS). Although these algorithms are effective in ships, detecting and identifying the interference between the ships, mainly due their proximity, the ambient noise, which is a function of the medium in which the signal you want to identify and noise of the ship itself where the algorithms are installed, may increase the complexity for performing the detection and classification of the vessels.

This thesis proposes the use of algorithms of blind source separation, in order to achieve improvement in the signal/interference and ambient noise reduction with respect to the signal of interest. Simulated and experimental signals were used to validate the efficiency of these algorithms and statistical methods were applied to measure the performance index of the components estimated by the algorithms.

By the fact of simulated data are completely controlled, it was possible to verify the efficiency of algorithms for independent component analysis (ICA), mainly in the frequency domain, improving the SIR (signal/interference) and SNR (Signal/Noise), relative to results obtained by factorization algorithms for non-negative matrices, that have been proposed in this work. It was used the same procedure on the simulated and experimental data. Again, representative results have been achieved with algorithms for ICA.

Sumário

Lista de Figuras	x
Lista de Tabelas	xix
1 Introdução	1
1.1 Motivação	3
1.2 Objetivo	4
1.3 Metodologia	4
1.4 Organização da tese	5
2 Sistema de Sonar Passivo	6
2.1 Introdução	7
2.2 Ruído Irrradiado	8
2.3 Configuração básica de um sistema de sonar passivo	10
2.3.1 Arranjo de Sensores	11
2.3.2 Conformação de Feixes	13
2.3.3 Processamento de Sinal	15
2.3.4 Tipos de Sistemas de Sonar Passivo	18
2.3.5 Equação de um Sistema de Sonar Passivo	20
2.4 Características dos sinais recebidos por um sistema de sonar passivo .	21
3 Separação Cega de Fontes	22
3.1 Análise de Componentes Independentes	22
3.1.1 O Princípio da Independência Estatística	24
3.1.2 Não Gaussianidade e Independência	25
3.1.3 Escalonamento e Permutação	29
3.1.4 Estimção das Funções Densidade de Probabilidade	30
3.1.5 Algoritmo JADE	32
3.1.6 Algoritmo FastICA	33
3.1.7 Algoritmo Newton-Like Multiplicativo	34
3.2 Fatoração de Matrizes não Negativas	35
3.2.1 Fatoração de Matrizes usando o Método das Divergências . . .	36

4	Metodologia de Análise e Operação do Sistema	39
4.1	Dados utilizados	40
4.2	Metodologia de Análise	44
4.2.1	Domínio do tempo	44
4.2.2	Domínio da frequência	45
4.3	Monitoração da estacionaridade	46
4.4	Classificação de contatos	46
4.5	Medida do desempenho	47
4.6	Operação do sistema	50
5	Resultados da Separação Cega de Fontes	51
5.1	Dados Simulados	51
5.1.1	Separação cega no domínio do tempo	51
5.1.2	Separação cega no domínio da frequência	73
5.2	Dados Experimentais	95
5.2.1	Separação no domínio do tempo (2)	95
5.2.2	Separação cega no domínio da frequência	115
5.2.3	Análise da estacionaridade	137
5.2.4	Classificação de contatos	139
6	Conclusões e Trabalhos Futuros	152
6.1	Trabalhos Futuros	153
	Referências Bibliográficas	154
A	Trabalhos Publicados	160

Lista de Figuras

1.1	Cenário de um ambiente submarino.	2
1.2	Metodologia de separação cega de sinais no domínio do tempo.	4
1.3	Metodologia de separação cega de sinais no domínio da frequência.	5
2.1	Diferentes tipos de sistemas de sonar passivo.	6
2.2	Espectro do ruído irradiado de um navio em duas velocidades.	10
2.3	Diagrama de blocos de um sistema de sonar passivo.	10
2.4	Arranjo linear de hidrofones com $n + 1$ elementos.	11
2.5	Arranjo cilíndrico de hidrofones.	12
2.6	Arranjo planar de hidrofones.	12
2.7	Conformador de feixes do tipo atraso e soma.	13
2.8	Conformação de feixes com um arranjo cilíndrico.	14
2.9	Gráfico Marcação \times Tempo.	14
2.10	Diagrama de blocos da análise LOFAR.	15
2.11	Janela usada para remover o ruído de fundo com o algoritmo TPSW.	16
2.12	Análise LOFAR.	16
2.13	Diagrama de blocos da análise DEMON.	17
2.14	Análise DEMON.	17
4.1	Análise DEMON dos 1.020 segundos dos sinais simulados.	41
4.2	Análise DEMON da marcação 190.	42
4.3	Análise DEMON da marcação 205.	43
4.4	Análise DEMON do ruído próprio.	43
4.5	Diagrama de blocos da metodologia no domínio do tempo (1).	45
4.6	Diagrama de blocos da operação no domínio do tempo (2).	45
4.7	Diagrama de blocos da metodologia aplicada no domínio da frequência.	46
4.8	Diagrama de blocos do sistema de classificação usando a separação cega de fontes.	47
4.9	Diagrama de blocos da operação do sistema.	50
5.1	Espectro das janelas de 60s.	52

5.2	Espectro, dos contatos e dos componentes, da janela temporal 17, no domínio do tempo (1) usando o algoritmo FastICA.	53
5.3	Espectro, dos contatos e dos componentes, da janela temporal 17, no domínio do tempo (1) usando o algoritmo JADE.	54
5.4	Espectro, dos contatos e dos componentes, da janela temporal 17, no domínio do tempo (1) usando o algoritmo Newton-like.	54
5.5	Espectro, dos contatos e dos componentes, da janela temporal 17, no domínio do tempo (1) usando o algoritmo NMF com a função custo distância Euclidiana.	55
5.6	Divergência KL entre as observações e os componentes estimados a cada janela temporal.	56
5.7	Divergência KL entre as observações e os componentes estimados a cada janela temporal.	57
5.8	Espectros dos contatos e dos componentes da janela 15 usando o algoritmo FastICA no domínio do tempo (2).	58
5.9	Espectros dos contatos e dos componentes da janela 16 usando o algoritmo FastICA no domínio do tempo.	58
5.10	Espectros dos contatos e dos componentes da janela 17 usando o algoritmo FastICA no domínio do tempo.	59
5.11	Divergência KL entre as observações e entre os componentes estimados pelo algoritmo FastICA.	60
5.12	Divergência KL entre as referências e as observações, e entre as referências e as estimativas obtidas algoritmo FastICA.	61
5.13	Espectros dos contatos e dos componentes da janela 15 usando o algoritmo JADE no domínio do tempo (2).	62
5.14	Espectros dos contatos e dos componentes da janela 16 usando o algoritmo JADE no domínio do tempo.	62
5.15	Espectros dos contatos e dos componentes da janela 17 usando o algoritmo JADE no domínio do tempo.	63
5.16	Divergência KL entre as observações e entre os componentes estimados pelo algoritmo JADE.	63
5.17	Divergência KL entre as referências e as observações e entre as referências as estimativas obtidas algoritmo JADE no domínio do tempo (2).	64
5.18	Espectros dos contatos e dos componentes da janela 15 usando o algoritmo Newton-like no domínio do tempo (2).	65
5.19	Espectros dos contatos e dos componentes da janela 16 usando o algoritmo Newton-like no domínio do tempo (2).	65

5.20	Espectros dos contatos e dos componentes da janela 17 usando o algoritmo Newton-like no domínio do tempo (2).	66
5.21	Divergência KL entre as observações e os componentes estimados pelo algoritmo Newton-like no domínio do tempo (2).	67
5.22	Divergência KL entre as referências e as observações, e entre as referências e as estimativas obtidas algoritmo Newton-like no domínio do tempo (2).	67
5.23	Espectros dos contatos e dos componentes da janela 15 usando o algoritmo NMF com a distância Euclidiana como função custo no domínio do tempo.	68
5.24	Espectros dos contatos e dos componentes da janela 16 usando o algoritmo NMF com a distância Euclidiana como função custo no domínio do tempo.	69
5.25	Espectros dos contatos e dos componentes da janela 17 usando o algoritmo NMF com a distância Euclidiana como função custo no domínio do tempo.	69
5.26	Divergência KL entre as observações e entre os componentes estimados pelo algoritmo NMF usando como função custo a distância Euclidiana no domínio do tempo (2).	70
5.27	Divergência KL entre as referências e as observações, e entre as referências e as estimativas usando o algoritmo NMF com a distância Euclidiana como função custo no domínio do tempo (2).	70
5.28	Espectros dos contatos e dos componentes da janela 15 usando o algoritmo NMF com divergência de Kullback-Leibler como função custo no domínio do tempo.	71
5.29	Espectros dos contatos e dos componentes da janela 16 usando o algoritmo NMF com divergência de Kullback-Leibler como função custo no domínio do tempo.	72
5.30	Espectros dos contatos e dos componentes da janela 17 usando o algoritmo NMF com divergência de Kullback-Leibler como função custo no domínio do tempo.	72
5.31	Divergência KL entre as observações e os componentes estimados pelo algoritmo NMF usando a função custo divergência de Kullback-Leibler.	73
5.32	Divergência KL entre as referências e as observações, e entre as referências e as estimativas obtidas algoritmo NMF usando como função custo a divergência de Kullback-Leibler.	74
5.33	Espectros dos contatos e dos componentes da janela temporal número 15 usando o algoritmo FastICA no domínio da frequência.	75

5.34	Espectros dos contatos e dos componentes da janela temporal número 16 usando o algoritmo FastICA no domínio da frequência.	75
5.35	Espectros dos contatos e dos componentes da janela temporal número 17 usando o algoritmo FastICA no domínio da frequência.	76
5.36	Divergência KL entre as observações e entre os componentes estimados pelo algoritmo FastICA no domínio da frequência.	77
5.37	Divergência KL entre as referências; e as observações e as estimativas obtidas algoritmo FastICA no domínio da frequência.	77
5.38	Espectros dos contatos e dos componentes estimados, da janela temporal número 15, usando o algoritmo JADE no domínio da frequência.	78
5.39	Espectros dos contatos e dos componentes estimados, da janela temporal número 16, usando o algoritmo JADE no domínio da frequência.	79
5.40	Espectros dos contatos e dos componentes estimados, da janela temporal 17, usando o algoritmo JADE no domínio da frequência.	79
5.41	Divergência KL entre as observações e entre os componentes estimados pelo algoritmo JADE no domínio da frequência.	80
5.42	Divergência KL entre as referências e as observações, e entre as referências e as estimativas obtidas algoritmo JADE no domínio da frequência.	81
5.43	Espectros dos contatos e dos componentes estimados, da janela temporal número 15, usando o algoritmo Newton-like no domínio da frequência.	81
5.44	Espectros dos contatos e dos componentes estimados, da janela temporal número 16, usando o algoritmo Newton-like no domínio da frequência.	82
5.45	Espectros dos contatos e dos componentes estimados, da janela temporal número 17, usando o algoritmo Newton-like no domínio da frequência.	82
5.46	Divergência KL entre as observações e entre os componentes estimados pelo algoritmo Newton-like no domínio da frequência.	83
5.47	Divergência KL entre as referências e as observações; e entre as referências e as estimativas obtidas algoritmo Newton-like no domínio da frequência.	84
5.48	Espectros dos contatos e dos componentes estimados, da janela temporal número 15, usando o algoritmo NMF com a função custo Euclidiana no domínio da frequência.	84
5.49	Espectros dos contatos e dos componentes estimados, da janela temporal número 16, usando o algoritmo NMF com a função custo Euclidiana no domínio da frequência.	85

5.50	Espectros dos contatos e dos componentes estimados, da janela temporal número 17, usando o algoritmo NMF com a função custo Euclidiana no domínio da frequência.	85
5.51	Divergência KL entre as observações e entre os componentes estimados pelo algoritmo NMF com a função custo Euclidiana no domínio da frequência.	86
5.52	Divergência KL entre as referências e as observações, e entre as referências e as estimativas, obtidas pelo algoritmo NMF usando como função custo a distância Euclidiana no domínio da frequência.	87
5.53	Espectros dos contatos e dos componentes estimados, da janela temporal número 15, usando o algoritmo NMF, com a divergência de Kullback-Leibler como função custo, no domínio da frequência.	88
5.54	Espectros dos contatos e dos componentes estimados, da janela temporal número 16, usando o algoritmo NMF, com a divergência de Kullback-Leibler como função custo, no domínio da frequência.	88
5.55	Espectros dos contatos e dos componentes estimados, da janela temporal número 17, usando o algoritmo NMF, com a divergência de Kullback-Leibler como função custo, no domínio da frequência.	89
5.56	Divergência KL entre as observações e entre os componentes estimados, pelo algoritmo NMF, usando a divergência KL como função custo, no domínio da frequência.	89
5.57	Divergência KL entre as referências e as observações, e entre as referências e as estimativas, usando o algoritmo NMF, com a divergência KL como função custo, no domínio da frequência.	90
5.58	Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo FastICA no domínio do tempo (2).	96
5.59	Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado, pelo algoritmo FastICA no domínio do tempo (2).	97
5.60	Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado, pelo algoritmo FastICA no domínio do tempo (2).	98
5.61	Divergência KL entre as marcações 190 e 205; e entre os componentes estimados pelo algoritmo FastICA no domínio do tempo (2).	99
5.62	Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo JADE no domínio do tempo (2).	100

5.63	Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado, pelo algoritmo JADE no domínio do tempo (2).	101
5.64	Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado, pelo algoritmo JADE no domínio do tempo (2).	102
5.65	Divergência KL entre as marcações 190 e 205; e entre os componentes estimados pelo algoritmo JADE no domínio do tempo (2).	103
5.66	Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo Newton-like no domínio do tempo (2).	104
5.67	Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado pelo algoritmo Newton-like no domínio do tempo (2).	105
5.68	Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado pelo algoritmo Newton-like no domínio do tempo (2).	106
5.69	Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações usando o algoritmo Newton-like.	107
5.70	Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo NMF, no domínio do tempo (2), usando a distância Euclidiana como função custo.	108
5.71	Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado pelo algoritmo NMF, no domínio do tempo (2), usando a distância Euclidiana como função custo.	109
5.72	Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado pelo algoritmo NMF, no domínio do tempo (2), usando a distância Euclidiana como função custo.	110
5.73	Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações, usando o algoritmo NMF com a função distância Euclidiana, no domínio do tempo.	111
5.74	Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo NMF, usando a divergência de Kullback-Leibler como função custo, no domínio do tempo (2).	112
5.75	Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado pelo algoritmo NMF, usando a divergência de Kullback-Leibler como função custo, no domínio do tempo (2).	113

5.76	Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado pelo algoritmo NMF, usando a divergência de Kullback-Leibler como função custo, no domínio do tempo (2).	114
5.77	Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações usando o algoritmo NMF com a função divergência de Kullback-Leibler, no domínio do tempo.	115
5.78	Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo FastICA no domínio da frequência.	116
5.79	Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado, pelo algoritmo FastICA no domínio da frequência.	117
5.80	Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado, pelo algoritmo FastICA no domínio da frequência.	118
5.81	Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações usando o algoritmo FastICA no domínio da frequência.	119
5.82	Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo JADE no domínio da frequência.	120
5.83	Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado, pelo algoritmo JADE no domínio da frequência.	121
5.84	Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado, pelo algoritmo JADE no domínio da frequência.	122
5.85	Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações, usando o algoritmo JADE, no domínio da frequência.	123
5.86	Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo Newton-like no domínio da frequência.	124
5.87	Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado, pelo algoritmo Newton-like no domínio da frequência.	125
5.88	Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado, pelo algoritmo Newton-like no domínio da frequência.	126
5.89	Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações usando o algoritmo Newton-like no domínio da frequência.	127

5.90	Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo NMF, usando a distância Euclidiana como função custo, no domínio da frequência.	128
5.91	Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado pelo algoritmo NMF, usando a distância Euclidiana como função custo, no domínio da frequência.	129
5.92	Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado pelo algoritmo NMF, usando a distância Euclidiana como função custo, no domínio da frequência.	130
5.93	Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações usando o algoritmo NMF com a distância Euclidiana como função custo no domínio da frequência. . .	131
5.94	Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo NMF, usando a divergência de Kullback-Leibler como função custo, no domínio da frequência. . . .	132
5.95	Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado pelo algoritmo NMF, usando a divergência de Kullback-Leibler como função custo, no domínio da frequência. . . .	133
5.96	Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado pelo algoritmo NMF, usando a divergência de Kullback-Leibler como função custo, no domínio da frequência. . . .	134
5.97	Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações usando o algoritmo NMF com a divergência da Kullback-Leibler como função custo no domínio da frequência.	135
5.98	Energia acumulada.	138
5.99	Número de grupos após a observação de cada agrupamento.	139
5.100	Espectro médio da análise LOFAR de cada uma das marcações. . . .	141
5.101	Espectro médio da análise LOFAR de cada componente estimado pelo algoritmo FastICA.	142
5.102	Espectro médio da análise LOFAR de cada componente estimado pelo algoritmo JADE.	142
5.103	Espectro médio da análise LOFAR de cada componente estimado pelo algoritmo Newton-like.	143
5.104	Espectro médio da análise LOFAR de cada componente estimado pelo algoritmo NMF, usando a distância Euclidiana como função custo. . .	143
5.105	Espectro médio da análise LOFAR de cada componente estimado pelo algoritmo NMF, usando a divergência de Kullback-Leibler como função custo.	144

5.106	Classificação utilizando os espectros da análise LOFAR.	145
5.107	Classificação utilizando o algoritmo FastICA como pós-processamento dos espectros da análise LOFAR.	146
5.108	Classificação utilizando o algoritmo JADE como pós-processamento dos espectros da análise LOFAR.	147
5.109	Classificação utilizando o algoritmo Newton-like como pós- processamento dos espectros da análise LOFAR.	148
5.110	Classificação utilizando o algoritmo NMF, com a distância Euclidiana como função custo, nos espectros da análise LOFAR.	149
5.111	Classificação utilizando o algoritmo NMF, com a divergência de Kullback-Leibler como função custo, nos espectros da análise LOFAR.	150

Lista de Tabelas

2.1	Fontes de ruído irradiado em um navio de propulsão diesel-elétrica . . .	9
3.1	Funções Kernel e suas eficiências	32
5.1	Tabela com os índices desempenho entre os contatos e as referências; e entre os componentes estimados pelos algoritmos de ICA e as re- ferências.	91
5.2	Tabela com os índices desempenho entre os contatos e as referências; e entre os componentes estimados pelos algoritmos de NMF e as re- ferências.	92
5.3	SIR , em dB, janela a janela, dos sinais simulados no domínio do tempo com relação as observações e os componentes estimados algo- ritmos usando a ICA e a NMF.	93
5.4	SIR , em dB, janela a janela, dos sinais simulados no domínio da frequência com relação as observações e os componentes estimados algoritmos usando a ICA e a NMF.	94
5.5	Nível em dB, das marcações (raw-data) e dos componentes estimados, pelos algoritmos de ICA, à cada janela temporal.	135
5.6	Nível em dB, das marcações (raw-data) e dos componentes estimados, pelos algoritmos NMF, à cada janela temporal.	136
5.8	Largura à meia altura das rotações, das marcações (raw-data) e dos componentes estimados, pelos algoritmos de NMF à cada janela tem- poral.	137
5.7	Largura à meia altura das rotações, das marcações (raw-data) e dos componentes estimados, pelos algoritmos de ICA em cada janela tem- poral.	137
5.9	Número de neurônios na camada escondida em relação ao melhor índice <i>SP</i> de cada algoritmo.	141
5.10	Eficiência da discriminação obtida por cada um dos classificadores. . .	151

Capítulo 1

Introdução

As operações de guerra naval têm sido cada vez mais estudadas em termos de estratégias e tecnologias. Na área de tecnologia, têm sido desenvolvidas várias técnicas para o acompanhamento, detecção e classificação de contatos no mar. Os navios de superfície podem ser detectados e classificados usando o radar, que utiliza ondas eletromagnéticas, pois estas têm uma baixa atenuação no ar. Já no caso dos submarinos, que estão submersos no mar, as ondas eletromagnéticas sofrem uma grande atenuação no ambiente submarino e, portanto não são usadas para a detecção e classificação de submarinos submersos. Por outro lado, as ondas acústicas conseguem se propagar em grandes distâncias no mar, dependendo da sua frequência, sem perda significativa da sua energia. Então, a onda acústica que é propagada por um navio de superfície, pode ser usada pelo submarino para a realização da identificação deste navio. Da mesma forma, os navios de superfície usam as ondas acústicas para a localização de submarinos.

O sistema que usa a propagação do som (transmissão e recepção) em baixo d'água é chamado de sistema de sonar. A palavra sonar é derivada de “***SO**und **NA**avigation **R**anging” e tem sido usada desde a segunda grande guerra. Existem dois tipos de sistemas de sonar que são usados nos navios. O sistema de sonar ativo, usado em navios anti-submarinos, envolve a transmissão de uma onda acústica através de um projetor (normalmente por um conjunto de hidrofones) que, refletida em um alvo, fornece ao sistema a informação para a detecção, classificação, localização e determinação da distância do referido alvo. Neste sistema, temos a vantagem de saber que tipo de onda estamos transmitindo, porém ficamos mais expostos quanto ao reconhecimento, por estarmos emitindo sinais. Já o sistema que se baseia na detecção e estimação do som propagado pelo próprio alvo, sem nenhuma transmissão de sinal, é chamado de sistema de sonar passivo. Este sistema, normalmente, é usado nos submarinos. O problema da detecção passiva é conhecer o sinal do alvo desejado através de sua assinatura (sinal propagado pelo alvo) em um ambiente ruidoso, onde o ruído tem um espectro de frequência similar ao sinal propagado pelo alvo de*

interesse. O ruído irradiado pelo alvo contém informações importantes a respeito da maquinaria presente no interior do alvo, bem como o ruído de propulsão. Além do ruído que se encontra no ambiente, outros alvos que estão presentes num dado cenário podem interferir no processo de detecção e classificação de um determinado contato. Por isto, técnicas de processamento de sinais são necessárias para a separação dos sinais de interesse com o objetivo de melhorar a relação sinal/ruído e a relação sinal/interferência para detecção e a classificação dos alvos. A Figura 1.1 mostra um possível cenário, onde um submarino está em patrulha no modo passivo, para realizar a detecção e classificação dos contatos na área de operação.




Figura 1.1: Cenário de um ambiente submarino.

A detecção e classificação em um sistema de sonar passivo são realizadas de forma automática, por algoritmos de processamento de sinais e de inteligência computacional, para apoiar o operador sonar (OS). Em um sistema de sonar moderno, o processamento do sinal é um dos mais importantes componentes do sistema, funcionando como apoio à detecção e classificação por parte do OS. Mesmo as técnicas modernas de processamento podem ter dificuldades de realizar a detecção e classificação do contato de interesse proveniente de uma determinada marcação. Apesar destes algoritmos serem eficazes na detecção e identificação de um contato, a interferência entre os contatos (alvos); e entre o contato e o ruído ambiente normalmente permanecem, principalmente quando estes alvos estão se aproximando. Por isto se faz necessário aumentar a complexidade nos sistemas automáticos para a realização da detecção e classificação dos contatos com a finalidade de mostrar com mais clareza as características dos alvos a serem detectados. Neste caso, se faz ne-

cessária a implementação de novas técnicas para o pré-processamento dos sinais, visando a separação do sinal das interferências. Uma possível solução é a separação cega de fontes, onde métodos estatísticos são usados visando a melhoria na relação sinal/interferência; ou a redução do ruído em relação ao sinal de interesse.

1.1 Motivação

Os primeiros sonares passivos ganharam forte motivação na sua implementação após a primeira grande guerra mundial. Eles eram compostos somente de um sistema de áudio onde o operador sonar escutava os sinais provenientes de uma determinada direção para identificar o tipo de contato que estava presente no cenário onde o submarino se encontrava. Verificou-se, então, a necessidade de se criar um sistema que tivesse algumas características adicionais, além do áudio, para apoiar o operador. Outros tipos de sonares passivos mais sofisticados foram desenvolvidos, realizando-se pesquisas em análise dos dados que foram obtidos pelos primeiros sonares.

Um sistema de sonar passivo tem como principais características a estimação da direção de interesse DOA (*Direction Of Arrival*), a detecção, identificação, a classificação e acompanhamento de contatos em um determinado cenário acústico. A estimação da direção de interesse é realizada usando algoritmos de conformação de feixes [1], que estabelecem de qual direção o sinal do contato de interesse está sendo proveniente. A identificação destes contatos é realizada através da sua assinatura (ruído acústico emitido pelo contato) usando duas análises: LOFAR e DEMON. A análise LOFAR (*LOW Frequency Analysis and Recording*) é uma análise espectral que é realizada em toda a banda de frequência do sinal que vai ser analisado. Esta análise, identifica o ruído da maquinaria do navio (contato). A análise DEMON (*DEtection MODulation on Noise*) é uma análise que detecta a envoltória do ruído de cavitação¹ para identificar o tipo de propulsão do navio, informando o número de eixos e o número de pás do contato de interesse [2].

Em determinadas situações, os sinais de marcações próximas, além do ruído ambiente causado pelos fenômenos naturais (vento, temperatura, salinidade, etc.), poderão interferir de forma significativa durante a estimação da direção de chegada, causando dificuldades na identificação dos contatos detectados em cada marcação, por parte do operador sonar (OS). Devido as situações mencionadas anteriormente, se faz necessário a utilização de técnicas inteligentes como o pré-processamento para a separação destes sinais, com o objetivo de facilitar, de forma efetiva, a identificação dos alvos e melhorar a detecção e classificação dos contatos nas análises DEMON e LOFAR. Modelos de separação cega de fontes têm sido usados com eficiência em

¹Implosão e explosão de bolhas de ar, devido a cavitação, causando a geração de um ruído de banda larga

diversas áreas para a realização desta separação. A ideia, então, é aplicar estes modelos para verificar o seu desempenho nos sinais de sonar passivo.

1.2 Objetivo

O objetivo deste trabalho é melhorar a detecção e a classificação de um contato em uma determinada marcação, que são realizadas através das análises DEMON e LOFAR, usando como pré-processamento dos sinais algoritmos de separação cega de fontes. A ideia é melhorar a relação sinal/interferência (SIR) e a relação sinal/ruído (SNR), de forma a apoiar o operador de sonar na detecção e classificação do contato, facilitando a sua identificação.

1.3 Metodologia

A metodologia utilizada neste trabalho é baseada na implementação de algoritmos de separação cega de fontes, como pré-processamento, para melhorar a detecção e classificação de sinais de sonar passivo. Estes algoritmos foram implementados tanto com os sinais no domínio do tempo como no domínio da frequência e foram aplicados tanto em sinais simulados quanto em sinais experimentais.

A Figura 1.2, mostra o diagrama de blocos do pré-processamento usado para a separação cega de sinais de sonar passivo no domínio do tempo.




Figura 1.2: Metodologia de separação cega de sinais no domínio do tempo.

A partir da aquisição das marcações no domínio do tempo, os algoritmos de separação cega de fontes são implementados para a estimação dos componentes de interesse. Após a separação cega, uma análise espectral (análise DEMON e LOFAR) é implementada nos componentes estimados para verificar se houve uma melhora na relação sinal/interferência e sinal/ruído entre as marcações já separadas. Também são utilizadas técnicas estatísticas para quantificar o desempenho da separação.

No domínio da frequência, como é mostrado no diagrama de blocos da Figura 1.3, é implementada uma análise espectral a partir das marcações e os algoritmos de separação cega de fontes são usados para a estimação dos componentes. Da mesma forma que foi utilizada no domínio do tempo, técnicas para quantificar o desempenho da separação também foram utilizadas no domínio da frequência.




Figura 1.3: Metodologia de separação cega de sinais no domínio da frequência.

Existem vários algoritmos de separação cega de sinais. Neste trabalho, foram utilizados algoritmos para a separação usando a análise de componentes independentes e a fatoração de matrizes não negativas.

1.4 Organização da tese

O capítulo 2 faz uma abordagem sobre sistema de sonar passivo, seus componentes, tais como, arranjo de sensores (hidrofonos) que são usados para receber os sinais provenientes dos contatos que estão chegando de várias direções. A estimação da direção de chegada que é realizada através da conformação de feixes com o objetivo de verificar de qual direção o contato está chegando. A detecção e classificação de contatos são realizadas através de análises espectrais. O capítulo 3 faz uma explanação sobre algoritmos que realizam a separação cega de fontes que serão utilizados como pré-processamento para a melhoria da relação sinal/interferência e sinal/ruído dos contatos. O capítulo 4, mostra a metodologia e a operação de um sistema de sonar passivo. O capítulo 5 trata dos resultados obtidos com os algoritmos de separação cega de fontes na remoção de interferências através da detecção e classificação de contatos, usando as análises DEMON e LOFAR. Resultados mostram um melhor desempenho dos algoritmos de ICA, tanto no domínio do tempo como no domínio da frequência, em relação aos algoritmos de NMF, A conclusão, que é explanada no capítulo 6, mostra que tipo de pré-processamento alcançou o melhor desempenho na separação cega dos contatos e também indica futuros trabalhos que poderão ser desenvolvidos para completar esta pesquisa.

Capítulo 2

Sistema de Sonar Passivo

Neste Capítulo, será feita uma descrição do funcionamento de um sistema de sonar passivo, cobrindo os requisitos de processamento de sinais que são necessários para a detecção e classificação dos sinais irradiados pelos navios, provenientes das várias direções que são formadas através de um arranjo de sensores (hidrofonos) [3]. A Figura 2.1, mostra vários tipos de sistema de sonar passivo que são usados atualmente.




Figura 2.1: Diferentes tipos de sistemas de sonar passivo.

Um sistema de sonar passivo que é comumente usado, para a detecção de submarinos, são as sonobóias, que normalmente são jogadas de aeronaves no mar e

formam um conjunto de hidrofones aleatoriamente espalhados, para a realização da vigilância em uma determinada região do oceano. Estas sonobóias, ficam no modo passivo, verificando, a presença ou não, de submarinos nesta região. Os ruídos adquiridos pelas sonobóias são, então, transmitidos, via rádio, para a aeronave que as lançou no mar e são processados, usando as análises necessárias para a detecção de submarinos.

Um outro tipo de sistema de sonar passivo é o arranjo rebocável. Este tipo de arranjo é linear e, normalmente, é rebocado por um navio de superfície (também pode ser rebocado por um submarino) tendo um cordão umbilical onde as informações da direção dos sinais são enviadas para serem processadas pelo navio, o qual ele está acoplado.

Hoje em dia, a colocação de arranjos de hidrofones em linha na plataforma continental dos países é feita com o objetivo de realizar a vigilância passiva em toda a costa marítima do país. Em qualquer situação, por exemplo, de ultrapassagem de uma determinada linha de segurança, o navio seria detectado através de uma central onde os dados estão sendo recebidos, para que providências sejam tomadas.

Submarinos e navios de superfície que têm a finalidade de fazer a detecção de alvos, utilizam sistemas de sonar passivo para obter informações sobre estes alvos (navios e submarinos) que estão presentes no cenário de um ambiente oceânico, analisando os sinais que chegam destes alvos. Um sistema de sonar passivo tem a finalidade de fazer a análise destes sinais, de forma a separá-los das interferências¹, formadas pelo ruído ambiente e, pelo ruído do próprio navio, onde o sistema de sonar passivo está instalado.

2.1 Introdução

O sistema de sonar passivo tem a finalidade de realizar detecção e classificação de sinais acústicos em ambientes submarinos, usualmente o oceano. A diferença entre sonar passivo e ativo é que o passivo não emite nenhum sinal; ao invés de emitir sinais, o seu propósito é detectar sinais acústicos provenientes de navios (contatos) que chegam de diferentes direções. A partir de uma perspectiva histórica, o principal impulso para a investigação e desenvolvimento de sistemas de sonares passivos têm sido suas aplicações militares. Porém, o ritmo da pesquisa militar, para a detecção de submarinos no modo passivo, tem diminuído nos últimos anos, pelo fato de que cada vez mais os submarinos estão se tornando mais silenciosos e atingindo grandes profundidades, quando em operação. Desta forma, o foco tem mudado para sistemas de sonar ativo. Contudo, novas aplicações e técnicas de processamento de sinais continuam sendo desenvolvidas para sistemas de sonares passivos com o

¹Todo tipo de ruído que dificulta a detecção e classificação dos contatos

objetivo de melhorar a detecção e classificação destes submarinos. Além disto, uma maior conscientização das questões ambientais tem estimulado o desenvolvimento de técnicas passivas de detecção de cardumes de peixes e baleias, bem como a detecção de petróleo e gás em águas profundas.

A análise dos dados em um sistema de sonar passivo normalmente é dividida em três estágios: detecção, classificação e localização de contatos. A tarefa de detecção é verificar a presença de sinais acústicos de um contato de interesse que vem contaminado por um ruído de fundo, e é pré-requisito para o subsequente processamento. Quando o contato é detectado, é necessário que ele seja classificado para a realização da sua identificação. Com isto, pode ser estabelecido que o contato seja de interesse ou que possa ser desprezado. Por exemplo, em sistemas de sonar passivo de uso militar, o classificador pode tentar distinguir entre os navios de superfície e submarinos ou a que classe o navio pertence. Após a identificação dos contatos de interesse, uma tentativa pode ser feita para localizar o contato e realizar o seu acompanhamento em função do tempo. Informações mais detalhadas sobre o processamento de sinal para sistemas de sonar passivo podem ser encontrados em artigos de revisão e livros didáticos [4] e [5].

2.2 Ruído Irradiado

Existem várias fontes de ruído em um ambiente submarino. Dentre estas fontes, os navios e submarinos são grandes geradores de ruído sonoro no mar. Estes ruídos são provenientes das máquinas e da propulsão destes contatos. As máquinas que estão contidas nos navios vibram em determinadas frequências e esta vibração se propaga pelo casco formando, assim, uma assinatura característica do navio.

Existem três formas de geração deste ruído: ruído hidrodinâmico, ruído de hélices e ruído das máquinas. A Tabela 2.1, mostra as fontes geradoras de ruído de um sistema de propulsão elétrica-diesel, com as partes do navio que são responsáveis pela geração dos respectivos ruídos.

O ruído hidrodinâmico ocorre quando o navio se desloca na água. Ele tem origem no fluxo do líquido passando pelo navio em movimento. As variações de pressão associadas a este fluxo podem ser irradiadas a uma certa distância caracterizando um tipo de ruído do navio.

O ruído do hélice é um ruído proveniente do ruído de cavitação. A cavitação [6] ocorre devido a explosão e implosão de bolhas em torno do hélice, a partir de uma determinada velocidade de rotação. Isto causa um ruído de banda larga, que abrange uma faixa de dezenas de Hertz até milhares Hertz. A rotação do hélice modula este ruído de cavitação, com aumentos periódicos da amplitude e isto ocorre na velocidade de rotação do eixo propulsor ou na frequência das pás do hélice,

Tabela 2.1: Fontes de ruído irradiado em um navio de propulsão diesel-elétrica

Ruído Hidrodinâmico	<ul style="list-style-type: none"> • Ruído de fluxo irradiado • Excitação ressonante de cavidades e de placas • Cavitação em estruturas
Ruído do Hélice	<ul style="list-style-type: none"> • Cavitação no hélice • Excitação ressonante do casco induzida pelo hélice
Ruído de Máquinas	<ul style="list-style-type: none"> • Motores diesel, motores principais, engrenagens redutoras, turbinas • Geradores, bombas, equipamentos de ar condicionado

correspondendo, então, a frequência do eixo multiplicada pelo número de pás. A partir desta frequência, a velocidade do navio pode ser estimada.

O ruído de máquinas tem origem nas diversas máquinas do navio, quando ele está em movimento e se propaga através do mar, pelo casco do navio. A vibração das máquinas tem diferentes origens:

- Dentes das engrenagens, ranhuras das armaduras e lâminas das turbinas;
- Eixos e armaduras de motores desalinhados;
- Explosões em cilindros de máquinas alternativas;
- Cavitação e turbulência no fluxo dos fluidos das bombas, canos e válvulas de descarga de capacitores.

Das três classes de ruído, o ruído do hélice e o de máquinas dominam o espectro do ruído irradiado na maioria das condições das máquinas do navio. Os dois tipos de ruído são importantes e dependem da velocidade e da profundidade do navio para assumir determinadas características. A Figura 2.2 mostra estas características do espectro do ruído de um navio em duas velocidades diferentes [6]. A Figura 2.2(a) mostra o espectro do navio em baixa velocidade, onde o ruído de cavitação apenas começa a aparecer. Os espectros de baixa frequência são as linhas espectrais das máquinas. Estas linhas desaparecem à medida que a frequência aumenta. Para velocidades mais altas, Figura 2.2(b), o ruído do hélice aumenta e se desloca para frequências mais baixas. Ao mesmo tempo alguns componentes de frequência aumentam tanto em nível quanto em frequência, mantendo a velocidade constante, e

permanecem sem alteração pelo aumento da velocidade do navio. Assim, em altas velocidades o espectro contínuo do hélice esconde várias componentes de frequência caracterizando a velocidade do navio.

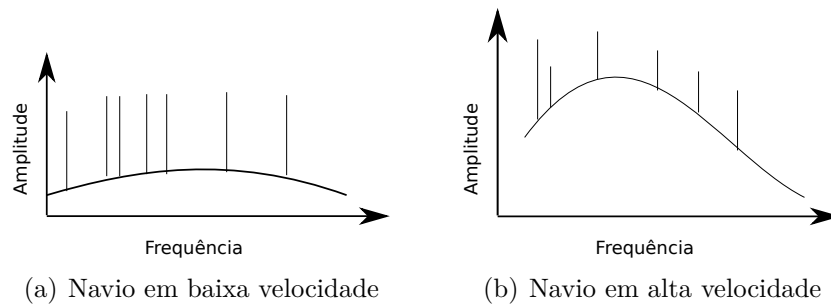


Figura 2.2: Espectro do ruído irradiado de um navio em duas velocidades.

2.3 Configuração básica de um sistema de sonar passivo

Um sistema de sonar passivo contém basicamente um conjunto de subsistemas conforme mostrado na Figura 2.3.

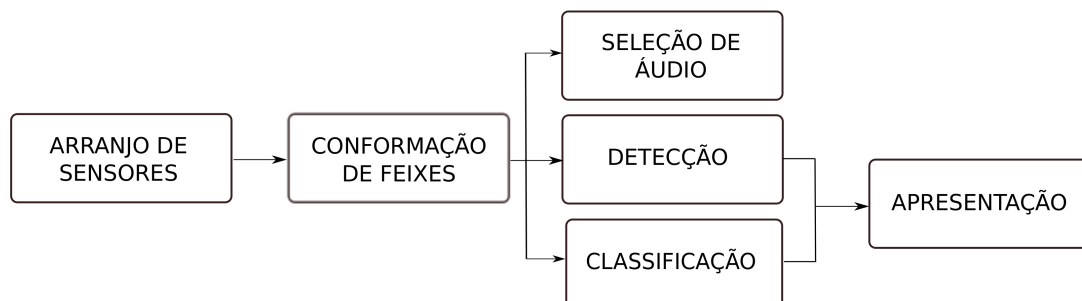


Figura 2.3: Diagrama de blocos de um sistema de sonar passivo.

O sistema é composto por um arranjo de sensores, que tem a finalidade de receber os sinais gerados (ruído irradiado) pelos navios em todas as direções. Na sequência, um conformador de feixes realiza uma filtragem espacial dos sinais que chegam no arranjo de sensores. Um seletor de feixes permite a escuta do áudio do contato em uma determinada direção de interesse e um sistema realiza a detecção e, em seguida, a classificação de contatos. Por fim, as análises são apresentadas de forma gráfica. A seguir, será feita uma explanação do funcionamento de cada um destes blocos.

2.3.1 Arranjo de Sensores

O arranjo de sensores em um sistema de sonar passivo é composto por um conjunto de hidrofones que tem a finalidade de capturar as assinaturas acústicas² provenientes de várias direções, para que posteriormente sejam processadas [5]. Com este arranjo de sensores, podem ser determinadas a direcionalidade do arranjo, a sua faixa de frequência de operação e a sua capacidade de atenuação do ruído próprio.

Os arranjos de sensores podem ser do tipo linear, cilíndrico, ou planar [1]. Cada um destes arranjos realizam a conformação de feixes com uma determinada característica. Por exemplo, o arranjo linear, normalmente, é composto por um conjunto de sensores (hidrofones) que estão igualmente espaçados, conforme mostrado na Figura 2.4, e realiza a aquisição dos sinais -90° a 90° graus, em relação ao seu eixo de resposta principal (MRA - Main Response Axis) [5].




Figura 2.4: Arranjo linear de hidrofones com $n + 1$ elementos.

A direção de chegada do sinal é calculada através do ângulo de azimuth θ (ângulo obtido entre a chegada do sinal e o eixo de resposta principal).

Um outro tipo de arranjo de sensores é o arranjo cilíndrico (CHA - Cylindrical Hydrophone Array), conforme mostrado na Figura 2.5 [1]. Este arranjo é composto de vários staves (conjunto de hidrofones na posição vertical) em torno de um cilindro, formando assim o arranjo de sensores que realiza a aquisição dos sinais de forma omnidirecional. Nesta configuração podem ser estimados tanto o ângulo de azimuth, θ , quanto o ângulo de elevação, ϕ (ângulo do sinal de chegada em relação aos staves do arranjo).

O arranjo planar, conforme mostrado na Figura 2.6, também mede os ângulos de azimuth e elevação, porém, não realiza a vigilância omnidirecional. A vigilância,

²sinais dos contatos




Figura 2.5: Arranjo cilíndrico de hidrofones.




Figura 2.6: Arranjo planar de hidrofones.

neste caso, é realizada em relação ao plano que o arranjo está posicionado. Cada um destes arranjos com suas geometrias e o número de hidrofones têm uma determinada resolução e podem ser usados para diversas aplicações em problemas de sonar passivos [1].

Os resultados experimentais apresentados neste trabalho foram obtidos através dos sinais adquiridos de um sistema de sonar passivo, a partir de um arranjo de hidrofones cilíndrico, que está instalado nos submarinos da Marinha do Brasil.

2.3.2 Conformação de Feixes

A conformação de feixes tem a finalidade de investigar as direções de interesse (DOA - Direction Of Arrival), de modo a observar a energia de um determinado contato (alvo) [7] em uma determinada direção. Existem várias formas para a realização da conformação de feixes [1]. A mais comum, emprega a técnica do atraso e soma (delay and sum), que é normalmente implementada para realizar a estimação da direção de sinais de banda larga.

Dado um arranjo, com N hidrofones, e sendo $x_n(t)$ o sinal recebido no n ésimo hidrofone, tal que $n = 0, 1, \dots, N - 1$, o conformador atraso e soma é mostrado na Figura 2.7. As entradas $x_n(t)$ são os sinais provenientes do arranjo de sensores, τ_n são os deslocamentos temporais inseridos para direcionar os sinais em uma determinada direção e w_n são ponderações usadas para formar a resposta do conformador. Quando os atrasos temporais são iguais aos atrasos atuais de um sinal que está se propagando através do arranjo, este sinal, então, é somado de forma coerente pelo conformador e reforçado naquela direção. Sinais chegando de outras direções são somados de forma incoerente e são atenuados.




Figura 2.7: Conformador de feixes do tipo atraso e soma.

Neste trabalho, foi utilizado um arranjo de sensores do tipo cilíndrico composto de 96 staves e que realiza a conformação dos feixes com 32 staves adjacentes para calcular a direção de interesse. Esta configuração fornece uma resolução angular de $3,75^\circ$, como é mostrado na Figura 2.8.




Figura 2.8: Conformação de feixes com um arranjo cilíndrico.

A Figura 2.9 mostra o gráfico da direção de chegada (marcação \times tempo) de um sistema de sonar passivo. Nesta Figura, o eixo horizontal representa a marcação em graus, que vai de 0° a 180° em um bordo e de 0° a 180° para outro bordo, fazendo a cobertura em 360° . O eixo vertical representa o tempo em segundos, onde cada traço maior representa uma janela temporal de 60 segundos. A energia em cada marcação tem uma representação em escala de cinza, quanto maior for a tonalidade cinza, maior será probabilidade de um alvo está presente naquela marcação. Com isto, é possível ao operador sonar fazer uma observação visual de que direção vem o contato.




Figura 2.9: Gráfico Marcação \times Tempo.

2.3.3 Processamento de Sinal

A conformação de feixes é importante para a obtenção da direção de chegada dos contatos [7]. Após a estimação da direção de chegada de um contato, se faz necessário o processamento dos sinais para a caracterização do mesmo. Um sistema de sonar passivo realiza a detecção, classificação e em algumas situações o acompanhamento de um contato. Para a realização da detecção dos sinais, após a conformação de feixes, duas análises principais são realizadas. A análise LOFAR (Low Frequency Analysis and Recording) e a análise DEMON (Demodulation of Envelope Modulation On Noise). A análise LOFAR também é usada para a realização da classificação do contato, pelo fato desta análise, fornecer características do maquinário do contato.

Análise LOFAR

A análise LOFAR é uma análise espectral de banda larga [2] que caracteriza a faixa de frequência do ruído das máquinas do contato. A Figura 2.10 mostra o diagrama de blocos da análise LOFAR.




Figura 2.10: Diagrama de blocos da análise LOFAR.

Fornecida uma direção de interesse, o sinal primeiramente é filtrado e multiplicado por uma janela de Hanning [8]. Posteriormente, uma transformada de Fourier (STFFT) é realizada [9] para que seja obtido uma representação do sinal no domínio da frequência (modulo do espectro). Então, o sinal é normalizado usando o algoritmo TPSW (Two Pass Split Window) [2], [10] e [11] com o objetivo de realizar a estimativa do ruído de fundo. A Figura 2.11 mostra como é realizada a filtragem usando o TPSW. O objetivo é criar uma janela que se desloca ao longo do sinal realizando uma média local para remover o ruído de fundo e normalizar o sinal. Com isto, os picos de frequência de menor amplitude ficam mais evidentes e ocorre uma remoção da tendência do sinal, de forma que as amplitudes em todo o espectro sejam normalizadas.

A Figura 2.12 mostra uma apresentação típica da análise LOFAR. O eixo horizontal corresponde a frequência, que neste caso, cobre a faixa de 0 a 15.625 Hz, enquanto o eixo vertical representa a janela temporal. Nesta apresentação, a janela temporal foi de aproximadamente 25 segundos, com um segundo de apresentação em cada linha. Existe uma frequência de 2.506 Hz que persiste todo o tempo da janela temporal. Esta frequência caracteriza um ruído do maquinário referente ao




Figura 2.11: Janela usada para remover o ruído de fundo com o algoritmo TPSW.

tipo do contato a ser identificado.




Figura 2.12: Análise LOFAR.

Análise DEMON

A análise DEMON, é uma análise de banda estreita que, opera sobre o ruído de cavitação da propulsão do alvo com o propósito de identificar o número de eixos, a frequência de rotação dos eixos e o número de pás [2] e [12]. Esta análise possibilita a detecção e identificação de um contato por parte do operador sonar. A Figura 2.13, mostra o diagrama de blocos da análise DEMON clássica.

A partir de uma determinada marcação, o sinal é limitado em banda através de um filtro passa-faixa, na banda de frequência onde a cavitação é mais acentuada [5]. A faixa de frequência de cavitação pode ir de centenas até milhares de Hertz.



Figura 2.13: Diagrama de blocos da análise DEMON.

Porém, em determinadas bandas de frequências, a cavitação é mais caracterizada, isto é, o índice de modulação é mais acentuado, facilitando a identificação do contato. Após a filtragem, o sinal é demodulado para obter as informações sobre a propulsão do contato. Como a frequência de amostragem do sinal é elevada em relação a banda de frequência da propulsão, uma reamostragem é realizada para que o sinal seja transposto para a banda de propulsão. Então, uma transformada rápida de Fourier (STFFT - Short Time Fourier Transform) é implementada para a obtenção do espectro do sinal. Como já foi explanado anteriormente, na análise LOFAR, a normalização é implementada para a realização da equalização dos picos de frequência. Então, ocorre a apresentação do espectro.

A Figura 2.14 mostra o gráfico de uma análise DEMON clássica. O eixo horizontal representa a escala de rotação, em rpm, enquanto a escala vertical corresponde a amplitude em dB. A amplitude maior representa a velocidade de rotação do eixo, enquanto os harmônicos subsequentes indicam o número de pás [12].




Figura 2.14: Análise DEMON.

Classificação

Um módulo de processamento importante em um sistema de sonar passivo é a classificação de alvos para dar apoio a decisão na caracterização de um contato por parte do operador sonar [13] [14] e [15]. Usualmente, a classificação é baseada na

extração de características relevantes do contato a ser classificado e usa estas características para decidir se o alvo detectado pertence a uma determinada classe. Como já foi mencionado anteriormente, as características dos contatos são extraídas tipicamente no domínio da frequência, através da análise LOFAR. Porém, em função das interferências nas direções de interesse e uma grande quantidade de classes que normalmente estão muito próximas, a classificação automática, frequentemente usa algoritmos de inteligência computacional visando a obtenção da melhoria na relação sinal interferência do contato. Redes neurais [16] tem sido usadas em sistemas de sonar passivo com sucesso na classificação dos sinais [13], [14], [17] e [18]. Outras técnicas de processamento de sinais têm sido aplicadas para a realização da tarefa de classificação, Peyvandi et. al, [19], usou o modelo de Markov escondido com a similaridade de Hausdorff para a detecção e classificação de alvos. Uma outra maneira para a realização da classificação de sinais em sistema de sonar passivo é usar o método de Prony [20], que fornece um modelo alternativo de mapeamento no domínio da frequência (os sinais são modelados através de um somatório de senóides amortecidas) que são adaptadas para sinais acústicos.

Foi realizada uma pesquisa bibliográfica com objetivo de verificar o estado da arte das análises DEMON e LOFAR, bem como os modelos que estão sendo aplicados para que, estas análises, possam melhorar a detecção da propulsão e da classificação de contatos. Porém, pelo fato deste material ser confidencial e conter um grau de sigilo rigoroso, não foram encontrados trabalhos publicados, nesta área. Principalmente, no que diz respeito à parte militar, nem tão pouco, que tipo de pré-processamento tem sido utilizado para melhorar a identificação de um contato. Os trabalhos publicados, na maioria, estão correlacionados com a Marinha do Brasil (MB) e os que são de fora, não fornecem informações suficientes para que se pudesse estabelecer o estado da arte no momento atual. Tudo o que foi feito, partiu de discussões, com os pesquisadores e o pessoal operativo da Marinha.

2.3.4 Tipos de Sistemas de Sonar Passivo

A figura 2.1, mostrada anteriormente, ilustra vários tipos de sistemas de sonar passivo que estão em uso hoje. O arranjo rebocável é usado normalmente por navios de superfície, mas também podem ser usados por submarinos. Os sinais são enviados através do cabo de reboque para serem processados a bordo dos navios. Os navios de superfície e submarinos são frequentemente equipados com os sensores montados no casco, nas formas que foram explanadas nas seção 2.3.1, porém, o arranjo rebocável se torna mais imune ao ruído próprio do navio.

A sonobóia é um dispositivo descartável que pode ser lançado de uma aeronave no oceano e que transmite sinais de seu sensor através de um link de rádio para a

serem processados no sonar da aeronave. Normalmente, as sonobóias são lançadas em conjunto em uma determinada área no oceano e a aeronave realiza a varredura recebendo os sinais de rádio das diversas sonobóias da região para a detecção de submarinos.

Para a vigilância passiva das zonas costeiras e portos, vários arranjos de sensores podem ser instalados no fundo do mar e ligados por cabos a uma estação de processamento destes sinais em terra.

Os sensores que estão imersos no oceano compõem a parte molhada do sistema de sonar. Os hidrofones geralmente são escolhidos para ter uma resposta omnidirecional nas frequências de interesse, sensores de velocidade das partículas são por vezes utilizados para realizar uma resposta direcional. Um dos principais objetivos ao se projetar um hidrofone é fazer com que ruído o ambiente se torne limitado, ou seja, o principal contribuinte para o nível de ruído total deve ser o ruído ambiente gerado pela água que incide sobre o hidrofone. Este tipo de ruído é intrínseco ao ambiente submarino e impõe uma limitação inevitável sobre o desempenho do sonar. Outro componente de ruído é chamado de ruído próprio: exemplos, são o ruído eletrônico do amplificador do hidrofone, o ruído canalizado para o hidrofone de sua montagem mecânica, e o ruído de fluxo (resultante da água, que passou pelo hidrofone). Ao contrário do ruído ambiente, o ruído próprio está sob o controle do projetista do sistema e é passível de redução através da construção de sistemas que tornem a SIR em relação ao ruído próprio cada vez menor. Os arranjos de sensores são usados com frequência para aumentar a sensibilidade na detecção ou para fornecer uma boa resolução na estimação da direção de chegada.

O sistema eletrônico para o processamento e a apresentação de dados que foram recebidos pela parte molhada constituem a parte seca do sistema de sonar passivo. Os sistemas de sonares passivos modernos dependem quase que exclusivamente de processamento digital de sinais para o seu funcionamento. No início do desenvolvimento de sonares passivos, processadores customizados foram utilizados para a realização do processamento das tarefas que necessitavam de uma carga computacional intensiva, porém, novos processadores têm substituído estes processadores especializados. O software de que realiza o processamento do sinal é normalmente escrito em uma linguagem de alto nível, com um sistema operacional de tempo real.

A principal função realizada pelo processamento analógico em um sonar de hoje é o condicionamento de sinal, tal como a amplificação e filtragem, que é necessária entre o hidrofone e o conversor analógico/digital (ADC - Analog-to-Digital Converter). No início, a faixa dinâmica dos sonares passivos foi insuficiente para condicionar a variabilidade dos níveis do ruído ambiente, sendo necessário a inclusão controle de ganho automático (AGC - Automatic Gain Control). Com o desenvolvimento tecnológico dos ADC, que agora contém, uma ampla faixa dinâmica, se tornou possível

para eliminar o AGC.

A ideia do sistemas de sonares passivos modernos é fazer com que o operador sonar tenha cada vez mais facilidade na interpretação dos resultados dos sinais processados. Existe também, uma preocupação na apresentação destes dados de forma que o operador sonar possa tomar as decisões sobre a detecção e classificação dos contatos. Por outro lado, o volume de processamento dos sinais se tornou grande com os avanços da tecnologia e, os sinais devem ser armazenados para evitar um desgaste maior por parte do operador sonar. Além disto, decisões automáticas podem ser desenvolvidas como forma de reduzir a carga de trabalho do operador sonar, apoiando a sua decisão quanto a presença ou ausência de um contato.

2.3.5 Equação de um Sistema de Sonar Passivo

O propósito de um sistema de sonar passivo é detectar sinais que estão contaminados por ruído, e medir o desempenho desta detecção. A medida do desempenho pode ser obtida a partir da equação sonar [6]. Uma das formas da equação de um sistema de sonar passivo é:

$$SE = SL - NL + AG - TL - DT \quad (2.1)$$

onde as variáveis da equação 2.1 são descritas como:

- SE - Excesso de sinal na entrada do detector (em dB);
- SL - Nível da fonte na distância de 1 metro do centro acústico da fonte que está irradiando o sinal (nível de pressão do som em dB relativo a $1 \mu Pa$ a 1 metro);
- NL - Nível de ruído no receptor (nível de espectro em db relativo $\mu Pa^2/Hz$;
- AG - Ganho do arranjo que melhora a relação sinal/ruído (SNR) fornecida pela diretividade do sistema de sensores em relação a um hidrofone omnidirecional (em dB);
- TL - Perda na transmissão entre a fonte e o receptor sonar (em dB); e
- DT - Limiar de detecção, ou SNR necessário para o detector ter um desempenho específico (em dB).

Para aplicações militares que usa sistemas de sonar passivo, o ruído irradiado por navios e submarinos é de grande importância na detecção e classificação de contatos. As características dos sinais são modeladas teoricamente a partir de mecanismos geradores destes ruídos [21]. O espectro do ruído irradiado pelo navio é misturado

com o espectro contendo os componentes discretos e contínuos do navio. Como mostrado na Figura 2.2. Os componentes discretos são tons produzidos pela rotação das propulsões, máquinas compressores e bombas. Estes componentes tonais são dependentes ou independentes da velocidade de acordo com a mudança no nível da frequência quando o navio muda de velocidade. O ruído contínuo, chamado de ruído de banda larga se origina do ruído de cavitação e cresce a medida que a velocidade aumenta.

2.4 Características dos sinais recebidos por um sistema de sonar passivo

Os sinais gerados por grande parte das máquinas de um navio pode ser considerado como um sinal e aleatório estacionário no sentido amplo, desde que não ocorra alterações no regime das máquinas, no rumo e na velocidade do contato. Esta situação se mantém durante grande parte do tempo, se alterando apenas eventualmente, quando o contato faz alguma manobra ou altera seu regime de máquinas. Após alguma manobra, as máquinas retornam a uma condição estável, embora, não obrigatoriamente, a mesma em que elas estavam antes. Este sinais são normalmente chamados de ruído. Desta forma, o ruído gerado pelo um contato, proveniente de uma determinada direção, é uma composição dos sinais das diversas máquinas do contato e pode ser considerado estacionário no sentido amplo.

O ruído que é irradiado pelo próprio navio onde os hidrofones estão instalados, sofre alterações, durante sua propagação no ambiente submarino, que fazem com que o sinal, recebido pelo sensor de um sistema de sonar passivo distante, não seja mais um sinal estacionário. Em primeiro lugar, o ruído irradiado varia com em relação à linha proa-popa do navio.

Devido ao que foi abordado anteriormente, o sistema de sonar passivo tem dificuldades, na detecção e classificação de um contato proveniente de uma determinada direção. Um pré-processamento destes sinais, se faz necessário para melhorar a identificação de um contato em uma determinada direção. Dentre os vários, a separação cega de fontes foi escolhida.

Existem vários modelos de separação cega de fontes que podem ser utilizados para melhorar a a detecção e classificação de sinais de sonar passivo. Porém, neste trabalho foi utilizado o modelo básico de separação cega de fontes com o objetivo de melhorar a relação, sinal/interferência e sinal/ruído, de sinais que estejam espacialmente muito próximos, pelo fato do sinais que estão separados, já serem provenientes de das suas respectivas marcações e terem sido adquiridos em águas profundas [5].

Capítulo 3

Separação Cega de Fontes

O objetivo da separação cega de fontes (BSS - Blind Source Separation) é estimar fontes que foram misturadas de alguma forma desconhecida. Daí a utilização da palavra “cega”. A separação cega pretende enfatizar a falta ou quase nenhum conhecimento, que se tem acerca das fontes que deram origem à mistura. A mistura sim, completamente conhecida (dados observados), é o ponto de partida e objeto de trabalho de vários métodos que existem para a resolução do problema da separação cega de fontes [22], [23].

Neste trabalho, o problema de separar ou estimar os parâmetros dos sinais originais a partir do conjunto de amostras recolhidas pelos sensores, sem conhecimento das características das misturas e das fontes, está relacionado com:

- Análise de Componentes Independentes (ICA - Independent Component Analysis) [24] ; e
- Fatoração de Matrizes não Negativas (NMF - Nonnegative Matrix Factorization) [25] .

Este capítulo tem a finalidade de apresentar os principais algoritmos que realizam a separação cega de fontes e métodos relacionados [22], [24] e [25]. No caso dos sinais de sonar passivo, não se tem conhecimento da informação a priori, sobre o sinal, nem sobre o ambiente em que o sinal está sendo propagado. Desta forma, a separação cega de fontes se aplica à extração dos componentes pertencentes a estes sinais misturados.

3.1 Análise de Componentes Independentes

Uma maneira de se realizar a separação cega de fontes é fazer uma análise dos componentes independentes. Isto significa dizer que o valor de um componente não fornece nenhuma informação sobre o valor de qualquer outro. Considerando que os

componentes originais são estatisticamente independentes, então, o que se pretende é extrair os componentes a partir das observações.

A técnica de análise de componentes independentes teve uma grande motivação na década de 80 com a publicação dos trabalhos [26], [27] e [28]. O problema surgiu, primeiramente, em 1982, ligado à neurofisiologia. Era um modelo que tinha por objetivo a codificação do movimento durante a contração muscular. As saídas, destes modelos, eram obtidas a partir de dois sensores que mediam as contrações musculares. A ideia era determinar outros dois sinais que informavam a posição angular e a velocidade da articulação em movimento. Chegou-se a conclusão que o sistema nervoso interferia na posição angular e na velocidade da articulação. Então, foi desenvolvido, em 1991 o trabalho de Jutten et. al. [29] para solucionar este problema.

Como pode ser observado, a ICA era, essencialmente, objeto de pesquisas científicas, somente usada pela comunidade de cientistas franceses e com pouco impacto internacional. Em 1989, foi realizada a primeira oficina internacional de uma área que fazia uma abordagem sobre análise espectral de ordem superior. Foi nesta oficina que surgiram os trabalhos de Cardoso [30] e de Common [31]. Os trabalhos se baseavam em cumulantes para a realização da ICA. Estes trabalhos serviram como base para a criação de dois algoritmos de ICA, o algoritmo JADE e o método de diagonalização de cumulantes de ordem superior [32].

Até os anos 90, trabalhos que abordavam a ICA se mantiveram reduzidos. O grande interesse da comunidade científica em ICA aconteceu em meados do anos 90, depois da publicação dos trabalhos de Common [33]. Posteriormente, em 1995, Bell et. al. [34] implementaram um trabalho que se baseava no princípio informax. Em 1996, Amari implementou um trabalho de separação cega de fontes usando o gradiente natural. Poucos anos depois, surgiu o algoritmo FastICA [35] implementado por Oja, Hyvärinen e Karhunen.

Para a definição do problema de ICA, pode-se recorrer a um modelo estatístico de variáveis latentes. Sendo um modelo gerativo, a ICA descreve como os dados observados são gerados através de um processo de mistura dos componentes independentes.

A análise de componentes independentes considera que um conjunto de N sinais observados $\mathbf{x}(t) = [x_1(t), \dots, x_N(t)]^T$ seja gerado por uma combinação linear de fontes de sinais $\mathbf{s}(t) = [s_1(t), \dots, s_N(t)]^T$:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) \tag{3.1}$$

onde \mathbf{A} é a matriz de misturas $N \times N$ [22]. Sendo formulado, desta maneira, o problema da ICA também pode ser chamado de separação cega de fontes [36] e o

seu propósito é a estimativa das fontes originais $\mathbf{s}(t)$ usando somente os dados $\mathbf{x}(t)$. Uma solução pode ser obtida achando-se a inversa da matriz de misturas $\mathbf{B} = \mathbf{A}^{-1}$ e aplicando-se esta transformação inversa nos sinais observados para, então, obter as fontes originais.

$$\mathbf{s}(\mathbf{t}) = \mathbf{B}\mathbf{x}(\mathbf{t}) \quad (3.2)$$

Um princípio geral para a estimação da matriz \mathbf{B} pode ser formulado considerando que os sinais originais são estatisticamente independentes, ou que eles possam ser tão independentes quanto possível. Informações sobre as estatísticas de ordem superior (HOS - High Order Statistic) são necessárias para a realização da análise de componentes independentes. Existem vários métodos matemáticos para a realização do cálculo dos coeficientes da matriz \mathbf{B} . Porém, a decorrelação não linear e a maximização da não gaussianidade são os mais aplicados [22]. Existem também algumas indeterminações no modelo da ICA, de forma que podem ocorrer mudanças na ordem da extração dos componentes independentes. Multiplicadores escalares também podem fazer modificações nos componentes estimados. Mas, estas indeterminações, na maioria das aplicações, são irrelevantes [24].

O problema pode ser resumido, então, em encontrar os sinais originais sem qualquer conhecimento prévio dos mesmos, conhecendo-se apenas a mistura, que é uma combinação linear desses sinais originais. Nem sempre, se consegue encontrar tal representação, mas pode-se chegar até os componentes que sejam tão independentes quanto possível.

3.1.1 O Princípio da Independência Estatística

O princípio da independência estatística estabelece que, duas variáveis aleatórias \mathbf{a} e \mathbf{b} , são estatisticamente independentes se e somente se [37]:

$$p_{\mathbf{a},\mathbf{b}}(\mathbf{a}, \mathbf{b}) = p_{\mathbf{a}}(\mathbf{a})p_{\mathbf{b}}(\mathbf{b}) \quad (3.3)$$

onde $p_{\mathbf{a},\mathbf{b}}(\mathbf{a}, \mathbf{b})$, $p_{\mathbf{a}}(\mathbf{a})$ e $p_{\mathbf{b}}(\mathbf{b})$ são respectivamente as funções densidade de probabilidade conjunta e marginais (pdf) das variáveis aleatórias \mathbf{a} e \mathbf{b} respectivamente. Uma condição equivalente é obtida se, para todas as funções, $g(\mathbf{a})$ e $h(\mathbf{a})$, que são absolutamente integráveis, obtém-se a seguinte expressão:

$$E\{g(\mathbf{a})h(\mathbf{b})\} = E\{g(\mathbf{a})\}E\{h(\mathbf{b})\} \quad (3.4)$$

onde $E\{\cdot\}$ é o operador de expectância [37].

Em problemas de separação cega de fontes, a estimação direta das pdfs é uma tarefa bastante complicada. A Equação 3.4, fornece uma alternativa para a medida da independência, de modo que vários algoritmos de ICA, que procuram pela

descorrelação não linear, foram desenvolvidos.

Variáveis aleatórias independentes não são correlacionadas, embora a recíproca nem sempre seja verdadeira. A correlação linear é verificada pelas estatísticas de segunda ordem, enquanto a independência, para ser verificada, necessita de informações estatísticas de ordem superior. Em métodos de descorrelação não linear, as funções não lineares apresentam estas estatísticas.

Como mostrado na Equação 3.4, duas variáveis aleatórias são estatisticamente independentes se elas forem descorrelacionadas de forma não linear. Como não é possível verificar toda a integração das funções, $g(\cdot)$ e $h(\cdot)$, a estimativa dos componentes independentes é obtida garantindo a descorrelação não linear entre um conjunto finito de funções não lineares [24]. Como exemplo, pode ser citado um algoritmo, bem conhecido, de Chichoki e Unbehauen proposto em [22]. Este algoritmo obtém os componentes independentes enquanto fornece a descorrelação entre a tangente hiperbólica e uma função polinomial, que são aplicadas aos sinais de entrada.

3.1.2 Não Gaussianidade e Independência

Nesta seção, a independência entre variáveis aleatórias (fontes de sinais) é obtida em termos da não gaussianidade.

Medida da não Gaussianidade

Seja o modelo descrito na Equação 3.1. Esta Equação pode ser reescrita da seguinte forma:

$$x_i = \sum_{j=1}^N a_{ij} s_j \quad i = 1, \dots, N \quad (3.5)$$

O teorema do limite central [37] e [38] afirma que, a soma de variáveis aleatórias independentes vai na direção de produzir uma variável aleatória mais gaussiana do que a distribuição original cada variável. Como descrito na Equação 3.5, os sinais observados x_i são formados por um somatório ponderado das fontes s_i . Desta forma, x_i está mais gaussiana do que as variáveis s_i . Então, os componentes independentes podem ser obtidos através da maximização da não gaussianidade [39].

A gaussianidade e, conseqüentemente, a independência estatística de uma variável aleatória, pode ser medida através de cumulantes de ordem superior. Considerando uma variável aleatória \mathbf{x} , o momento α_k e o momento central μ_k de ordem k são definidos por [38]:

$$\alpha_k = E\{x^k\} = \int_{-\infty}^{\infty} \mathbf{x}^k p_x(\mathbf{x}) dx \quad (3.6)$$

$$\mu_k = E\{(\mathbf{x} - \alpha_1)^k\} = \int_{-\infty}^{\infty} (\mathbf{x} - \alpha_1)^k p_x(\mathbf{x}) dx \quad (3.7)$$

onde $\alpha_1 = m_{\mathbf{x}}$ é a média de \mathbf{x} . Se a variável aleatória \mathbf{x} for uma variável média zero, isto é, $m_{\mathbf{x}} = 0$, então, para todo k tem-se que $\alpha_k = \mu_k$.

O cumulante χ_k de ordem k , é definido em função dos momentos [38]. Por exemplo, para uma variável aleatória \mathbf{x} média zero, os quatro primeiros cumulantes têm as seguintes fórmulas:

$$\chi_1 = 0 \quad (3.8)$$

$$\chi_2 = E\{\mathbf{x}^2\} = \alpha_2 \quad (3.9)$$

$$\chi_3 = E\{\mathbf{x}^3\} = \alpha_3 \quad (3.10)$$

$$\chi_4 = E\{\mathbf{x}^4\} - 3[E\{\mathbf{x}\}^2]^2 = \alpha_4 - 3\alpha_2^2 \quad (3.11)$$

Os cumulantes de terceira e quarta ordem são respectivamente a simetria (χ_3) e a kurtose (χ_4) [22]. Cumulantes de ordem superior aos cumulantes de quarta ordem são raramente aplicados em problemas práticos de ICA. Algumas propriedades interessantes dos cumulantes são:

$$\chi_k(\mathbf{x} + \mathbf{y}) = \chi_k(\mathbf{x}) + \chi_k(\mathbf{y}) \quad (3.12)$$

$$\chi_k(\mathbf{x}) = 0, \quad \text{para } k > 2 \text{ se } \mathbf{x} \text{ for gaussiana} \quad (3.13)$$

Pode-se dizer, então, que os cumulantes de ordem maior do que dois podem ser aplicados para a realização da estimação da gaussianidade de dados. O valor da simetria, por exemplo, está relacionado com a simetria da função de densidade de probabilidade, isto é, $\chi_3 = 0$, indica que a pdf é simétrica. No intervalo de $[-2, \infty)$, quando a kurtose é zero, pode ser um indicativo que a variável é gaussiana. Valores negativos da kurtose indicam que a variável é sub-gaussiana; isto é, a pdf se torna mais suave do que a gaussiana. Por outro lado, valores positivos da kurtose indicam que a variável aleatória é super-gaussiana. Neste caso, a pdf é mais aguda do que a gaussiana [22] e [38]. Kurtose pode ser calculada substituindo a expectância da Equação 3.11 pela média das amostras da variável. Um cuidado que deve ser tomado no cálculo da kurtose é que ela pode sofrer influência considerável aos "outliers" (observações que estão numericamente distantes do resto dos dados). Em casos extremos, o valor da kurtose pode ser calculado por um pequeno número de pontos [40]. Estudos têm obtido uma robusta estimação de cumulantes de ordem superior

[41].

Uma forma alternativa de se medir a gaussianidade de uma variável aleatória pode ser obtida da teoria da informação [42]. Os parâmetros para a realização da medida são, normalmente, mais robustos às medidas discrepantes da variável aleatória. Um exemplo é a negentropia de uma variável aleatória \mathbf{x} , que é calculada através [42]:

$$J(\mathbf{x}) = H(\mathbf{x}_{gauss}) - H(\mathbf{x}) \quad (3.14)$$

onde $H(\cdot)$ é a entropia, e \mathbf{x}_{gauss} é uma variável gaussiana com a mesma média e variância de \mathbf{x} . A entropia é um dos conceitos básicos da teoria da informação e pode ser definida como o nível de informação contido em uma variável aleatória. A entropia $H(\mathbf{x})$ pode ser vista como o comprimento de código mínimo para que a variável aleatória \mathbf{x} tenha representatividade [42]. Se considerarmos a variável aleatória discreta, a entropia é definida como [43]:

$$H(\mathbf{x}) = \sum_i P(\mathbf{x} = a_i) \log P(\mathbf{x} = a_i) \quad (3.15)$$

onde a_i são os possíveis valores assumidos pela variável \mathbf{x} , e $P(\mathbf{x} = a_i)$ é a probabilidade que $\mathbf{x} = a_i$.

As variáveis aleatórias gaussianas têm a máxima entropia entre variáveis de mesma variância [39]. Desta forma, pode ser dito que a entropia e a negentropia podem ser usadas como medidas de gaussianidade. A vantagem da negentropia, como mostra a Equação 3.14, é que ela sempre vai ser não negativa e se tornará zero quando a variável \mathbf{x} for gaussiana. Um problema com o cálculo de $J(\cdot)$ e $H(\cdot)$ em processamento cego de sinais é a estimação da pdf (observe as Equações 3.14 e 3.15). Para evitar este problema, são realizadas aproximações usando cumulantes de ordem superior. Funções não polinomiais também poderão ser aplicadas [39].

Medida da Independência

Uma forma de medir a independência estatística entre variáveis aleatórias pode ser obtida através da informação mútua. A informação mútua entre m variáveis aleatórias, expressa a quantidade de informação que uma variável tem sobre a outra [42]. Então, a minimização da informação mútua leva para a independência estatística. Seja $\mathbf{x} = [x_1, x_2, \dots, x_m]$, então a informação mútua pode ser obtida através da fórmula [39]:

$$I(x_1, \dots, x_m) = \sum_{i=1}^m H(x_i) - H(\mathbf{x}) \quad (3.16)$$

Um outro método da teoria da informação para medir a independência estatística

entre as variáveis aleatórias é a divergência. Na teoria da informação a divergência é o aumento progressivo entre duas distribuições. Um divergência que normalmente é usada para medir esta independência estatística é a divergência de Kullback-Leibler (KL), que é definida pela Equação 3.17, da seguinte forma [22].

$$C_{kl}(q, p) = \int q_x(\mathbf{x}) \log \frac{q_x(\mathbf{x})}{p_x(\mathbf{x})} dx \quad (3.17)$$

A divergência KL tem a finalidade de medir a (dis)similaridade de duas densidades de probabilidades, $p_x(\mathbf{x})$ e $q_x(\mathbf{x})$. Esta divergência é sempre não negativa e atinge o valor mínimo de zero quando as densidades são idênticas. Por exemplo, se uma pdf é gaussiana, então a maximização da Equação 3.17 é equivalente a maximização da não gaussianidade entre as variáveis. A referência [22], mostra que a divergência KL, em determinadas situações, é equivalente a informação mútua.

A medida da independência entre variáveis aleatórias também pode ser realizada usando os cumulantes cruzados [44]. A finalidade dos cumulantes cruzados é medir a independência dos componentes extraídos através dos algoritmos de ICA. Foi derivada uma fórmula para o cálculo da independência através de tensores cumulantes. Um caso especial, onde, $n = 4$ permite o cálculo dessa medida com eficiência, usando matrizes cumulantes.

Como mencionado anteriormente, quando se trata de independência estatística, precisa-se considerar as leis da probabilidade e realizar o cálculo das funções densidade de probabilidade (pdf) das variáveis aleatórias. Mas, na prática, a estimativa destas pdf não é conseguida de forma trivial. Então, para quantificar de que forma esta independência pode ser calculada, necessita-se de se obter os cumulantes cruzados entre as variáveis aleatórias. A fórmula do cumulante de quarta ordem é mostrada a seguir.

$$\chi_{\mathbf{cum}}^4 = \sum_{i,j=1}^n \sum_{k,l=1}^n \mathbf{cum}\{x_i, x_j, x_k, x_l\}^2 \quad (3.18)$$

onde \mathbf{x} é um vetor aleatório cujo os componentes são $x_1 \dots x_n$, tem média zero e $\mathbf{cum}\{x_i, x_j, x_k, x_l\}$ é o cumulante de quarta ordem das variáveis aleatórias x_i, x_j, x_k, x_l que pode ser escrito da seguinte forma [37]:

$$\begin{aligned} \mathbf{Cum}\{x_i, x_j, x_k, x_l\} = & E\{x_i, x_j, x_k, x_l\} - E\{x_i, x_j\}E\{x_k, x_l\} - \\ & E\{x_i, x_k\}E\{x_j, x_l\} - E\{x_i, x_l\}E\{x_k, x_j\} \end{aligned} \quad (3.19)$$

Agora vai ser definido, como em Cardoso [45], uma matriz cumulante de quarta ordem da seguinte maneira:

$$\begin{aligned} \mathbf{cum}_x^{2,2}(\mathbf{A}) &= E\{\mathbf{xx}^T \mathbf{x}^T \mathbf{Ax}\} - E\{\mathbf{xx}^T\}E\{\mathbf{x}^T \mathbf{Ax}\} - \\ &E\{\mathbf{xx}^T\} \mathbf{A} E\{\mathbf{xx}^T\} - E\{\mathbf{xx}^T\} \mathbf{A}^T E\{\mathbf{xx}^T\} \end{aligned} \quad (3.20)$$

onde $\mathbf{A} \in \Re^{n^2}$ é uma matriz. O (i, j) -ésimo elemento de $\mathbf{Cum}_x^{2,2}(\mathbf{A})$ é:

$$\mathbf{Cum}_x^{2,2}(\mathbf{A})_{i,j} = \sum_{k,l=1}^n \mathbf{cum}\{x_i, x_j, x_k, x_l\} \mathbf{A}_{k,l} \quad (3.21)$$

Então, vai ser desenvolvida uma maneira eficiente de calcular $\chi_{\mathbf{cum}}^4(\mathbf{x})$. Se; a $\mathbf{I}_{k,l}$ é uma matriz $n \times n$ que tem 1's nas posições (k, l) e os outros elementos, desta matriz, têm valores iguais a zero. Então da Equação 3.21 obtém-se:

$$\mathbf{Cum}_x^{2,2}(\mathbf{I}_{k,l})_{i,j} = \mathbf{cum}\{x_i, x_j, x_k, x_l\} \quad (3.22)$$

Aplicando 3.21 duas vezes, obtemos:

$$\begin{aligned} \mathbf{Cum}_x^{2,2} \mathbf{Cum}_x^{2,2}(\mathbf{I}_{u,v})_{i,j} &= \sum_{k,l=1}^n \mathbf{cum}\{x_i, x_j, x_k, x_l\} (\mathbf{cum}_x^{2,2}(\mathbf{I}_{u,v}))_{k,l} \\ &= \sum_{k,l=1}^n \mathbf{cum}\{x_i, x_j, x_k, x_l\} \mathbf{cum}\{x_k, x_l, x_u, x_v\} \end{aligned} \quad (3.23)$$

Em particular, quando $(i, j) = (u, v)$ e usando a propriedade da simetria dos cumulantes [22] obtém-se a seguinte fórmula:

$$\mathbf{Cum}_x^{2,2} \mathbf{Cum}_x^{2,2}(\mathbf{I}_{i,j})_{i,j} = \mathbf{cum}\{x_i, x_j, x_k, x_l\}^2 \quad (3.24)$$

Pode-se mostrar, então, que a Equação 3.24 representa o cálculo do cumulante de quarta ordem [44].

Existem duas restrições que são importantes para a extração dos componentes, devido a matriz de separação, que serão mostradas a seguir.

3.1.3 Escalonamento e Permutação

No modelo de análise de componentes independentes não é possível determinar a energia de cada componente independente. Isto se deve ao fato de se poder apenas estimar os sinais originais a menos de uma constante multiplicativa. Sendo desconhecidos quer os sinais e a forma como eles se combinam (a matriz de misturas) para resultar nas observações, qualquer constante multiplicativa de uma fonte pode ser cancelada dividindo a coluna da matriz de misturas correspondente a esta fonte

pela mesma constante. A Equação 3.25 mostra como isto acontece.

$$\begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} \frac{1}{\sigma}a_{11} & a_{12} & \cdots & a_{1n} \\ \frac{1}{\sigma}a_{21} & \cdots & & \vdots \\ \vdots & & \ddots & \vdots \\ \frac{1}{\sigma}a_{n1} & & & a_{nn} \end{pmatrix} \begin{pmatrix} \sigma s_1 \\ s_2 \\ \vdots \\ s_n \end{pmatrix} \quad (3.25)$$

Esta constante, σ , pode alterar a magnitude dos sinais, porém, ela não altera os seus formatos.

A ordem com que os componentes são obtidos também é indeterminada. Existe uma matriz de permutação que pode mudar esta ordem na extração dos componentes. Desta forma, pode-se concluir que a matriz de separação é composta pela combinação de uma matriz de escalonamento \mathbf{W} e uma matriz de permutação \mathbf{P} .

$$\mathbf{B} = \mathbf{WP} \quad (3.26)$$

Por exemplo, considere o caso onde se deseja extrair três componentes de uma mistura que tem o modelo conforme mostra a Equação 3.27, onde a mistura tem o mesmo número de componentes.

$$\begin{pmatrix} x_1 \\ x_2 \\ x_2 \end{pmatrix} = \mathbf{A} \begin{pmatrix} s_1 \\ s_2 \\ s_3 \end{pmatrix} \quad (3.27)$$

Sempre é possível encontrar uma matriz de permutação onde o modelo pode ser verificado. A matriz \mathbf{P} e a sua inversa são mostradas na Equação 3.28.

$$\mathbf{P} = \begin{pmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{pmatrix} \quad \mathbf{P}^{-1} = \begin{pmatrix} 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{pmatrix} \quad (3.28)$$

Pode-se concluir que a matriz de permutação resulta apenas na alteração da ordem dos sinais.

Com as restrições de escalonamento e permutação, do modelo para a extração dos componentes independentes, a questão central da ICA continua a ser de se obter uma estimativa para os componentes independentes ($\hat{\mathbf{S}}$) que combinadas linearmente dão origem a uma matriz de misturas \mathbf{X} .

3.1.4 Estimação das Funções Densidade de Probabilidade

Desde o final de 1890, várias formas para realizar a estimação de funções de densidade de probabilidades (pdfs) têm sido propostas. A partir de 1956 os métodos

de estimação de funções de densidade de probabilidade não paramétricas têm sido consolidados como uma alternativa sofisticada para tratamento tradicional de um conjunto de dados. A função de densidade é um conceito fundamental em estatística. Esta função é definida como real, mensurável, não negativa e satisfaz a seguinte condição:

$$\int_{-\infty}^{+\infty} f(x)d(x) = 1 \quad (3.29)$$

Estimação da pdf usando o Histograma

Por exemplo, pode-se usar o histograma para a estimação da pdf. Seja, I_1, I_2, \dots, I_n intervalos de dados tal que $x \in I_i$ para cada $i = 1, \dots, n$, o histograma \hat{f} é um estimador de máxima verossimilhança dentre os estimadores [46]. Este estimador tem a seguinte fórmula:

$$\hat{f} = \frac{n_i}{n|I_i|} \quad (3.30)$$

onde $|I_i|$ representa o comprimento do intervalo i e n_i o número de elementos na amostra I_i .

A estimação usando histograma tem limitações importantes. Dentre elas é a dependência do comprimento do intervalo e o fato de o histograma não constituir uma função contínua [46], [47] e [48].

Estimação da pdf usando Kernel

Sejam x_1, \dots, x_n observações independentes e identicamente distribuídas que têm uma determinada função densidade de probabilidade f . Vamos, então, considerar a seguinte estimativa dessa função densidade de probabilidade.

$$f_n(x, h) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right) \quad (3.31)$$

onde $K(\bullet)$, representa uma função núcleo, também chamada de função de kernel, e h é a largura de banda dessa função, que determina a suavização da curva da densidade estimada. A função de kernel deve satisfazer a seguinte propriedade:

$$\int K(x)d(x) = 1 \quad (3.32)$$

Silverman, [49], apresenta uma discussão sobre a escolha do núcleo ideal para a estimação das pdfs, mostrando um índice de eficiência de cada um dos núcleos utilizados. A Tabela 3.1 mostra a fórmula e a eficiência de cada uma das funções kernel que foram abordadas por Silverman. Pode ser observado através da Tabela,

que a maior eficiência entre as funções núcleos é a de Epanechnikov.

Tabela 3.1: Funções Kernel e suas eficiências

Kernel	Função analítica, $K(x)$	Eficiência
Epanechnikov	$\frac{3}{4}(1 - x^2)$ para $ x \leq 1$	1
Biquadrada	$\frac{15}{16}(1 - x^2)^2$ para $ x \leq 1$	0,9939
Triangular	$1 - x $ para $ x \leq 1$	0,9859
Gaussiana	$\frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right)$ para $ x \leq 1$	0,9512
Uniforme	$\frac{1}{2}$ para $ x \leq 1$	0,9295

O parâmetro h , também chamado de parâmetro de suavização ou janela tem um valor positivo e não aleatório. O valor de h é crítico na estimação da densidade. Vários métodos têm sido propostos para a escolha de um valor de h ideal [49] e [50].

Como pode ser observado pela fórmula 3.31, a função de densidade é estimada baseada em dois parâmetros: o parâmetro de suavização, h , e a função kernel. Se a janela h e a função kernel são corretamente especificadas, então a correspondente função de densidade estimada será única para aquele conjunto de dados.

Assim, deve ser escolhido o valor de h que seja ótimo para que possa ser obtido uma única função de densidade. Uma maneira de realizar a escolha de h é minimizar o erro médio quadrático dado por:

$$\hat{h}_0 = 1,06 \min \left(\hat{\sigma}_x, \frac{\hat{R}}{1,34} \right) n^{-0,2} \quad (3.33)$$

onde $\hat{\sigma}_x$ é a estimação da variância de x , \hat{R} representa a extensão do interquartil de x , dado por: $\hat{R} = x_{0,75} - x_{0,25}$ e n é o número de observações.

O uso dos diferentes métodos para o cálculo da independência tem proporcionado várias rotinas para a estimação da matriz de separação \mathbf{B} [39]. Serão considerados a seguir alguns destes algoritmos que realizam a ICA.

3.1.5 Algoritmo JADE

O algoritmo JADE (Joint Approximate Diagonalization of Eigenmatrices) realiza a separação cega de fontes através da otimização dos cumulantes, que é implementada nos dados de forma implícita, usando algoritmos da teoria da informação [42]. Estes algoritmos operam nos cumulantes cruzados de segunda e quarta ordem.

O tensor cumulante é um operador linear que é definido pelo cumulante de quarta ordem $cum(x_i, x_j, x_k, x_l)$ [39]. Esta operação linear gera uma matriz na forma da Equação 3.34. No algoritmo JADE, a autodecomposição dos autovalores é conside-

rada como um pré-processamento dos dados:

$$F_{ij}(\mathbf{M}_i) = \sum_{kl} m_{kl} cum(x_i, x_j, x_k, x_l) \quad (3.34)$$

onde m_{kl} é um elemento da matriz \mathbf{M}_i que é transformada, e \mathbf{x} é um vetor aleatório de dimensão $n \times 1$. O cumulante de segunda ordem é usado para garantir o branqueamento dos dados. Um conjunto de matrizes cumulantes é estimado dos dados branqueados, conforme na Equação 3.34, e a matriz $\mathbf{F}(\mathbf{M})$ é diagonalizada através da matriz \mathbf{W} para alguma matriz \mathbf{M}_i .

$$\mathbf{Q} = \mathbf{W}F(\mathbf{M}_i)\mathbf{W}^T \quad (3.35)$$

A minimização da soma dos quadrados dos elementos fora da diagonal da Equação 3.35 é equivalente à maximização da soma dos quadrados dos elementos da diagonal, pelo fato da matriz ortogonal W não realizar mudanças na soma total dos quadrados de uma matriz. A maximização do algoritmo JADE é um método que fornece uma aproximação conjunta da diagonal de $F(\mathbf{M}_i)$ [39].

$$J_{JADE}\mathbf{W} = \sum_i \|diag(\mathbf{W}F(\mathbf{M}_i)\mathbf{W}^T)\|^2 \quad (3.36)$$

3.1.6 Algoritmo FastICA

Os componentes independentes também podem ser extraídos de uma mistura, realizando o princípio da não gaussianidade, em termos da kurtose ou negentropia [39] e [51]. Considerando uma mistura \mathbf{x}_i é possível realizar a estimação dos componentes independentes através de uma função custo, como mostrado na Equações 3.37 e 3.38., onde \mathbf{W} é uma matriz de ponderação, e \mathbf{z} é o vetor de dados branqueado por uma matriz \mathbf{V} , $\mathbf{z} = \mathbf{V}\mathbf{x}$.

$$\mathbf{x} = \mathbf{W}^T \mathbf{z} \quad (3.37)$$

$$\frac{\partial |kurt(\mathbf{W}^T \mathbf{z})|}{\partial \mathbf{W}} = 4sign[kurt(\mathbf{W}^T \mathbf{z})] E \left\{ \mathbf{z}(\mathbf{W}^T \mathbf{z} - 3\mathbf{W}\|\mathbf{W}\|^2) \right\} \quad (3.38)$$

Com a finalidade de tornar o algoritmo mais rápido, o gradiente é calculado na forma da Equação 3.39.

$$\Delta \mathbf{W} \propto sign(kurt(\mathbf{W}^T \mathbf{z})) E \left\{ \mathbf{z}(\mathbf{W}^T \mathbf{z}) \right\} \quad (3.39)$$

Uma normalização em \mathbf{W} , $\mathbf{W} \leftarrow \frac{\mathbf{W}}{\|\mathbf{W}\|}$, é realizada para se evitar uma divergência no algoritmo. O algoritmo FastICA [52] otimiza esta matriz de ponderação.

Uma outra possibilidade de maximização da não gaussianidade é a negentropia [22]. O método clássico de aproximação usando a negentropia é baseado em cumulantes de ordem superior e a expansão polinomial dos valores de entrada \mathbf{x} como $G(\mathbf{x}) = \log[\cosh(\mathbf{x})]$ ou $-\exp(\frac{\mathbf{x}^2}{2})$ [35]. Usando um algoritmo gradiente baseado neste método, as funções polinomiais mencionadas anteriormente poderão ser aplicadas no algoritmo FastICA como é mostrado na Equação 3.40.

$$\mathbf{W} \leftarrow E \{ \mathbf{z}g(\mathbf{W}^T \mathbf{z}) \} - E \{ g^*(\mathbf{W}^T \mathbf{z}) \} \mathbf{W} \quad (3.40)$$

3.1.7 Algoritmo Newton-Like Multiplicativo

Como observado anteriormente, o problema da otimização tem a finalidade de encontrar uma matriz ideal (ótima) sob determinadas restrições. Um algoritmo multiplicativo foi proposto por Akuzawa e Murata [53], usando a kurtose como função custo. Este método aplica a otimização de segunda ordem (através de um algoritmo Newton-like) para buscar os componentes independentes [54].

Neste algoritmo não é necessário o pré-branqueamento dos dados de entrada. O algoritmo trabalha diretamente sobre os dados. Resultados experimentais foram obtidos em [55] indicam que, o algoritmo desenvolvido pelo Akuzawa e Murata, tem um desempenho melhor, na realização da ICA, do que os algoritmos FastICA e o JADE [36].

A proposta deste algoritmo é encontrar um transformação linear $\mathbf{y} = \mathbf{B}\mathbf{x}$ onde $\mathbf{x} = [x_1, \dots, x_N]^T$ é o vetor das misturas, $\mathbf{y} = [y_1, \dots, y_N]^T$ é o vetor que contém as estimativas das fontes e \mathbf{B} é a matriz de separação (matriz de (des)mistura). A seguir serão mostrados os passos executados durante as iterações:

1. Escolha B_0 e $\Delta_0(N \times N)$;
2. Avalie a iteração: $B_i = \exp(\Delta_{i-1})B_{i-1}$;
3. Avalie a função custo em B_i usando a expansão de segunda-ordem em torno de B_{i-1} ;
4. Δ_i é escolhido como ponto de sela da função custo;
5. Volte para o passo de número 2 até a convergência.

3.2 Fatoração de Matrizes não Negativas

A fatoração de matrizes não negativas (NMF - Non-negative Matrix Factorization) começou a ter uma grande motivação a partir da publicação do trabalho de Lee et. al em [56]. Neste trabalho, foi desenvolvido uma aplicação para o processamento de imagens e mineração de dados.

Uma outra área onde a NMF também tem sido utilizada, é em aplicações musicais. A ideia é que através da NMF se consiga uma melhor qualidade da música.

Algoritmos de aprendizado não supervisionados, tais como, análise de componentes principais e quantização vetorial [57], [58], podem ser entendidos como fatoração de uma matriz de dados, sujeita a diferentes restrições. Dependendo da restrição utilizada, a fatoração resultante pode ser levada para diferentes propriedades na sua representação. Por exemplo, a análise de componentes principais impõe uma restrição de ortogonalidade, resultando em uma representação da máxima variância dos dados. Já a quantização vetorial resulta na clusterização dos dados em agrupamentos mutuamente exclusivos.

A fatoração de matrizes não negativas tem por objetivo decompor uma matriz de dados \mathbf{X} em um produto de matrizes \mathbf{A} e \mathbf{S} respectivamente. Pode ser observado que, pelo fato da matriz de dados ser não negativa, para a realização de sua fatoração, esta restrição faz com que se possa já ter aprendido uma parte da representação dos dados [25].

Como já mencionado anteriormente, dada uma matriz de dados não negativa $\mathbf{X} \in \mathbb{R}^{m \times N}$, o objetivo da fatoração é encontrar duas matrizes não negativas $\mathbf{A} \in \mathbb{R}^{m \times n}$ e $\mathbf{S} \in \mathbb{R}^{n \times N}$ tal que:

$$\mathbf{X} \approx \mathbf{AS} \tag{3.41}$$

Pode-se reescrever a Equação 3.41 na forma de coluna por coluna $x \approx \mathbf{As}$, onde \mathbf{x} e \mathbf{s} são as colunas correspondentes das matrizes \mathbf{X} e \mathbf{S} respectivamente. Isto é, cada vetor \mathbf{x} correspondente a uma combinação linear das colunas de \mathbf{A} , ponderados pelos componentes de \mathbf{s} . Desta forma, a \mathbf{A} pode ser considerada como a matriz que contém a base que é otimizada para a aproximação linear dos dados em \mathbf{X} .

A seguir serão mostradas algumas funções custo que podem ser usadas para a fatoração de matrizes não negativas. O objetivo destas funções é fazer com que o modelo da Equação 3.41 se aproxime cada vez mais da relação $\mathbf{X} = \mathbf{AS}$.

3.2.1 Fatoração de Matrizes usando o Método das Divergências

Uma maneira de estimar as matrizes \mathbf{A} e \mathbf{S} para realização da fatoração da matriz \mathbf{X} é considerar uma medida da similaridade para quantificar a diferença entre a matriz de dados, \mathbf{X} e o modelo aproximado $\hat{\mathbf{X}} = \mathbf{AS}$. A escolha desta medida da similaridade (também chamada de distância, divergência ou dissimilaridade) depende da distribuição da probabilidade dos sinais estimados. A seguir serão abordados alguns métodos que serão usados como função custo para a realização da fatoração de matrizes.

Distância Euclidiana

A medida da divergência mais simples e frequentemente mais usada é baseada na distância Euclidiana quadrática, também chamada de norma de Frobenius [23]:

$$D_F(\mathbf{X}||\mathbf{AS}) = \frac{1}{2}\|\mathbf{X} - \mathbf{AS}\|_F^2 \quad (3.42)$$

Pode ser observado da Equação 3.42 que a função custo Euclidiana é convexa em relação a matriz \mathbf{A} ou a matriz \mathbf{S} , mas não é em relação a ambas. Desta forma, pode ser realizada a minimização da função custo em relação a cada uma das matrizes. Isto é, fixa-se o valor de \mathbf{A} e minimiza-se \mathbf{S} e posteriormente é feito ao contrário. Isto nos conduz para o algoritmo chamado de mínimos quadrados alternativos (ALS - Alternating Least Square).

O algoritmo ALS tem sido uma abordagem muito usada para a realização da NMF. Contudo, não é garantido a convergência para um mínimo global nem para um ponto estacionário, mas o algoritmo vai para uma solução onde a função custo deixa de diminuir [59].

Para a realização da fatoração da matriz \mathbf{X} se faz necessário encontrar as matrizes \mathbf{A} e \mathbf{S} ótimas de forma a atender a Equação 3.41. A atualização destas matrizes é realizada usando a seguinte regra multiplicativa [60]:

$$a_{ij} \leftarrow a_{ij} \frac{[\mathbf{XS}^T]_{ij}}{[\mathbf{ASS}^T]_{ij}}, \quad s_{jk} \leftarrow s_{jk} \frac{[\mathbf{A}^T\mathbf{X}]_{jk}}{[\mathbf{A}^T\mathbf{AS}]_{jk}} \quad (3.43)$$

Divergência de Kullback-Leibler

Uma outra medida da divergência entre matrizes, que é normalmente utilizada como função custo, para a fatoração de matrizes, é a divergência de Kullback-Leibler, que

é dada pela Equação:

$$D_{KL}(\mathbf{X}||\mathbf{AS}) = \sum_{ik} \left(x_{ik} \log \frac{x_{ik}}{z_{ik}} + z_{ik} - x_{ik} \right) \quad (3.44)$$

onde $z_{ik} = a_{ik}s_{ik}$. A atualização das matrizes \mathbf{A} e \mathbf{S} é realizada usando a regra multiplicativa [60]:

$$a_{ij} \leftarrow a_{ij} \frac{\sum_{k=1}^N x_{jk} (x_{ik}/z_{ik})}{\sum_{p=1}^N x_{jp}}, \quad s_{jk} \leftarrow s_{jk} \frac{\sum_{i=1}^m a_{ij} (s_{ik}/z_{ik})}{\sum_{q=1}^m a_{qj}} \quad (3.45)$$

Embora a distância Euclidiana quadrática e a divergência de Kullback-Leibler sejam convexas somente para cada uma das matrizes \mathbf{A} ou \mathbf{S} , elas não são conjuntamente convexas. Então, a abordagem básica para a realização da NMF é alternar a minimização em relação aos dois conjuntos de parâmetros a_{ij} e s_{jk} . Isto é, a cada tempo de otimização uma matriz é atualizada enquanto a outra permanece fixa [23].

Divergência Alfa

A divergência alfa pode ser derivada da divergência de Csiszár [23] e tem sido usada para a separação cega de fontes. Realizando a variação do valor de α , na fórmula da divergência alfa, pode-se chegar até outras divergências. A fórmula da divergência alfa é mostrada abaixo.

$$D_A^{(\alpha)}(\mathbf{X}||\mathbf{AS}) = \frac{1}{\alpha(\alpha-1)} \sum_{ik} (x_{ik}^\alpha z_{ik}^{1-\alpha} - \alpha x_{ik} + (\alpha-1)z_{ik}), \quad \alpha \in \mathbb{R}. \quad (3.46)$$

Existem valores de α onde a divergência alfa assume casos especiais. Para $\alpha = 2, 0, 5$ e -1 , respectivamente, a divergência alfa se torna as distâncias Chi-square, Hellinger e Pearson respectivamente [25]. A Equação de cada uma destas distâncias são mostradas a seguir em relação aos respectivos α .

$$D_A^{(2)}(\mathbf{X}||\mathbf{AS}) = D_{Chi}(\mathbf{x}||\mathbf{z}) = \frac{1}{2} \sum_i \frac{(x_i - z_i)^2}{z_i}; \quad (3.47)$$

$$D_A^{(1/2)}(\mathbf{X}||\mathbf{AS}) = 2D_H(\mathbf{x}||\mathbf{z}) = 2 \sum_i (\sqrt{x_i} - \sqrt{z_i})^2; \quad (3.48)$$

$$D_A^{(-1)}(\mathbf{X}||\mathbf{AS}) = D_P(\mathbf{x}||\mathbf{z}) = \frac{1}{2} \sum_i \frac{(x_i - z_i)^2}{z_i}. \quad (3.49)$$

Para os casos de $\alpha = 1$ e $\alpha = 0$ a divergência α pode ser definida respectivamente pelos limites $\alpha \rightarrow 1$ e $\alpha \rightarrow 0$. Quando a divergência α é avaliada em torno destes limites chega-se a divergência generalizada de Kullback-Leibler que é definida pelas

Equações 3.50 e 3.51.

$$\lim_{\alpha \rightarrow 1} D_A^{(\alpha)}(\mathbf{X}||\mathbf{AS}) = D_{KL}(\mathbf{X}||\mathbf{AS}) = \sum_{ik} \left(x_{ik} \ln \frac{x_{ik}}{[\mathbf{AS}]_{ik}} + [\mathbf{AS}]_{ik} - x_{ik} \right) \quad (3.50)$$

$$\lim_{\alpha \rightarrow 1} D_A^{(\alpha)}(\mathbf{AS}||\mathbf{X}) = D_{KL}(\mathbf{AS}||\mathbf{X}) = \sum_{ik} \left([\mathbf{AS}]_{ik} \ln \frac{[\mathbf{AS}]_{ik}}{x_{ik}} - [\mathbf{AS}]_{ik} + x_{ik} \right) \quad (3.51)$$

Divergência Beta

Uma outra divergência que é usada como função custo para a realização da fatoração de matrizes não negativas é a divergência β . Esta divergência é parametrizada por β [61], sendo β um número real, diferente de 0 e -1 . A fórmula da divergência β é mostrada na Equação 3.52. Nota-se que, para o caso em que β assume o valor 1, obtém-se a distância Euclidiana, enquanto que para os casos de $\beta = 0$ e $\beta = -1$ a divergência β deve ser definida nos casos limites quando $\beta \rightarrow 0$ e $\beta \rightarrow -1$.

$$D_B^\beta(\mathbf{X}||\mathbf{AS}) = \sum_{ik} \left(x_{ik} \frac{x_{ik}^\beta - |\mathbf{AS}|_{ik}^\beta}{\beta} - \frac{x_{ik}^{\beta+1} - |\mathbf{AS}|_{ik}^{\beta+1}}{\beta + 1} \right) \quad (3.52)$$

Quando este limite é avaliado para $\beta \rightarrow 0$, a divergência generalizada de Kullback-Leibler é obtida, sendo definida como:

$$\lim_{\beta \rightarrow 0} D_B^\beta(\mathbf{X}||\mathbf{AS}) = D_{KL}(\mathbf{X}||\mathbf{AS}) = \sum_{ik} \left(x_{ik} \ln \frac{x_{ik}}{[\mathbf{AS}]_{ik}} - x_{ik} + [\mathbf{AS}]_{ik} \right) \quad (3.53)$$

e quando o limite é avaliado para $\beta \rightarrow -1$, obtém-se a distância de Itakura-Saito como mostrado na Equação 3.54 [62].

$$\lim_{\beta \rightarrow -1} D_B^\beta(\mathbf{X}||\mathbf{AS}) = D_{IS}(\mathbf{X}||\mathbf{AS}) = \sum_{ik} \left(\ln \frac{x_{ik}}{[\mathbf{AS}]_{ik}} + \frac{x_{ik}}{[\mathbf{AS}]_{ik}} - 1 \right) \quad (3.54)$$

Capítulo 4

Metodologia de Análise e Operação do Sistema

Neste capítulo, será mostrada a metodologia de análise utilizada para a realização da separação cega de fontes, tanto no domínio do tempo quanto no domínio da frequência. A separação cega será utilizada como ferramenta, nas análises DEMON e LOFAR, com o objetivo de melhorar a detecção da propulsão e a classificação de contatos. Serão propostos um conjunto de índices de modo a avaliar o desempenho do sistema proposto. Além disso, serão descritos os dados utilizados neste trabalho, tanto simulados como experimentais.

Será feita também a proposição de uma metodologia para realizar a monitoração dos espectros dos sinais de sonar passivo, que foram obtidos através da análise DEMON, com o objetivo de acompanhar o comportamento estatístico destes sinais, para estabelecer o momento em que a matriz de separação deverá ser atualizada.

Para a separação cega dos sinais foram usados, algoritmos que utilizam, a análise de componentes independentes (ICA), e a fatoração de matrizes não negativas (NMF). O uso da ICA se deve ao fato de tentar aproveitar as características da independência entre os contatos que estão sendo analisados, enquanto que, a NMF não utiliza estas características, porém, pelo da fatoração ser realizada com matrizes não negativas, faz com que já se tenha alguma informação a priori à respeito das características dos sinais.

Foram utilizados os seguintes algoritmos de ICA:

1. FastICA - Algoritmo de ponto fixo, usa a negentropia como função custo para a realização da estimação dos componentes independentes. Os componentes são estimados por deflação e foi utilizada a tangente hiperbólica como função de não linearidade.
2. JADE - Algoritmo que realiza a separação cega de fontes através da otimização dos cumulantes.

3. Newton-like - Algoritmo que aplica a otimização de segunda ordem (através de um algoritmo Newton-like) para buscar os componentes independentes.

Para a NMF, foi utilizado o algoritmo de mínimos quadrados para a realização da fatoração, na matriz de misturas, com a finalidade seja criada uma matriz que contenha os componentes estimados. Para isto, o algoritmo necessita de uma função custo para ser minimizada. Neste trabalho foram usadas as seguintes funções custo:

1. Distância Euclidiana.
2. Divergência de Kullback-Leibler


Como o algoritmo NMF usa somente valores positivos, na sua implementação, e os sinais de sonar passivo contém valores negativos na sua aquisição, para a metodologia no domínio do tempo, foi adicionado à todas as amostras do sinal o valor mínimo da função densidade de probabilidade.

Será, também, mostrado como o sistema deve operar, na prática, nas análises DEMON e LOFAR, com a finalidade de avaliar em que momento as técnicas de separação cega de fontes vão ser aplicadas.


4.1 Dados utilizados

Os dados utilizados neste trabalho, foram obtidos por simulação e testes experimentais, a partir da colaboração com a Marinha do Brasil. A frequência de amostragem foi mantida em $f_s = 31.250$ Hz e os sinais foram recortados em janelas temporais de 60 s. A escolha do tamanho da janela se deve ao fato de que, em função da reamostragem que é realizada, durante a análise DEMON, o tempo mínimo, para que seja garantida uma boa resolução de frequência, é de aproximadamente 20 s para uma FFT de 1.024 bins de frequências. A seguir, serão mostrados como estes dados foram adquiridos.

- **Dados simulados** - Foram adquiridos por meio de um simulador de sonar passivo para treinamento de operadores de sonar da Marinha do Brasil. Neste simulador, foi criado um cenário operacional onde dois navios, que estão em permanente regime de cavitação, partindo de marcações distintas (M1 e M2), algum tempo depois, se aproximam o suficiente para que haja uma interferência entre os sinais adquiridos. A característica principal destes dados é o alto índice de cavitação, que permite a identificação da propulsão dos contatos através da análise DEMON. Cada um dos sinais adquiridos tem uma duração, aproximada, de 1.020 s (17 minutos). A Figura 4.1 mostra a análise DEMON de cada um contatos. Pode ser observado que o contato 1, Figura 4.1(a), pro-



(a) Contato 1



(b) Contato 2

Figura 4.1: Análise DEMON dos 1.020 segundos dos sinais simulados.

duz rotações entre 471 e 477 rpm, enquanto as rotações do contato 2, Figura 4.1(b), ficam entre 386 e 392 rpm. A partir de um determinado momento, ≈ 780 s (janela temporal número 13), começa a existir uma interferência cruzada, caracterizando que existe uma aproximação entre os contatos. Uma outra observação importante é que até o instante de tempo de 600 s aproximadamente, a rotação de cada um dos contatos permaneceu em 477,5 e 392,6 rpm, respectivamente. Posteriormente, as rotações sofreram modificações, ficando em 471,5 e 386,6 rpm. Isto aconteceu pelo fato de que, durante a aproximação, ocorreu uma variação na velocidade dos contatos, no simulador. Estes dados têm por objetivo avaliar o desempenho do sistema de separação cega de fontes, pois, a simulação controlada facilita a estimativa das fontes

originais que devem ser separadas.

- **Dados Experimentais** - Foram adquiridos de um sistema de sonar passivo real, que está instalado nos submarinos da Marinha do Brasil. A aquisição foi realizada entre duas marcações próximas, que estão sofrendo a interferência cruzada, a interferência do ruído do próprio submarino, além do ruído ambiente. A duração aproximada de cada um dos sinais é de 200 s (3 minutos e 20 segundos). As Figuras 4.2, 4.3 e 4.4 mostram as análises DEMON, de cada um dos contatos e do ruído próprio. Pode-se notar que a marcação 190, produz a rotação de 146,5 rpm e uma rotação harmônica de 293 rpm. Isto caracteriza um navio de um eixo com duas pás. Além disto, esta marcação está sofrendo a interferência da marcação 205, através da rotação 120,1 rpm e do ruído próprio, 304,7 rpm. Por outro lado, a marcação 205 está sofrendo a interferência do ruído próprio, rotação de 304,7 rpm.

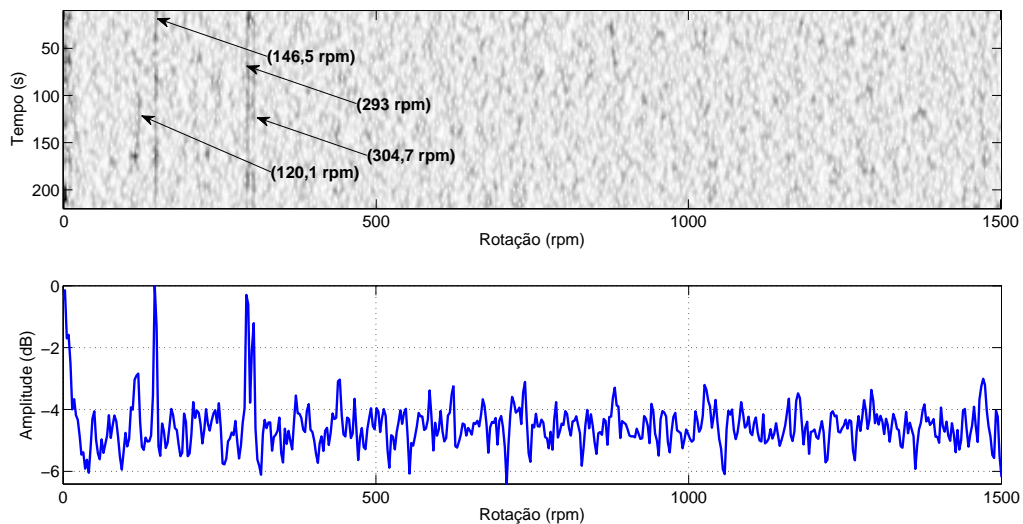


Figura 4.2: Análise DEMON da marcação 190.

Com estes dados, será possível realizar, também, a análise LOFAR possibilitando a caracterização do ruído hidrodinâmico do contato (assinatura do navio), permitindo através dos espectros obtidos por esta análise, a realização da classificação dos contatos usando redes neurais.

Devido ao fato dos sinais experimentais terem sido adquiridos no ambiente acústico submarino, que tem um comportamento não estacionário, devido as mudanças contínuas dos parâmetros inerentes ao ambiente, como por exemplo a temperatura, a salinidade, entre outros parâmetros., se faz necessária a monitoração, desta estacionaridade, para verificar o momento que a matriz de

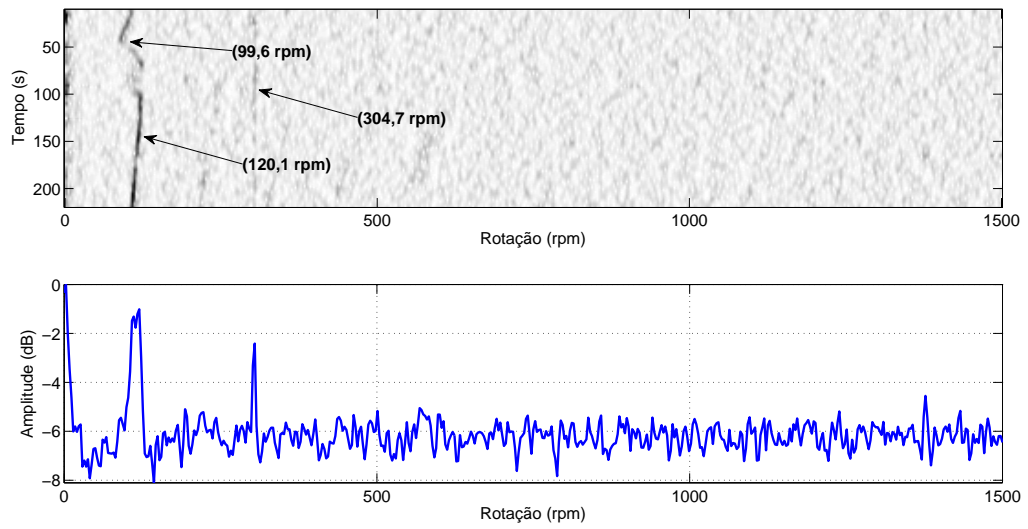


Figura 4.3: Análise DEMON da marcação 205.




Figura 4.4: Análise DEMON do ruído próprio.

separação deverá ser atualizada, garantindo a separação cega das fontes. A ideia é implementar um sistema que faça o acompanhamento dos sinais nas marcações que estão sofrendo a interferência cruzada.

Com estes dados será permitido, na prática, uma avaliação cega do sistema de separação de fontes, haja vista não haver o conhecimento das fontes a serem estimadas.

4.2 Metodologia de Análise

A separação cega de fontes foi utilizada, tanto na análise DEMON quanto na análise LOFAR, para a realização da detecção da propulsão e classificação de contatos de um sistema de sonar passivo. Em cada uma das análises foi criada uma metodologia para estimação dos componentes com o objetivo de melhorar a identificação dos contatos por parte do operador sonar.

A análise DEMON contém um pré-processamento, que é composto por uma filtragem em banda na faixa entre 1 e 2 kHz. Após esta filtragem ocorre uma demodulação em amplitude e uma reamostragem, para que os sinais sejam colocados dentro da banda de propulsão. Então, os sinais são transformados para o domínio da frequência para a verificação das amplitudes das rotações dos contatos.

A separação cega foi aplicada, antes e depois do pré-processamento na análise DEMON e, após a transformação para o domínio da frequência, com o objetivo de melhorar a detecção da propulsão dos contatos.

Já para a classificação dos contatos, a separação cega, foi utilizada nos espectros obtidos pela análise LOFAR e submetidos através de uma rede neural.

4.2.1 Domínio do tempo

No domínio do tempo, foram utilizadas duas metodologias para a realização da análise dos dados da propulsão dos contatos. A diferença entre as duas realizações é o momento em que os algoritmos de BSS são aplicados.

- Dados no domínio do tempo (1) - A Figura 4.5, mostra o diagrama de blocos da operação no domínio do tempo dos dados sem o pré-processamento dos dados adquiridos. Após a aquisição das marcações em janelas temporais de 60 s, é realizada a separação cega dos sinais, seguida de um pré-processamento que é composto por uma filtragem, demodulação e reamostragem, para que os sinais fiquem na faixa de frequência da propulsão dos contatos. Na sequência, os sinais são transformados para o domínio da frequência através de uma transformada de Fourier. Pelo fato da separação cega ter sido realizada em

toda a banda de frequência do sinal (entre 0 e 15.625 Hz), e sabe-se que a faixa de propulsão está contida bem no início, desta banda (entre 0 e 25 Hz), é possível que os algoritmos utilizados para a separação, em toda a banda, não tenham uma boa eficiência, devido a baixa relação sinal ruído.




Figura 4.5: Diagrama de blocos da metodologia no domínio do tempo (1).

- Dados no domínio do tempo (2) - A Figura 4.6 mostra o diagrama de blocos da operação no domínio do tempo dos dados pré-processados.




Figura 4.6: Diagrama de blocos da operação no domínio do tempo (2).

Nesta configuração, o pré-processamento dos sinais (filtragem, demodulação e reamostragem) é realizado de forma que os dados fiquem dentro da banda da propulsão dos contatos. Então, a separação cega é realizada, seguida de uma FFT para a apresentação dos sinais. Pelo fato da separação está sendo realizada na banda propulsão dos sinais, já estão sendo eliminados alguns componentes que não são de interesse.

4.2.2 Domínio da frequência

A Figura 4.7 mostra o diagrama de blocos da metodologia no domínio da frequência. Como já foi mencionado na metodologia do domínio do tempo, (1) e (2), cada uma das marcações é dividida em blocos temporais de 60s e um pré-processamento é implementado, com o objetivo de colocar os sinais dentro da faixa de propulsão dos contatos. Então, os sinais são transformados para o domínio da frequência, através da transformada de Fourier. A separação cega dos sinais, então, é realizada. A transformação dos dados para o domínio da frequência caracterizam os bins de frequência de cada contato. Isto poderá ser eficaz, na separação cega de fontes, principalmente nos algoritmos de ICA.




Figura 4.7: Diagrama de blocos da metodologia aplicada no domínio da frequência.

4.3 Monitoração da estacionaridade

Um sinal quando se propaga em um ambiente acústico submarino, está continuamente sofrendo mudanças e muitas das vezes dificultando a detecção do mesmo por parte do operador sonar. Qualquer estrutura capaz de reconhecer e rastrear as possíveis alterações no comportamento estatístico do sinal deve ter plasticidade, para aprender e se adaptar rapidamente a estas mudanças, e ser de baixa complexidade de implementação, para ser integrado na operação do sistema de separação cega de fontes, de forma a estabelecer o momento que a separação deverá se iniciada. Sistemas inteligentes com estas características de aprendizado, que usam redes neurais, por exemplo, dependem do conjunto de dados para a realização do seu projeto. A ideia é, então, monitorar os espectros, da análise DEMON, com o objetivo de verificar as alterações nas estatísticas, do ambiente, para que possa ocorrer a mudança na matriz de separação. Para esta monitoração, será utilizada a seguinte metodologia [63]:

1. Selecionar um número de espectros da análise DEMON de um contato;
2. Realizar o agrupamento do conjunto de espectros usando redes neurais;
3. Avaliar as mudanças no número de grupos e possíveis deslocamentos dos centros destes grupos;
4. Identificar as mudanças na estatística;
5. Voltar para o item 1.

4.4 Classificação de contatos

A ideia é utilizar um sistema de classificação automático com o propósito de apoiar o operador sonar na decisão de identificar um contato, especialmente na presença de múltiplos alvos. Para isto, algoritmos de separação cega de fontes foram utilizados com o objetivo de minimizar a interferência entre os contatos. Os algoritmos

são aplicados após a análise LOFAR, como um passo no processamento da classificação, de forma a recuperar as características relevantes dos contatos que devem ser classificados. A Figura 4.8, mostra o diagrama de blocos do sistema de classificação, usando a separação cega. Considerando que os sinais nas marcações 190 e 205 estão sofrendo interferência cruzada, primeiramente eles são processados através da análise LOFAR, e um espectro médio é obtido de cada uma das marcações, e são usados como entrada dos algoritmos de BSS. Os componentes estimados são, então, submetidos ao classificador neural.




Figura 4.8: Diagrama de blocos do sistema de classificação usando a separação cega de fontes.

Foi desenvolvido um classificador utilizando rede neural do tipo perceptron multicamada com uma única camada escondida. O número de neurônios na camada escondida foi escolhido após testes de desempenho da discriminação de diversas redes neurais. Para o treinamento foi utilizado o algoritmo backpropagation resiliente (RPROP) [64].

Para o desenvolvimento dos classificadores, as janelas temporais da análise LOFAR de cada uma das marcações foram divididas em conjuntos de treinamento, teste e validação. Para fazer uma avaliação dos efeitos, dos algoritmos de BSS, no processamento dos sinais, o classificador neural foi treinado usando os espectros, sem o processamento e após a realização da BSS, para medir o desempenho da separação [65].

4.5 Medida do desempenho

Para a medida do desempenho da metodologia usada nas análises, foram utilizados índices, para avaliar de forma qualitativa e quantitativa, a performance de cada um dos algoritmos. Todos os índices foram medidos sobre os espectros obtidos pelas análises, DEMON e LOFAR, antes e depois da separação cega.

A análise DEMON, normalmente, cobre a faixa de propulsão dos contatos entre 0 e 1500 rpm. No caso dos dados simulados, como a faixa de propulsão, dos contatos, fica entre 380 e 480 rpm, o processamento e a apresentação gráfica da análise, foram realizados na faixa de 350 a 550 rpm. Para os dados experimentais, o processamento foi realizado na faixa de 50 350 rpm, enquanto que, a apresentação gráfica ficou entre

0 e 350 rpm. Com isto, componentes que não são de interesse no processamento já serão eliminadas.

Como os dados simulados são totalmente controlados, devido ao conhecimento prévio do seu comportamento, foi assumido como padrão de referência de qualidade (padrão ouro) de cada um dos contatos, a primeira janela temporal adquirida em cada marcação. Isto se deve ao fato de que, na primeira janela temporal, é o momento em que os sinais estão mais separados entre eles. Foram realizadas medidas entre os espectros, de referência e dos componentes estimados pelos algoritmos de separação cega, usando índices de desempenho específico para esta finalidade..

Índice de desempenho utilizados nos espectros da análise DEMON:

- SIR - Mede a relação sinal/interferência nos espectros, das marcações e dos componentes estimados. Com isto, vai ser possível verificar de forma qualitativa, se houve uma melhora (atenuação) da SIR nos componentes estimados em relação as marcações.
- SNR - Mede a relação sinal/ruído nos espectro, das marcações e dos componentes estimados. Isto permite verificar, de forma qualitativa, a atenuação do ruído que está contido em todo o espectro nos componentes estimados em relação as marcações.
- Largura à meia altura - Mede a diferença entre dois valores extremos de uma variável independente onde a função atinge a metade do seu valor máximo. Permite calcular a resolução da amplitude das rotações, nas marcações e nos componentes estimados.
- Divergência de Kullback-Leibler (KL) - Mede de forma quantitativa o desempenho dos algoritmos de BSS. A Equação 4.1, mostra a fórmula utilizada para medir a divergência de Kullback-Leibler.

$$D_{kl}(p, q) = \sum_i \ln \left(\frac{p_i}{q_i} \right) p_i \quad (4.1)$$

onde p e q são as distribuições das observações e dos componentes estimados. Para este trabalho os espectros, tanto das observações (marcações) como dos componentes, foram usados como distribuições. Isto se deve ao fato de que, os espectros caracterizam, de forma substancial, o comportamento da propulsão dos sinais.

- Erro médio quadrático (EMQ) - Mede o erro médio quadrático entre o espectro de referência e o espectro estimado pelos algoritmos de separação cega. A

Equação 4.2 mostra a fórmula do erro médio quadrático, onde R_i é o espectro de referência e S_i é o espectro estimado.

$$MSE = \frac{1}{N} \sum_{i=1}^N (R_i - S_i)^2 \quad (4.2)$$

- Coeficiente da desigualdade de Theil - Faz uma comparação entre o espectro de referência e o espectro estimado, como mostra a Equação 4.3.

$$Theil = \frac{\sqrt{EMQ}}{\sqrt{\frac{\sum_{i=1}^N (S_i)^2}{N}}} \quad (4.3)$$

- Erro médio absoluto (EMA) - Mede quão próximas as estimativas dos espectros estão dos espectros de referência.

$$EMA = \frac{1}{N} \sum_{i=1}^N |R_i - S_i| \quad (4.4)$$

- Coeficiente de correlação (CC) - Mede a similaridade entre os espectros de referência e os espectros estimados. Os valores μ_R e μ_S são os valores médios de R_i e S_i respectivamente.

$$\frac{\sum_{i=1}^N (R_i - \mu_R) \sum_{i=1}^N (S_i - \mu_S)}{\sqrt{\sum_{i=1}^N (R_i - \mu_R)^2} \sqrt{\sum_{i=1}^N (S_i - \mu_S)^2}} \quad (4.5)$$

Índice de desempenhos utilizados nos espectros da análise LOFAR:

- Curva ROC - Mostra quanto a probabilidade de detecção (P_D) e de falso alarme (P_F) variam em relação a um limiar de decisão.
- -Produto SP - Ponderação entre as médias, aritmética e geométrica, em função de um limiar de decisão. O índice SP é definido como [66]:

$$SP = \frac{Ef_1 + Ef_2}{2} \times \sqrt{(Ef_1 \times Ef_2)} \quad (4.6)$$

onde $Ef_1 = P_D$ é a eficiência na detecção para a classe 1 e $Ef_2 = (1 - P_D)$ é a eficiência correspondente a classe 2. O limiar que maximiza o SP tende a produzir uma alta P_D e uma baixa P_F .

4.6 Operação do sistema

A operação do sistema de separação cega de fontes, propõe a detecção da propulsão de contatos e classificação de sinais de sonar passivo usando as análises DEMON e LOFAR. A Figura, 4.9, mostra o diagrama de blocos da operação do sistema da separação cega atuando nestas análises. Caso não seja necessário, quando os sinais já estiverem separados, as análises são implementadas sem a necessidade do uso da BSS. Porém, quando o sinal de controle sinalizar, que existe uma interferência entre os contatos, através do cálculo da informação mútua entre os dados de entrada, a monitoração da estacionaridade começa a ser verificada, para que seja estabelecido o momento que as matrizes de separação terão que ser ajustadas com o objetivo de não se perder as estatísticas dos sinais que estão sendo separados. Neste momento, serão aplicados os algoritmos de BSS.

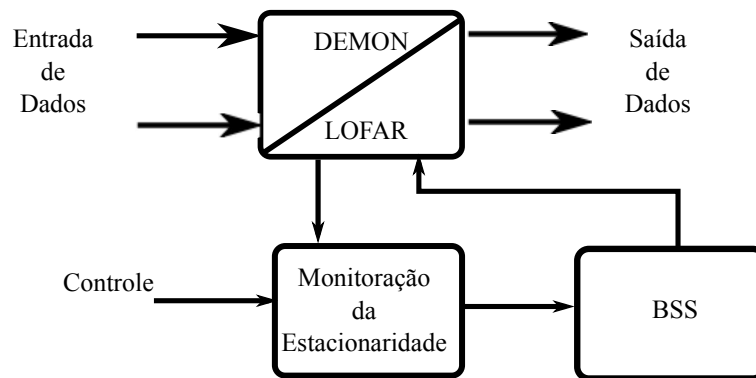


Figura 4.9: Diagrama de blocos da operação do sistema.

Capítulo 5

Resultados da Separação Cega de Fontes

Neste capítulo, serão mostrados os resultados obtidos com os dados simulados e experimentais, usando a metodologia de análise que foi abordada no capítulo 4. Serão feitas avaliações de desempenho da separação cega, por parte dos algoritmos de BSS, de forma qualitativa e quantitativa, usando os gráficos das análises no domínio das observações e dos componentes estimados.

5.1 Dados Simulados


A primeira janela temporal, contém a informação dos sinais de cada um dos contatos mais separados, e pode ser usada como referência para a calibração e comparação com os componentes estimados pelos algoritmos de separação cega. Como ocorre uma mudança de rotação, a partir de 660s, que corresponde a janela temporal de número 11, houve a necessidade da mudança na referência das respectivas rotações, para verificar se os algoritmos estão retornando as estimativas nas rotações desejadas. A última janela temporal (janela 17) contém a informação onde os contatos estão mais próximos, correspondendo a janela de maior interferência cruzada. Os algoritmos de separação cega foram aplicados, em cada uma das janelas temporais, com o objetivo de melhorar a interferência cruzada entre os sinais, caso ela exista, melhorando a identificação dos contatos por parte do operador sonar.

5.1.1 Separação cega no domínio do tempo

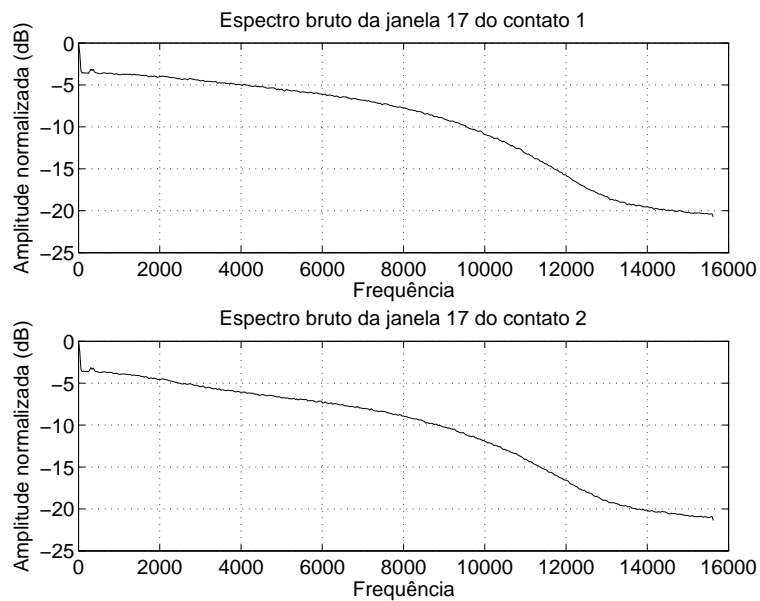
A separação cega de fontes no domínio do tempo foi realizada a partir de duas abordagens distintas de processamento, como mostrado no capítulo 4.

Domínio do tempo (1)

Primeiramente a separação cega foi realizada diretamente nas janelas temporais de 60s, sem pré-processamento prévio dos sinais. A Figura 5.1 mostra o espectro da primeira e da última janela dos sinais.



(a) Primeira janela.



(b) Última janela.

Figura 5.1: Espectro das janelas de 60s.

A banda de frequência dos sinais na qual será realizada a separação cega fica entre 0 e 15.625 Hz. Por outro lado, a banda de frequência da propulsão dos contatos fica entre 0 e 25 Hz, que corresponde a faixa de rotação de 0 a 1500 rpm. Desta forma, espera-se que enfoque de processamento produza um pior desempenho dos

algoritmos devido a baixa SNR.

A seguir serão mostrados os gráficos da análise DEMON, dos contatos e dos componentes estimados pelos algoritmos. As Figuras 5.2, 5.3, 5.4 e 5.5 mostram os espectros de cada um dos contatos e os seus respectivos componentes estimados, da janela temporal 17, de cada um dos algoritmos, de ICA e NMF. Observa-se que, tanto nos algoritmos de ICA quanto nos algoritmos de NMF, que, em nenhuma das situações, a separação entre os contatos foi realizada. Além de não acontecer a separação, em algumas situações, os algoritmos agruparam os contatos de marcações diferentes, na estimação dos componentes.

Pode ser observado que em nenhum dos algoritmos ocorreu uma melhora significativa da SIR. Em determinados algoritmos a SIR piorou, fazendo uma mistura entre os contatos. Isto se deve ao fato da quantidade de ruído na banda de frequência do sinal, que pode representar outros componentes, para os algoritmos no processo da separação cega.

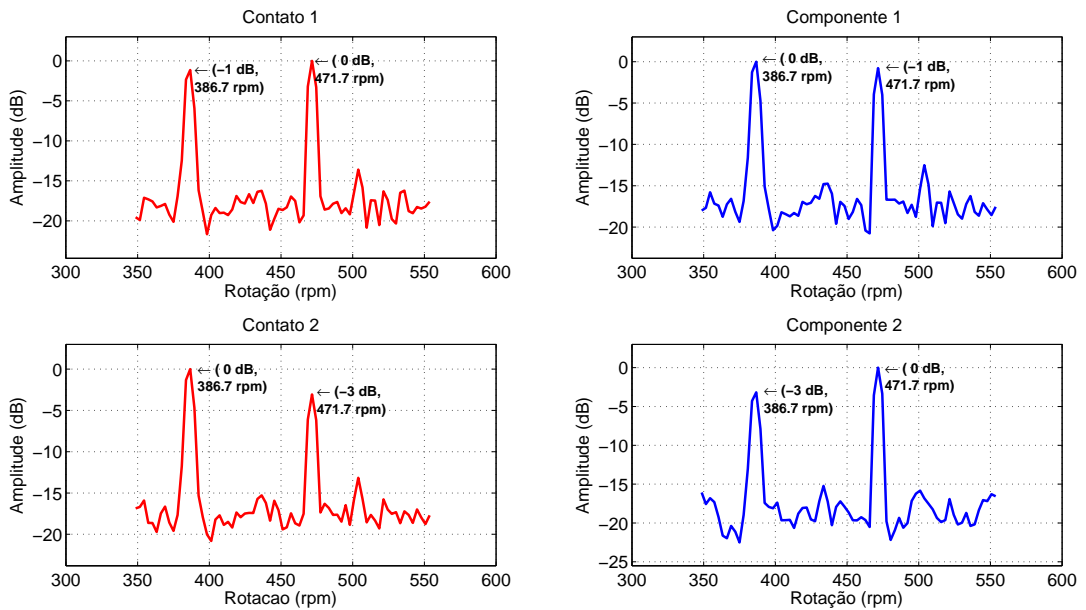


Figura 5.2: Espectro, dos contatos e dos componentes, da janela temporal 17, no domínio do tempo (1) usando o algoritmo FastICA.

As Figuras, 5.6 e 5.7 mostram a divergência KL entre as observações e os componentes estimados, de cada um dos algoritmos à cada janela temporal.

Pode ser observado, pelas Figuras 5.6, (a) e (b), que não ocorreu a separação dos componentes com os algoritmos FastICA e JADE, pelo fato de que, a divergência KL, tanto das observações quanto das estimativas permaneceram no mesmo patamar em todas as janelas temporais. No caso do algoritmo Newton-like, nas janelas temporais, 3, 4 e 5, a divergência das estimativas obtiveram valores menores do que




Figura 5.3: Espectro, dos contatos e dos componentes, da janela temporal 17, no domínio do tempo (1) usando o algoritmo JADE.

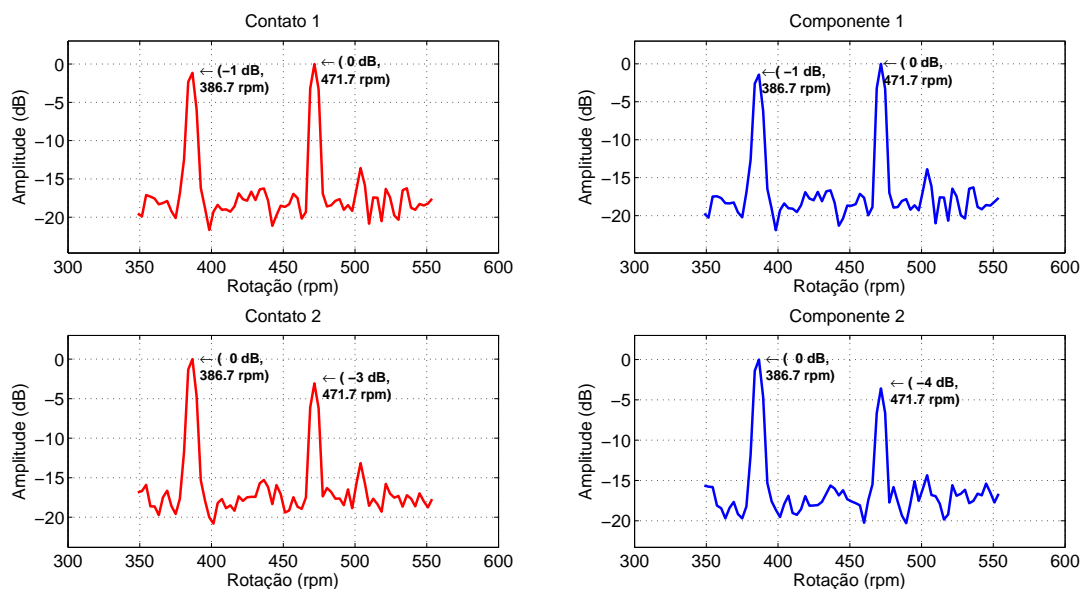


Figura 5.4: Espectro, dos contatos e dos componentes, da janela temporal 17, no domínio do tempo (1) usando o algoritmo Newton-like.

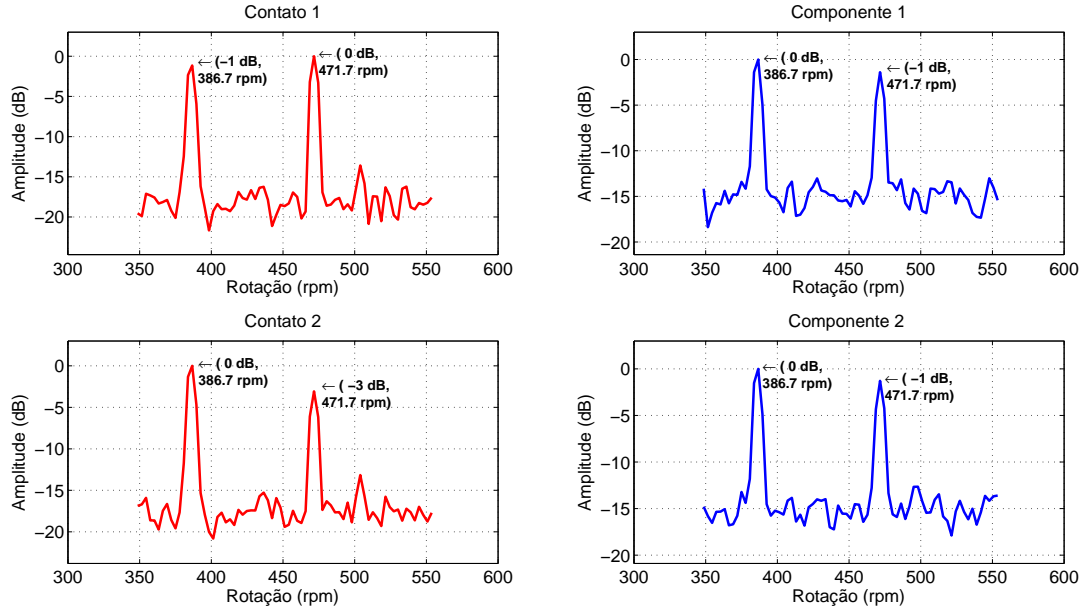


Figura 5.5: Espectro, dos contatos e dos componentes, da janela temporal 17, no domínio do tempo (1) usando o algoritmo NMF com a função custo distância Euclidiana.


as observações, indicando que ocorreu uma mistura entre os componentes nestas janelas. Quanto ao algoritmo NMF usando como função custo a distância Euclidiana, a divergência entre as estimativas, permaneceu com os valores próximos de zero e sempre abaixo da divergência das observações. Isto mostra que os componentes estão misturados. Pode-se concluir, então, que a estimação dos componentes, com estes algoritmos, diretamente nas janelas temporais, sem nenhum processamento, não é eficaz.

Domínio do tempo (2)


Os algoritmos de BSS são aplicados após o pré-processamento dos sinais. Para a apresentação gráfica, foram escolhidas as três últimas janelas devido ao fato de que, a partir da janela temporal de número 15, a interferência cruzada começa a aumentar entre os contatos, caracterizando a aproximação entre eles, e na janela temporal de número 17, a SIR é de menor valor. Para medir o desempenho dos algoritmos de forma quantitativa, são apresentados os gráficos da divergência KL, como as figura de mérito, entre as observações de cada uma das marcações e dos seus respectivos componentes estimados.

- **Algoritmo FastICA**

As Figuras 5.8, 5.9 e 5.10 mostram os espectros referentes as três últimas janelas temporais dos contatos, e seus respectivos componentes.




(a) Algoritmo FastICA.




(b) Algoritmo JADE.

Figura 5.6: Divergência KL entre as observações e os componentes estimados a cada janela temporal.



(a) Algoritmo Newton-like.



(b) Algoritmo NMF (dist. Euclidiana).

Figura 5.7: Divergência KL entre as observações e os componentes estimados a cada janela temporal.

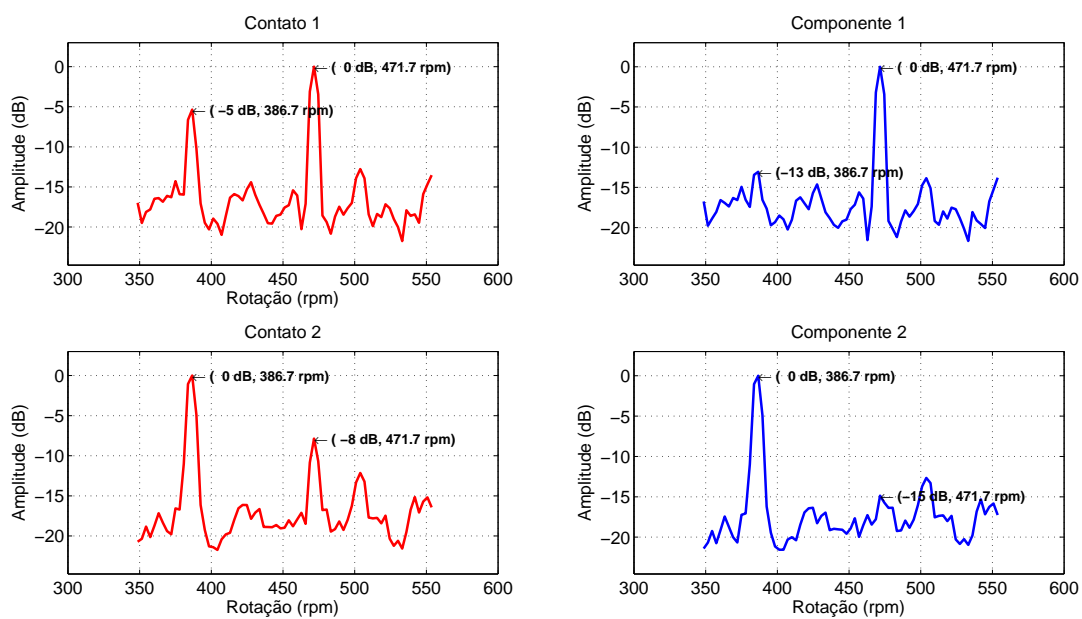


Figura 5.8: Espectros dos contatos e dos componentes da janela 15 usando o algoritmo FastICA no domínio do tempo (2).

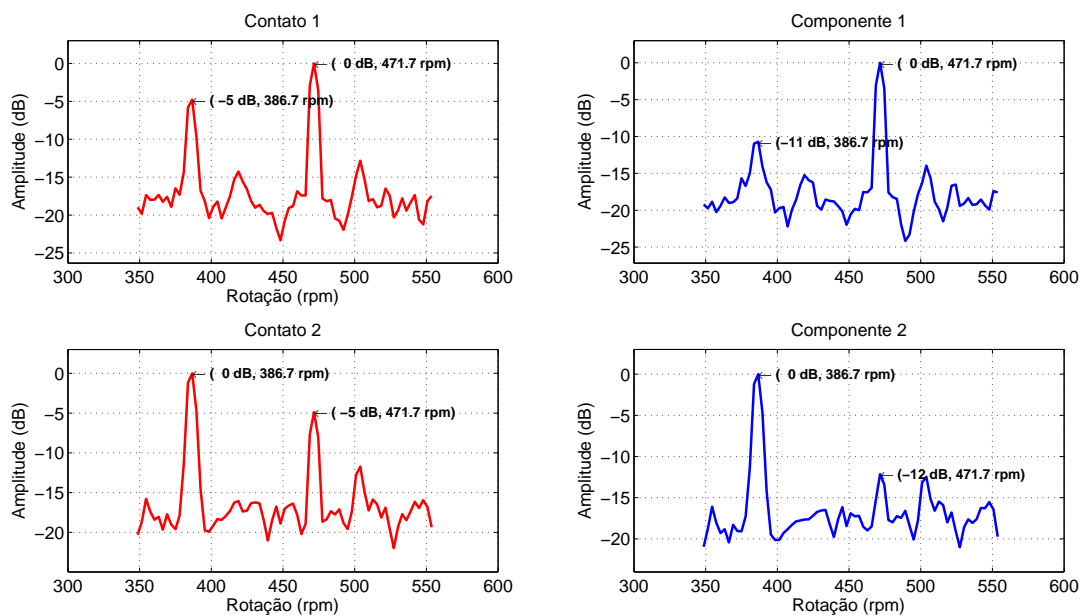


Figura 5.9: Espectros dos contatos e dos componentes da janela 16 usando o algoritmo FastICA no domínio do tempo.

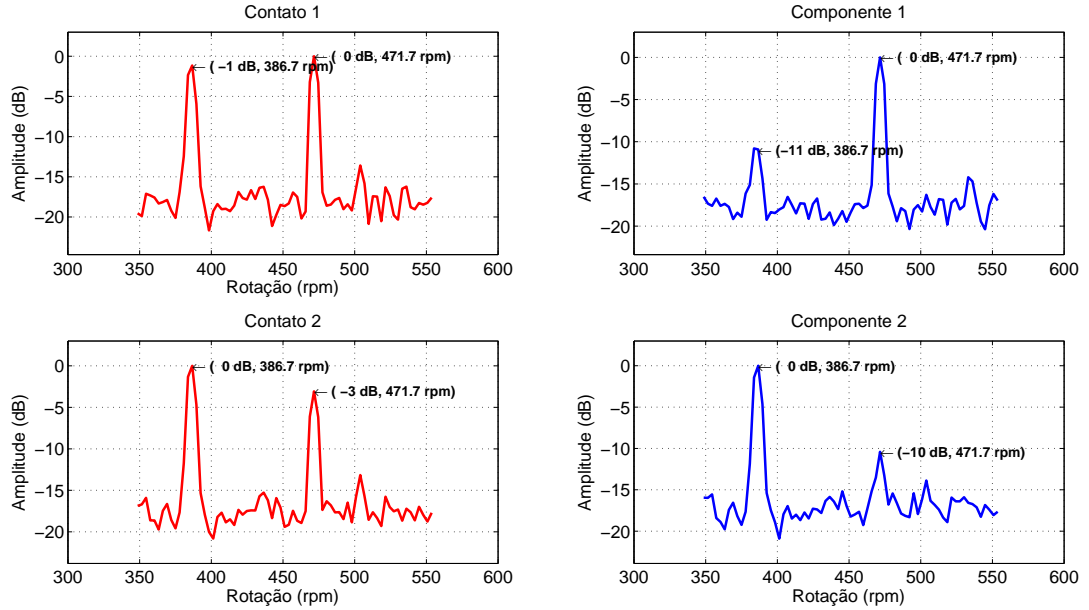


Figura 5.10: Espectros dos contatos e dos componentes da janela 17 usando o algoritmo FastICA no domínio do tempo.

A janela temporal de número 15, Figura 5.8, mostra que o contato 1 está com uma SIR de 5 dB, enquanto que o contato 2 tem a SIR de 8 dB. Após a separação cega, pode ser observado que a SIR de cada um dos componentes atingiu 13 e 15 dB, respectivamente. À medida que a SIR vai aumentando entre os contatos, Figuras 5.9 e 5.10, o algoritmo realizou a atenuação na interferência entre as marcações, melhorando a SIR.

A medida escolhida para medir de forma quantitativa a separação cega de fontes, foi a divergência de Kullback-Leibler (KL). Primeiro, a divergência KL foi calculada a cada janela temporal, entre as observações (contatos), e entre os componentes estimados, como mostra a Figura 5.11. Pode ser observada a eficiência da separação fazendo uma comparação entre as curvas das observações e das estimativas. Da primeira a décima terceira janela temporal, onde os sinais não estão sofrendo a interferência cruzada, as curvas da divergência KL entre as observações e entre os componentes, permanecem no mesmo patamar, sofrendo apenas variações devido as flutuações do ruído. Estas janelas temporais serviram para calibrar o comportamento do algoritmo. A partir da décima terceira janela temporal, quando começa a acontecer a interferência cruzada, a divergência KL entre as observações, começa a diminuir, chegando próximo até os valores de zero, enquanto a divergência KL, entre as estimativas, tende permanecer com os valores próximo de 1,6. Isto mostra que a divergência KL, dos componentes estimados, nestas janelas, estão próximos

aos valores, da divergência KL, das janelas temporais iniciais. Então pode-se concluir que, o algoritmo realizou a separação dos sinais retornando aos valores próximo das observações da primeira janela temporal.




Figura 5.11: Divergência KL entre as observações e entre os componentes estimados pelo algoritmo FastICA.

A outra forma de medir o desempenho do algoritmo FastICA é calcular a divergência KL entre as referências (padrão ouro) de cada um dos contatos e as respectivas marcações; e entre as referências e os seus respectivos componentes estimados, como mostrado na Figura 5.12.

A divergência KL entre as referências e as observações, permanecem próximo de zero da primeira a décima terceira da janela temporal. A partir da décima quarta janela, ocorre um aumento da divergência em função da interferência cruzada entre os contatos. Já no caso da divergência entre as estimativas, apesar do aumento da interferência cruzada, a divergência entre as referências e os componentes permanecem em torno de zero, certificando que o algoritmo realizou a estimação próximo aos valores de referência.




Figura 5.12: Divergência KL entre as referências e as observações, e entre as referências e as estimativas obtidas algoritmo FastICA.

- **Algoritmo JADE**

As Figuras 5.13, 5.14 e 5.15 mostram os espectros referentes as três últimas janelas temporais dos contatos, e seus respectivos componentes.

À medida que a SIR vai diminuindo entre os contatos, o algoritmo JADE tende a realizar a estimação dos componentes aumentando a SIR em cada componente. Foi utilizada, como figura de mérito, a divergência KL entre as observações e entre as estimativas para medir o índice de desempenho do algoritmo. A Figura 5.16, mostra o gráfico da divergência KL.

Da primeira à décima terceira janela temporal, onde os sinais não estão sofrendo a interferência cruzada, as curvas da divergência KL entre as observações e entre os componentes são similares e estão sofrendo apenas as flutuações do ruído, permanecendo na média, com os valores em torno de 2. A partir da décima terceira janela temporal, quando começa acontecer a interferência cruzada, a divergência entre as observações, começa a diminuir, chegando próximo de zero. Por sua vez, entre as estimativas, a divergência tende a permanecer com os valores entre 1,5 e 1,3 apesar de ocorrer a maior interferência entre os contatos. Isto mostra que o algoritmo melhorou a SIR em cada componente.

A segunda maneira de medir o desempenho do algoritmo JADE é a realização do cálculo da divergência KL entre as referências (padrão ouro) e as observações de cada uma das marcações; e entre as referências e os compo-

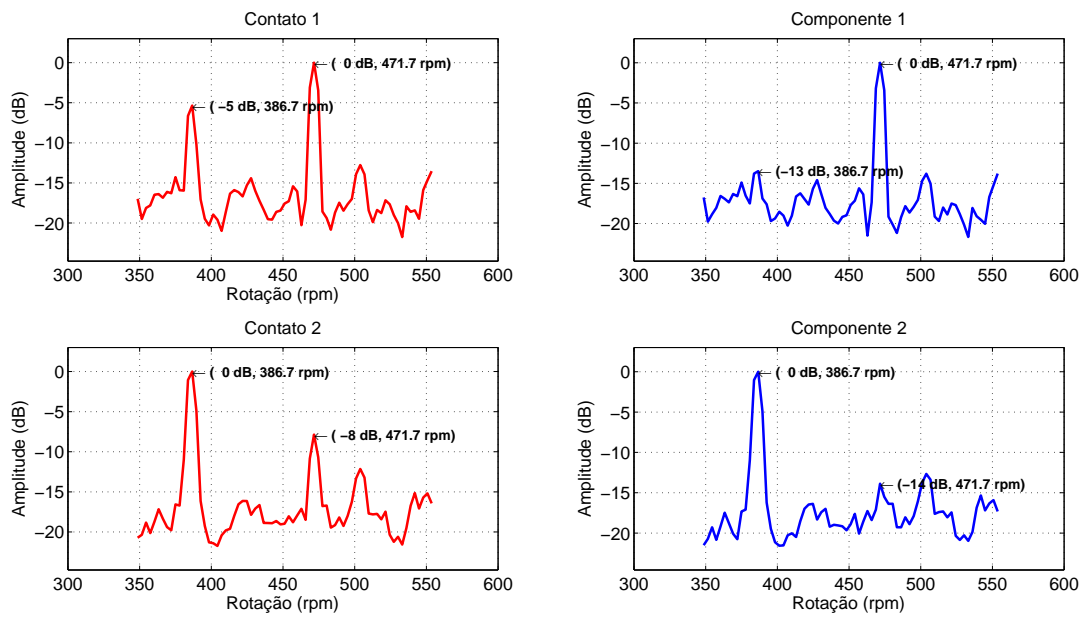


Figura 5.13: Espectros dos contatos e dos componentes da janela 15 usando o algoritmo JADE no domínio do tempo (2).




Figura 5.14: Espectros dos contatos e dos componentes da janela 16 usando o algoritmo JADE no domínio do tempo.




Figura 5.15: Espectros dos contatos e dos componentes da janela 17 usando o algoritmo JADE no domínio do tempo.




Figura 5.16: Divergência KL entre as observações e entre os componentes estimados pelo algoritmo JADE.

nentes estimados, como é mostrado na Figura 5.17. Pode ser observado que a divergência KL entre as referências e as observações, permaneceram próximo de zero da janela temporal 1 até a 13. A partir da décima quarta janela, ocorre um aumento da divergência KL, devido a interferência cruzada entre as marcações. Já no caso da divergência entre as referências e as estimativas, apesar do aumento da interferência, a divergência permanece em torno de zero, certificando que o algoritmo retornou as estimativas para as respectivas referências.




Figura 5.17: Divergência KL entre as referências e as observações e entre as referências as estimativas obtidas algoritmo JADE no domínio do tempo (2).

- **Algoritmo Newton-like**

As Figuras 5.18, 5.19 e 5.20 mostram os espectros referentes às três últimas janelas temporais dos contatos, e seus respectivos componentes, usando o algoritmo Newton-like.

A Figura 5.18 mostra que para a janela temporal de número 15 o contato 1 está com uma SIR de 5 dB, enquanto que para o contato 2, a SIR é de 8 dB. Após a separação cega, observa-se que a SIR de cada um dos componentes foi para 14 e 15 dB, respectivamente e que, à medida que a SIR de cada uma das marcações vai diminuindo, Figuras 5.19 e 5.20, o algoritmo realiza a estimação dos componentes e tende a melhorar SIR.

A Figura 5.21, mostra o gráfico da divergência KL entre as observações e entre os componentes estimados. De forma similar ao desempenho dos algoritmos




Figura 5.18: Espectros dos contatos e dos componentes da janela 15 usando o algoritmo Newton-like no domínio do tempo (2).




Figura 5.19: Espectros dos contatos e dos componentes da janela 16 usando o algoritmo Newton-like no domínio do tempo (2).




Figura 5.20: Espectros dos contatos e dos componentes da janela 17 usando o algoritmo Newton-like no domínio do tempo (2).

FastICA e o JADE, a divergência KL entre as observações e entre os componentes sofrem as variações, devido às flutuações do ruído entre a primeira e a décima terceira janela temporal. A partir da décima terceira janela temporal, início da interferência, a divergência entre as observações, começa a diminuir, chegando próximo de zero na janela de maior interferência. Já a divergência KL, entre as estimativas, tende a permanecer em torno dos valores originais.

Uma outra forma de medir o desempenho do algoritmo é calcular a divergência KL entre as referências (padrão ouro) e os contatos de cada uma das marcações e entre as referências os seus respectivos componentes estimados. A Figura 5.22 mostra o gráfico desta medida. As divergências KL, entre as observações e os respectivos padrão ouro, permaneceu próximo de zero da primeira a décima terceira janela temporal, onde não está ocorrendo nenhuma interferência entre as marcações. A partir da décima terceira janela temporal, as divergências começam a aumentar enquanto que, as divergências entre as referências e as estimativas permaneceram próximas de zero, indicando que as estimativas retornaram valores próximos aos valores das referências.

- **Algoritmo NMF usando como função custo a distância Euclidiana**

Uma outra maneira de se realizar a separação cega de fontes é utilizando a fatoração de matrizes não negativas. As Figuras 5.23, 5.24 e 5.25 mostram os espectros das três últimas janelas temporais dos contatos, e seus respectivos




Figura 5.21: Divergência KL entre as observações e os componentes estimados pelo algoritmo Newton-like no domínio do tempo (2).




Figura 5.22: Divergência KL entre as referências e as observações, e entre as referências as estimativas obtidas algoritmo Newton-like no domínio do tempo (2).

componentes.




Figura 5.23: Espectros dos contatos e dos componentes da janela 15 usando o algoritmo NMF com a distância Euclidiana como função custo no domínio do tempo.

A janela temporal de número 15, Figura 5.23, mostra que o contato 1 está com uma SIR de 5 dB enquanto no contato 2 a SIR é de 8 dB. Após a separação pode ser observado que a estimativas de cada um dos contatos passaram a ter a SIR de 8 e 12 dB respectivamente, mostrando que ocorreu uma melhora da SIR de cada uma das estimativas. Porém, a medida que a SIR entre as marcações vai diminuindo, Figuras 5.24 e 5.25, a estimativa dos componentes não melhora a SIR. Por exemplo, na décima sexta janela temporal, a SIR das estimativas sofreu um aumento em relação às observações, mostrando que não ocorreu a separação.

A divergência de Kullback-Leibler (KL) foi calculada entre as marcações (observações) e entre os componentes estimados, com a finalidade de medir a qualidade da separação a cada janela temporal. A Figura 5.26, mostra o gráfico da divergência KL. A divergência entre as estimativas, permaneceu, sempre, com os valores abaixo da divergência entre as observações. Isto mostra que o algoritmo não realizou a separação e não conseguiu melhorar a SIR entre as estimativas.

Uma outra medida do desempenho do algoritmo NMF é calcular a divergência KL entre as referências (padrão ouro) e os contatos de cada uma das marcações, e as referências e os seus respectivos componentes estimados. A Figura 5.27 mostra o gráfico desta medida.




Figura 5.24: Espectros dos contatos e dos componentes da janela 16 usando o algoritmo NMF com a distância Euclidiana como função custo no domínio do tempo.




Figura 5.25: Espectros dos contatos e dos componentes da janela 17 usando o algoritmo NMF com a distância Euclidiana como função custo no domínio do tempo.




Figura 5.26: Divergência KL entre as observações e entre os componentes estimados pelo algoritmo NMF usando como função custo a distância Euclidiana no domínio do tempo (2).

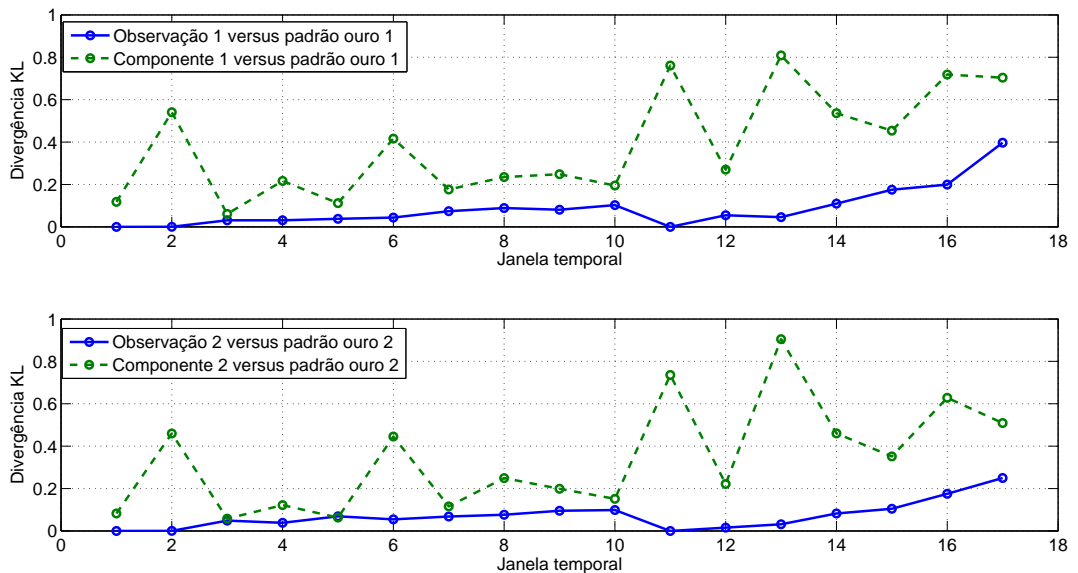


Figura 5.27: Divergência KL entre as referências e as observações, e entre as referências e as estimativas usando o algoritmo NMF com a distância Euclidiana como função custo no domínio do tempo (2).

A curva divergência KL, entre as referências e as estimativas, permaneceu em patamares superiores à divergência entre as referências e as observações a cada janela temporal.

- **Algoritmo NMF usando como função custo a divergência de Kullback-Leibler**

As Figuras 5.28, 5.29 e 5.30 mostram os espectros e seus respectivos componentes, usando o algoritmo NMF com a divergência de Kullback-Leibler como função custo.

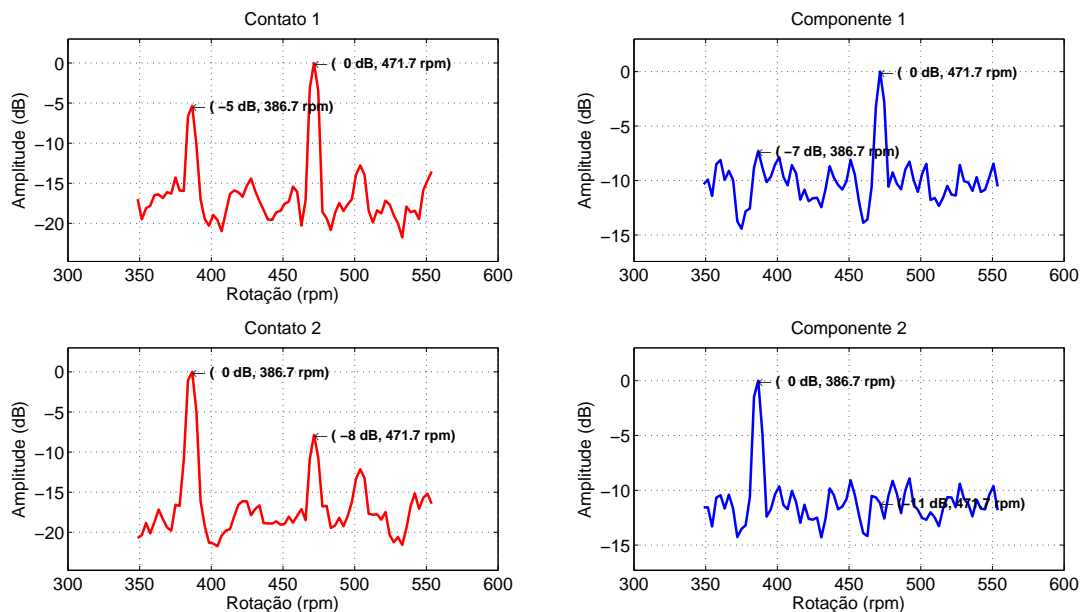


Figura 5.28: Espectros dos contatos e dos componentes da janela 15 usando o algoritmo NMF com divergência de Kullback-Leibler como função custo no domínio do tempo.

Na estimação dos componentes, a SIR sofreu melhora significativa na janela 15 como pode ser observado na Figura 5.28. Entretanto, à medida que a SIR das observações foi diminuindo, o mesmo acontece com a SIR das estimativas (janelas 16 e 17).

Novamente, a divergência KL foi utilizada como figura de mérito para a medida do desempenho na separação de cega do algoritmo. Primeiramente foi medida a divergência entre as observações e entre os componentes, como mostra a Figura 5.31. A curva da divergência KL entre as observações a cada janela temporal, permanece com os valores maiores do que a curva da divergência entre as estimativas. Isto mostra que as estimativas com o algoritmo proposto




Figura 5.29: Espectros dos contatos e dos componentes da janela 16 usando o algoritmo NMF com divergência de Kullback-Leibler como função custo no domínio do tempo.




Figura 5.30: Espectros dos contatos e dos componentes da janela 17 usando o algoritmo NMF com divergência de Kullback-Leibler como função custo no domínio do tempo.




Figura 5.31: Divergência KL entre as observações e os componentes estimados pelo algoritmo NMF usando a função custo divergência de Kulback-Leibler.

não conseguiu melhorar a SIR entre os componentes estimados. Isto pode ser observado na Tabela 5.3.

Também foi calculada a divergência KL entre as referências (padrão ouro) e as estimativas de cada uma das marcações a cada janela, como é mostrado na Figura 5.32.

Neste caso, pode-se observar que a curva da divergência entre as referências e as estimativas permanece com os valores acima da curva das referências e observações, caracterizando que o algoritmo não retornou os componentes estimados.

Pode-se concluir que os algoritmos de análise de componentes independentes tiveram um melhor desempenho, no domínio do tempo, em relação aos algoritmos de fatoração de matrizes não negativas. Mesmo no pior caso da SIR entre as marcações, janela temporal de número 17, onde os contatos estão mais próximos, os algoritmos de ICA retornaram estimativas com SIR maiores do que os das observações. O mesmo não acontece com os algoritmos de separação usando a NMF. Isto pode ser confirmado, através da Tabela 5.3.

5.1.2 Separação cega no domínio da frequência

No domínio da frequência, a separação cega é realizada após a transformada de Fourier dos sinais. Na análise DEMON, é criada uma janela frequência versus tempo,




Figura 5.32: Divergência KL entre as referências e as observações, e entre as referências e as estimativas obtidas algoritmo NMF usando como função custo a divergência de Kullback-Leibler.

como mostrado nas Figuras 4.2 e 4.3, para que possa ser feito um acompanhamento das frequências que persistirem ao longo da análise, e que caracterizem as rotações de um determinado contato. Então, um espectro médio é calculado, para cada um dos contatos, e a separação cega dos sinais é realizada.

O mesmo critério que foi utilizado para medir o desempenho dos algoritmos no domínio do tempo, também será aplicado para o domínio da frequência. Serão mostrados os gráficos das três últimas janelas temporais dos contatos e dos componentes estimados, onde a SIR nas observações começa a diminuir. A divergência de Kullback-Leibler será usada como uma medida quantitativa do desempenho dos algoritmos.

- **Algoritmo FastICA**

As Figuras 5.33, 5.34 e 5.35 mostram os espectros referentes as três últimas janelas temporais dos contatos, e seus respectivos componentes estimados.

A janela temporal número 15, 5.33, mostra que o contato 1 está com uma SIR de 5 dB, enquanto no contato 2 a SIR é de 8 dB. Após a separação, a SIR de cada um dos contatos foi para 13 e 17 dB respectivamente. A medida que a SIR vai diminuindo entre os contatos, como pode ser observado nas Figuras, 5.34 e 5.35, o algoritmo manteve a SIR dos componentes à níveis maiores.

Para medir de forma quantitativa a separação, primeiramente a divergência




Figura 5.33: Espectros dos contatos e dos componentes da janela temporal número 15 usando o algoritmo FastICA no domínio da frequência.




Figura 5.34: Espectros dos contatos e dos componentes da janela temporal número 16 usando o algoritmo FastICA no domínio da frequência.




Figura 5.35: Espectros dos contatos e dos componentes da janela temporal número 17 usando o algoritmo FastICA no domínio da frequência.

KL foi calculada a cada janela temporal, entre as observações, e entre as estimativas. A Figura 5.36, mostra o gráfico da divergência kl.

Da primeira a décima terceira janela temporal, as divergências KL entre as observações e entre os componentes, sofreram variações apenas devido as flutuações do ruído, permanecendo com os valores entre 1, 5 e 2, 5. Estas janelas serviram como uma calibração para o algoritmo. A partir da décima quarta janela temporal, quando começa acontecer a interferência cruzada, a divergência entre as observações, começa a diminuir, chegando próximo de zero, na janela temporal número 17. Enquanto que, a divergência entre as estimativas começa a aumentar, caracterizando, que houve uma separação entre as distribuições.

A outra forma de medir o desempenho do algoritmo é a realização do cálculo, da divergência KL, entre as referências e os contatos de cada uma das marcações; e entre as referências com os seus respectivos componentes estimados.

A Figura 5.37 mostra os gráficos das divergências. As divergências entre as referências e as observações, permaneceram próximo de zero, da janelas temporais, de 1 a 13, indicando que os sinais estão separados. A partir da janela temporal 14, ocorreu um aumento destas divergências devido a aproximação entre os contatos. No caso, da medida das divergências entre as referências e as estimativas, as divergências permanecem em torno de zero em todas as janelas




Figura 5.36: Divergência KL entre as observações e entre os componentes estimados pelo algoritmo FastICA no domínio da frequência.




Figura 5.37: Divergência KL entre as referências; e as observações e as estimativas obtidas algoritmo FastICA no domínio da frequência.

temporais, mostrando que o algoritmo realizou a estimação dos componentes próximo aos valores de referência.

- **Algoritmo JADE**

As Figuras 5.38, 5.39 e 5.40 mostram os espectros das três últimas janelas temporais dos contatos, e seus respectivos componentes estimados.




Figura 5.38: Espectros dos contatos e dos componentes estimados, da janela temporal número 15, usando o algoritmo JADE no domínio da frequência.

A janela temporal número 15, Figura 5.38, mostra que, após a separação cega, a SIR de cada um dos componentes, foram para os valores de 14 e 14 dB respectivamente. A medida que a SIR em cada marcação vai diminuindo, Figuras 5.39 e 5.40, o algoritmo manteve a SIR dos componentes em níveis suficientemente baixos, mostrando uma melhora na SIR.

A divergência KL, Figura 5.41, foi calculada a cada janela temporal, entre as observações, e entre as estimativas. Da primeira a décima terceira janela temporal a divergência KL entre as observações sofreu variações entre 1, 3 e 2, 6, enquanto que entre os componentes, a divergência ficou em torno de 2. Isto mostra que o algoritmo sempre manteve as estimativas com as distribuições próximas entre as janelas temporais. A partir da décima quarta janela temporal, momento em que começa acontecer a aproximação entre os contatos, a divergência entre as observações, começa a diminuir, chegando próximo de zero, enquanto a divergência entre as estimativas começa a aumentar, caracterizando que houve uma separação entre as distribuições das estimativas.




Figura 5.39: Espectros dos contatos e dos componentes estimados, da janela temporal número 16, usando o algoritmo JADE no domínio da frequência.




Figura 5.40: Espectros dos contatos e dos componentes estimados, da janela temporal número 17, usando o algoritmo JADE no domínio da frequência.




Figura 5.41: Divergência KL entre as observações e entre os componentes estimados pelo algoritmo JADE no domínio da frequência.

A Figura 5.42 mostra o gráfico da divergência KL entre as referências e as observações e entre as referências e as estimativas. A divergência entre as referências e as estimativas permanecem em torno de zero mesmo nas janelas onde a interferência cruzada entre os contatos começa a aumentar mostrando que os componentes estimados são semelhantes as respectivas referências.

As divergência KL entre as referências e as observações, permaneceram próximo de zero, da janela temporal 1 até a janela temporal 13, indicando que não houve interferência cruzada entre os contatos nestas janelas. A partir da janela temporal 14, ocorreu um aumento das divergências KL, devido ao aumento da interferência cruzada entre os contatos. No caso da medida entre as referências e as estimativas, as divergências permaneceram em torno de zero em todas as janelas, mostrando que as estimativas dos componentes retornaram para valores próximos as respectivas referências.

- **Algoritmo Newton-like**

As Figuras 5.43, 5.44 e 5.45 mostram os espectros referentes as três últimas janelas temporais dos contatos, e dos seus respectivos componentes estimados.

A qualidade da separação pode ser observada através dos componentes na melhora da SIR. A divergência foi calculada a cada janela temporal, entre as observações, e entre as estimativas, dos contatos. A ideia é que, a divergência entre as observações, comece a diminuir a partir do momento em que tenha início a interferência cruzada entre as marcações. Enquanto que, a divergência




Figura 5.42: Divergência KL entre as referências e as observações, e entre as referências e as estimativas obtidas algoritmo JADE no domínio da frequência.

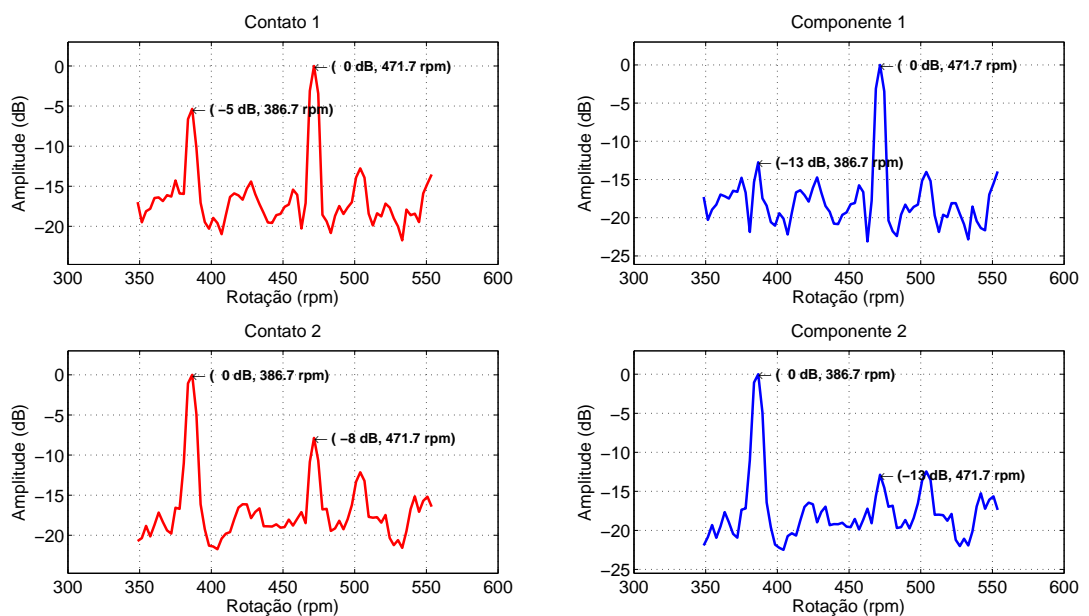


Figura 5.43: Espectros dos contatos e dos componentes estimados, da janela temporal número 15, usando o algoritmo Newton-like no domínio da frequência.




Figura 5.44: Espectros dos contatos e dos componentes estimados, da janela temporal número 16, usando o algoritmo Newton-like no domínio da frequência.

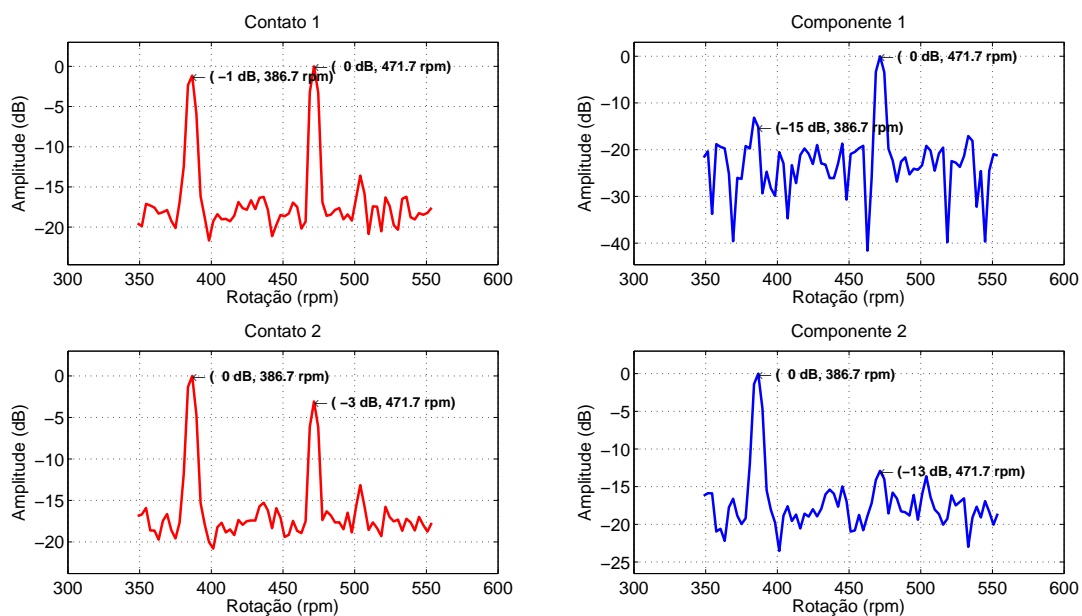


Figura 5.45: Espectros dos contatos e dos componentes estimados, da janela temporal número 17, usando o algoritmo Newton-like no domínio da frequência.

entre as estimativas, tende a aumentar por conta da separação cega. A Figura, 5.46, mostra os gráficos de cada uma destas divergências. A partir da janela temporal número 14 a divergência entre as observações tende para zero, enquanto a divergência entre as estimativas começa a aumentar até atingir o valor de 2,7 aproximadamente, na janela temporal de número 17, onde a SIR é menor, mostrando que ocorreu uma separação entre as estimativas.




Figura 5.46: Divergência KL entre as observações e entre os componentes estimados pelo algoritmo Newton-like no domínio da frequência.

Também foi realizado o cálculo da divergência entre as referências e as observações de cada uma das marcações; e entre as referências e os seus respectivos componentes estimados. A Figura, 5.47, mostra o gráfico entre estas medidas. Apesar da aproximação entre os contatos, situação que ocorre a partir da décima quarta janela temporal, os valores das divergências entre as referências e as estimativas permaneceram em torno de zero.

- **Algoritmo NMF usando como função custo a distância Euclidiana**

As Figuras 5.48, 5.49 e 5.50 mostram os espectros referentes as três últimas janelas temporais dos contatos, e seus respectivos componentes estimados.

O algoritmo apresenta uma instabilidade na SIR dos componentes estimados, como pode ser observado na Figuras 5.44 e 5.45. Na janela temporal número 17, na estimação do componente 1, o componente 2 ficou 1 dB abaixo em relação ao contato 2, no espectro do contato 1. Além disto, na estimação do




Figura 5.47: Divergência KL entre as referências e as observações; e entre as referências e as estimativas obtidas algoritmo Newton-like no domínio da frequência.

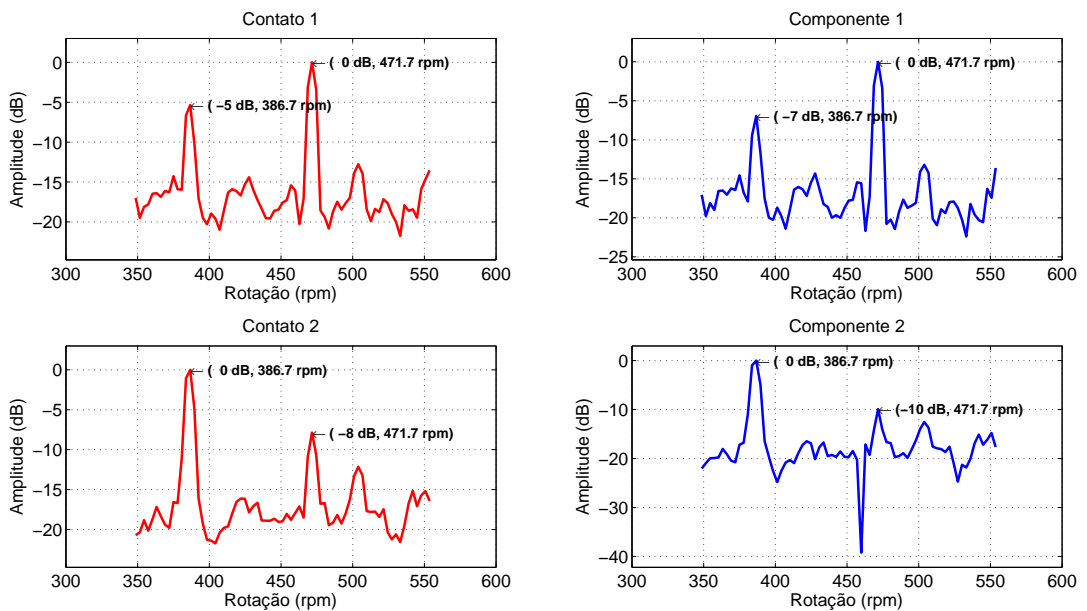


Figura 5.48: Espectros dos contatos e dos componentes estimados, da janela temporal número 15, usando o algoritmo NMF com a função custo Euclidiana no domínio da frequência.




Figura 5.49: Espectros dos contatos e dos componentes estimados, da janela temporal número 16, usando o algoritmo NMF com a função custo Euclidiana no domínio da frequência.




Figura 5.50: Espectros dos contatos e dos componentes estimados, da janela temporal número 17, usando o algoritmo NMF com a função custo Euclidiana no domínio da frequência.

componente 2, apareceram duas rotações que não pertencem nem ao componente 2 e nem ao contato 1.

A Figura 5.51 mostra a divergência KL entre as observações e entre as estimativas. A curva da divergência entre as estimativas nas janelas onde não está acontecendo a interferência cruzada entre os contatos, não tem o mesmo comportamento da curva das observações. Isto demonstra que o algoritmo não está retornando as estimativas que se esperava. Além disto, quando a interferência cruzada começa a acontecer, tanto a divergência das observações quanto a divergência das estimativas começam a se aproximar de zero.




Figura 5.51: Divergência KL entre as observações e entre os componentes estimados pelo algoritmo NMF com a função custo Euclidiana no domínio da frequência.

A Figura 5.52 mostra o gráfico entre as referências e as observações, e entre as referências e os componentes estimados. As divergências entre as referências e os componentes estimados ficaram com os valores próximos das divergências entre as referências e os contatos, mostrando que não ocorreu uma separação dos sinais.

- **Algoritmo NMF usando como função custo a divergência de Kullback-Leibler**

Uma outra maneira de se estimar os componentes, através da fatoração de matrizes não negativas, é utilizar a divergência de Kullback-Leibler como função custo. As Figuras, 5.53, 5.54 e 5.55, mostram os espectros referentes as três últimas janelas temporais dos contatos simulados, e seus respectivos componentes.

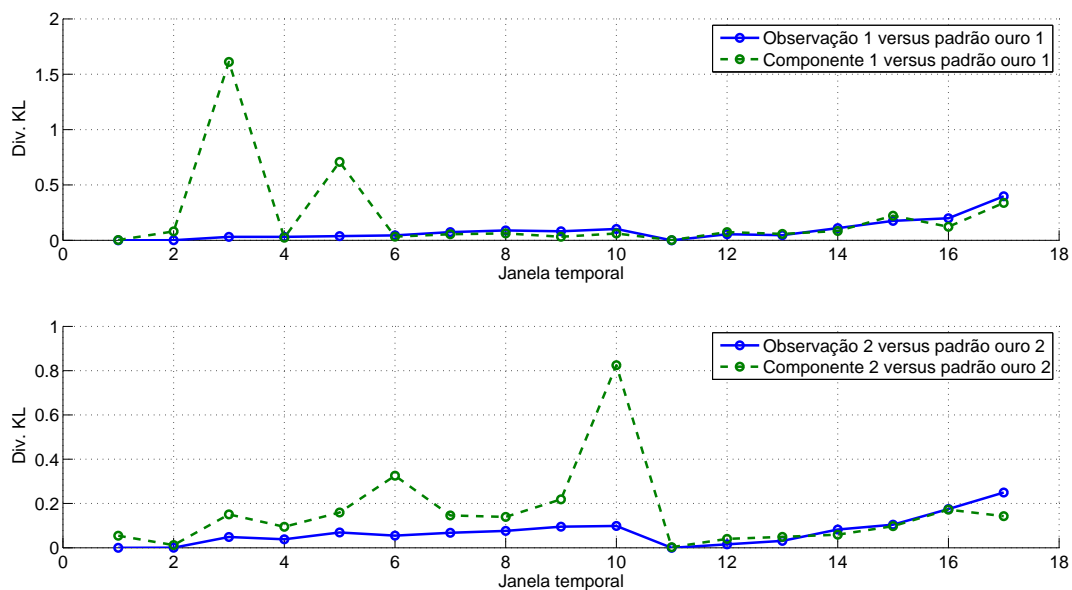


Figura 5.52: Divergência KL entre as referências e as observações, e entre as referências e as estimativas, obtidas pelo algoritmo NMF usando como função custo a distância Euclidiana no domínio da frequência.

De forma qualitativa pode ser observado que, o algoritmo na janela temporal número 16, ao invés de realizar a separação cega, misturou os sinais levando os componentes à níveis de SIR para os mesmos patamares dos contatos.

A Figura 5.56 mostra o gráfico da divergência KL entre as observações e as estimativas a cada janela temporal. A divergência entre as observações permanece sempre em patamares menores do que a divergência entre as estimativas, mostrando que houve uma separação dos sinais. A partir da décima quarta janela temporal, a divergência entre as observações começa a diminuir, mostrando o início da interferência cruzada entre os contatos. O mesmo acontece com a divergência entre as estimativas. Isto mostra que o algoritmo não obteve um desempenho em situações de alta SIR.

A Figura 5.57 mostra o gráfico entre as referências e as observações, bem como entre as referências e os componentes estimados. A divergência KL entre as referências e as observações, permaneceram próximo de zero, exceto a partir da décima quarta janela temporal, onde ocorre um aumento, da divergência, tanto entre as observações, quanto entre as estimativas. Isto caracteriza que os componentes, nestas janelas temporais, não retornaram para os valores próximos das referências.

Outros índices podem ser medidos para a verificação do desempenho dos algoritmos de separação cega de fontes dos sinais simulados. As Tabelas 5.1 e 5.2 mostram




Figura 5.53: Espectros dos contatos e dos componentes estimados, da janela temporal número 15, usando o algoritmo NMF, com a divergência de Kullback-Leibler como função custo, no domínio da frequência.




Figura 5.54: Espectros dos contatos e dos componentes estimados, da janela temporal número 16, usando o algoritmo NMF, com a divergência de Kullback-Leibler como função custo, no domínio da frequência.




Figura 5.55: Espectros dos contatos e dos componentes estimados, da janela temporal número 17, usando o algoritmo NMF, com a divergência de Kullback-Leibler como função custo, no domínio da frequência.




Figura 5.56: Divergência KL entre as observações e entre os componentes estimados, pelo algoritmo NMF, usando a divergência KL como função custo, no domínio da frequência.




Figura 5.57: Divergência KL entre as referências e as observações, e entre as referências e as estimativas, usando o algoritmo NMF, com a divergência KL como função custo, no domínio da frequência.

estes índices para os algoritmos de ICA e NMF respectivamente. Pode ser observado que alguns destes índices, têm valores elevados apesar do algoritmo ter melhorado a SIR no componente estimado. Isto ocorre pelo fato, de que, a relação sinal/ruído também é atenuada fazendo com que na realização da medida do espectro de referência ocorra este aumento.

Tabela 5.1: Tabela com os índices desempenho entre os contatos e as referências; e entre os componentes estimados pelos algoritmos de ICA e as referências.

Índice	Contato	Domínio do tempo			Domínio da frequência			
		FastICA	JADE	Newton-like	FastICA	JADE	Newton-like	Janela
Referência 1								
Theil	0,1	0	0	1,0	0,3	0,3	0,3	15
CC	0,8	1,0	1,0	1,0	1,0	1,0	-1,0	
EMQ	20,0	5,3	5,2	5,3	89,8	89,7	119,0	
EMA	1,3	0,8	0,8	0,8	3,2	3,2	2,9	
Theil	0,1	0	0,1	0,2	0,4	0,3	0,3	16
CC	0,8	1,0	1,0	0,9	-1,0	1,0	-1,0	
EMQ	12,3	1,4	1,1	89,1	133,6	89,9	118	
EMA	1,2	0,6	0,6	2,0	3,2	3,2	2,9	
Theil	0,1	0	0,2	0	0,4	0,3	0,8	17
CC	0,8	1,0	1,0	1,0	-1,0	1,0	1,0	
EMQ	48,6	5,6	5,5	88,4	133,0	90,0	106	
EMA	2,0	0,9	0,8	0,8	3,2	3,2	3,1	
Referência 2								
Theil	0	0	0	0	0,4	0,4	0,3	15
CC	1,0	1,0	1,0	-1,0	-1,0	1,0	1,0	
EMQ	2,9	0,6	0,2	0,6	125,3	125,7	94,2	
EMA	0,8	0,4	0,4	0,4	1,0	1,0	1,0	
Theil	0	0	0	0	0,4	0,4	0,3	16
CC	1,0	1,0	1,0	1,0	-1,0	-1,0	1,0	
EMQ	9,9	0,6	0,2	0,6	125,3	125,7	94,2	
EMA	1,2	0,4	0,4	0,4	1	1	1	
Theil	0	0	0,1	0	0,4	0,4	0,4	17
CC	1,0	1,0	1,0	1,0	-1,0	-1,0	-1,0	
EMQ	17,3	7,5	7,5	7,4	125,3	125,3	108,5	
EMA	1,4	0,9	0,9	0,9	1,0	1,0	1,0	

Tabela 5.2: Tabela com os índices desempenho entre os contatos e as referências; e entre os componentes estimados pelos algoritmos de NMF e as referências.

Índice	Contato	Domínio do tempo		Domínio da frequência		
		Dist. Euc.	NMF Div. KL	Dist. Euc.	Div. KL	Janela
Referência 1						
Theil	0,1	0,2	0,2	0	0,	15
CC	0,8	-1,0	1,0	1,0	1,0	
EMQ	20,0	78,3	88,2	7,6	5,8	
EMA	1,3	2,0	2,1	4,2	4,2	
Theil	0,1	0,2	0,2	0	0	16
CC	0,8	0,9	1,0	1,0	1,0	
EMQ	12,3	89,1	79,7	4,3	1,9	
EMA	1,2	2,0	2,0	3,8	4,1	
Theil	0,1	0,2	0,2	0	0,1	17
CC	0,8	0,8	0,7	1,0	0,8	
EMQ	48,6	90	95	21	45	
EMA	2,0	2,2	2,3	3,0	3,5	
Referência 2						
Theil	0	0,2	0,2	0	0	15
CC	1,0	1,0	1,0	1,0	1,0	
EMQ	2,9	63,2	74,6	2,2	0,6	
EMA	0,8	1,9	2,1	1,0	1,0	
Theil	0	0,2	0,2	0	0	16
CC	1,0	1,0	1,0	1,0	1,0	
EMQ	9,9	79,0	67,3	4,7	1,7	
EMA	1,2	2,2	2,0	1,0	1,0	
Theil	0	0,2	0,2	0	0	17
CC	1,0	1,0	0,9	1,0	1,0	
EMQ	17,3	71,7	82,1	25,0	9,4	
EMA	1,4	0,4	0,4	0,4	10	

As Tabelas 5.3 e 5.4 mostram a SIR no domínio do tempo e no domínio da frequência, a cada janela temporal dos sinais simulados, que foram obtidas através dos algoritmos utilizando a análise de componentes independentes e a fatoração de matrizes não negativas. Pode-se verificar um comportamento mais eficaz dos algoritmos de ICA em relação aos algoritmos NMF. Os algoritmos de ICA mantiveram a SIR em valores atenuados mesmo quando os contatos estão se aproximando. O mesmo não acontece com os algoritmos de NMF. Em determinadas situações, percebe-se uma diminuição da SIR após as separação.

Tabela 5.3: **SIR**, em dB, janela a janela, dos sinais simulados no domínio do tempo com relação as observações e os componentes estimados algoritmos usando a ICA e a NMF.

Janela	Raw-data		Newton-like		FastICA		JADE		Dist. Euc.		Div. KL	
	$SIR_{1/2}$	$SIR_{2/1}$	$SIR_{1/2}$	$SIR_{2/1}$	$SIR_{1/2}$	$SIR_{2/1}$	$SIR_{1/2}$	$SIR_{2/1}$	$SIR_{1/2}$	$SIR_{2/1}$	$SIR_{1/2}$	$SIR_{2/1}$
1	8	11	12	14	12	11	11	14	4	13	8	10
2	8	11	12	15	11	15	11	14	4	5	0	0
3	8	14	11	18	12	14	12	16	7	8	4	6
4	10	14	12	16	12	17	11	17	2	8	6	10
5	9	17	12	16	13	13	10	16	4	9	5	13
6	11	17	14	15	14	17	14	17	1	5	4	11
7	14	18	17	17	17	18	15	17	5	9	4	10
8	13	14	13	17	13	15	13	15	3	7	8	4
9	15	19	15	20	14	16	13	18	2	8	4	10
10	14	17	16	17	15	16	15	18	2	9	4	8
11	18	17	16	17	14	16	16	13	1	3	3	8
12	13	16	15	14	15	17	15	18	0	10	5	6
13	10	15	15	14	12	15	13	16	6	9	9	10
14	7	10	14	13	13	12	13	16	1	0	7	11
15	5	7	13	14	13	14	13	13	8	12	7	11
16	4	4	12	11	13	9	12	10	0	0	2	4
17	1	3	10	10	11	10	10	10	1	0	0	0

Tabela 5.4: **SIR**, em dB, janela a janela, dos sinais simulados no domínio da frequência com relação as observações e os componentes estimados algoritmos usando a ICA e a NMF.

Janela	Raw-data		Newton-like		FastICA		JADE		Dist. Euc.		Div. KL	
	$SIR_{1/2}$	$SIR_{2/1}$	$SIR_{1/2}$	$SIR_{2/1}$	$SIR_{1/2}$	$SIR_{2/1}$	$SIR_{1/2}$	$SIR_{2/1}$	$SIR_{1/2}$	$SIR_{2/1}$	$SIR_{1/2}$	$SIR_{2/1}$
1	8	11	12	13	12	17	13	14	8	16	17	15
2	8	11	12	13	12	17	13	14	8	18	14	17
3	8	14	12	13	15	13	13	15	11	16	10	25
4	10	14	12	13	15	13	13	14	9	19	11	29
5	9	17	12	13	11	17	13	14	9	13	13	29
6	11	17	12	13	11	18	13	15	13	4	14	27
7	14	18	11	13	16	18	13	14	10	40	16	35
8	13	14	12	11	13	11	12	12	20	13	23	24
9	15	19	11	11	12	19	13	15	12	39	18	32
10	14	17	13	13	15	13	13	15	11	28	19	31
11	18	17	13	12	13	17	15	14	20	14	34	30
12	13	16	13	12	13	16	14	14	19	12	21	21
13	10	15	12	12	16	11	14	14	10	29	16	21
14	7	10	12	12	16	11	14	13	24	9	12	14
15	5	7	13	12	16	12	14	14	7	10	10	10
16	4	4	13	12	13	17	15	14	8	7	1	0
17	1	3	15	12	14	15	19	14	2	11	5	6

5.2 Dados Experimentais

Os dados experimentais caracterizam tanto o ruído de propulsão quanto o ruído de maquinário de cada um dos contatos. Desta forma, será permitida a realização das análises, DEMON e LOFAR, em cada uma das marcações. O ruído próprio foi adquirido, em uma marcação, onde estava a popa do navio, para que pudesse ser enfatizada as informações da propulsão do navio.

Em função da baixa relação sinal/ruído e da prévia informação sobre a rotação dos contatos, em cada uma das marcações, além do conhecimento das rotações do ruído próprio, todo o processamento, da análise DEMON, foi realizado entre 50 e 350 rpm e a apresentação gráfica da análise foi mostrada na faixa de rotação de 0 a 350 rpm.

A aquisição dos sinais foi realizada nas marcações, 190 e 205, que estão sofrendo a interferência cruzada durante todo o tempo, bem como na marcação 076, que corresponde ao sinal do ruído do próprio submarino. Cada um dos sinais têm a duração de aproximadamente 180 s, e foram divididos em janelas temporais de 60 s, produzindo um total de três janelas.


Na análise DEMON, os algoritmos de separação cega foram aplicados, no domínio do tempo (2), tendo em visto que, não foram obtidos resultados satisfatórios, para os dados simulados no domínio do tempo (1); e no domínio da frequência.

A classificação dos contatos foi realizada usando um classificador baseado em redes neurais, onde o treinamento foi realizado, utilizando os espectros da análise LOFAR.


5.2.1 Separação no domínio do tempo (2)

- **Algoritmo FastICA**

As Figuras 5.58, 5.59 e 5.60, mostram as análises DEMON de cada uma das marcações, do ruído próprio e dos seus respectivos componentes estimados da terceira janela temporal. A marcação 190 sofre a interferência das rotações de 120,1 e 304,7 rpm, que correspondem, respectivamente, à marcação 205 e ao ruído próprio. Enquanto que, a marcação 205 sofre a interferência do ruído próprio. Após a estimação dos componentes, estas interferências sofreram uma atenuação de 2 dB.




(a)




(b)

Figura 5.58: Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo FastICA no domínio do tempo (2).




(a)




(b)

Figura 5.59: Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado, pelo algoritmo FastICA no domínio do tempo (2).



(a)



(b)

Figura 5.60: Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado, pelo algoritmo FastICA no domínio do tempo (2).

A Figura 5.61 mostra o gráfico da divergência KL, entre as marcações 190e 205 e os seus respectivos componentes estimados, em cada janela temporal. A curva da divergência entre as estimativas das marcações permanece com os valores acima da divergência entre as marcações, mostrando obteve-se uma separação entre os sinais.






Figura 5.61: Divergência KL entre as marcações 190 e 205; e entre os componentes estimados pelo algoritmo FastICA no domínio do tempo (2).

- **Algoritmo JADE**

O algoritmo JADE obteve o comportamento diferente do FastICA, como mostram as Figuras 5.62, 5.63 e 5.64. Após a estimação dos componentes, a interferência 205 sofreu uma atenuação de 4dB, no componente estimado da 190, enquanto que, o ruído próprio permaneceu no mesmo patamar do componente estimado. No entanto, caso do componente 205, o ruído próprio sofreu uma atenuação de 2 dB.




(a)




(b)

Figura 5.62: Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo JADE no domínio do tempo (2).




(a)




(b)

Figura 5.63: Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado, pelo algoritmo JADE no domínio do tempo (2).



(a)



(b)

Figura 5.64: Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado, pelo algoritmo JADE no domínio do tempo (2).

A Figura 5.65 mostra o gráfico da divergência KL, entre as marcações 190e 205 e, entre os seus respectivos componentes estimados. Da mesma forma como ocorreu no algoritmo FastICA, a divergência entre as estimativas das marcações permaneceu com os valores acima da divergência entre as marcações, mostrando, mais uma vez, que ocorreu uma separação entre os

componentes estimados.






Figura 5.65: Divergência KL entre as marcações 190 e 205; e entre os componentes estimados pelo algoritmo JADE no domínio do tempo (2).

- **Algoritmo Newton-like**

O algoritmo Newton-like obteve um desempenho inferior aos dois algoritmos de ICA que foram apresentados anteriormente. As Figuras 5.66, 5.67 e 5.68 mostram que, após a separação cega, ocorreu uma atenuação de 1 no componente da marcação 205, porém, a rotação 146, 5 e o seu harmônico 293 pertencentes ao componente 190, que nem se apresentavam na marcação 205, passaram a ter uma SIR de 4dB e 2dB respectivamente. Isto mostra que o algoritmo não realizou uma boa separação entres as estimativas.




(a)




(b)

Figura 5.66: Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo Newton-like no domínio do tempo (2).




(a)




(b)

Figura 5.67: Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado pelo algoritmo Newton-like no domínio do tempo (2).



(a)



(b)

Figura 5.68: Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado pelo algoritmo Newton-like no domínio do tempo (2).

A divergência KL, entre os componentes estimados das marcações 190e 205 mostram bem esta situação. Em todas as três janelas a divergência entre as estimativas permaneceu com os valores abaixo da divergência entre as marcações como é mostrado na Figura 5.69.

- **Algoritmo NMF usando a distância Euclidiana como função custo**





Figura 5.69: Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações usando o algoritmo Newton-like.


As Figuras 5.70, 5.71 e 5.72 mostram os espectros das marcações e seus respectivos componentes usando o algoritmo NMF. Após a separação, o componente da marcação 190, criou rotações que não pertencem a nenhuma, das marcações e do ruído próprio; além de não atenuar a rotação de 120, 1 rpm que pertence a marcação 205. A rotação de 146, 5 rpm, no componente 190, sofreu uma atenuação de 1dB em relação a marcação 190.

No caso do componente da marcação 205 a interferência do ruído próprio sofreu uma atenuação de 3 dB em relação a respectiva marcação, mostrando uma melhora na SIR. O mesmo não acontece com o componente do ruído próprio. Ocorreu uma mistura da rotação de 102, 1 rpm que pertence a marcação 205.

Isto mostra que o algoritmo NMF usando como função custo a distância Euclidiana não realizou uma melhora na SIR no componente 190. Conseguiu apenas melhorar a SIR do componente 205, enquanto que no caso do componente do ruído próprio, apareceu uma interferência proveniente da marcação 205.




(a)




(b)

Figura 5.70: Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo NMF, no domínio do tempo (2), usando a distância Euclidiana como função custo.




(a)




(b)

Figura 5.71: Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado pelo algoritmo NMF, no domínio do tempo (2), usando a distância Euclidiana como função custo.



(a)



(b)

Figura 5.72: Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado pelo algoritmo NMF, no domínio do tempo (2), usando a distância Euclidiana como função custo.

A Figura 5.73 mostra divergência KL, entre as marcações e os respectivos componentes estimados. Nas janelas temporais 1 e 2, a divergência entre as estimativas permaneceu com os valores abaixo da divergência entre as marcações, mostrando que não houve uma eficiência na separação. Enquanto que, na ja-

nela temporal número 3, apesar da divergência entre dos componentes está com o valor maior do que a divergência entre as marcações, verificou-se de forma qualitativa de o componente 190 não realizou uma melhora na SIR.






Figura 5.73: Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações, usando o algoritmo NMF com a função distância Euclidiana, no domínio do tempo.

- **Algoritmo NMF usando como função custo a divergência de Kullback-Leibler**

Da mesma forma que ocorreu no algoritmo NMF, que usa a função custo distância Euclidiana, também aconteceu com o algoritmo NMF, usando a função custo divergência de Kullback-Leibler, no domínio do tempo. Obteve-se uma melhora da SIR em relação apenas ao componente da marcação 205. As Figuras 5.74, 5.75 e 5.76 mostram os espectros das marcações e seus respectivos componentes.




(a)




(b)

Figura 5.74: Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo NMF, usando a divergência de Kullback-Leibler como função custo, no domínio do tempo (2).




(a)




(b)

Figura 5.75: Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado pelo algoritmo NMF, usando a divergência de Kullback-Leibler como função custo, no domínio do tempo (2).



(a)



(b)

Figura 5.76: Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado pelo algoritmo NMF, usando a divergência de Kullback-Leibler como função custo, no domínio do tempo (2).

A Figura 5.77 mostra divergência KL, entre as marcações e os respectivos componentes estimados. Em todas as janelas, a divergência entre as estimativas permaneceu com os valores abaixo da divergência entre as marcações. Isto mostra mais uma vez que o algoritmo não obteve uma boa eficácia na

separação dos componentes.





Figura 5.77: Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações usando o algoritmo NMF com a função divergência de Kullback-Leibler, no domínio do tempo.

5.2.2 Separação cega no domínio da frequência


A separação cega de fontes, foi realizada no domínio da frequência com os dados experimentais. O mesmo critério utilizado para medir o desempenho dos algoritmos no domínio do tempo, também será usado para a avaliação no domínio da frequência.

- **Algoritmo FastICA**

As Figuras 5.78, 5.79 e 5.80, mostram os espectros das marcações, do ruído próprio e dos componentes estimados. Pode ser observado que, no componente da marcação 190, as interferências provenientes, da marcação 205 e do ruído próprio, sofreram uma atenuação de 7 e 8 dB, respectivamente, em relação ao espectro da marcação 190. No componente da marcação 205, a SIR em relação ao ruído próprio permaneceu constante, mostrando que este componente retornou o espectro da respectiva marcação. Conclui-se que o algoritmo realizou a estimação apenas de um componente.




(a)




(b)

Figura 5.78: Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo FastICA no domínio da frequência.




(a)




(b)

Figura 5.79: Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado, pelo algoritmo FastICA no domínio da frequência.



(a)



(b)

Figura 5.80: Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado, pelo algoritmo FastICA no domínio da frequência.

A Figura 5.81 mostra a divergência KL entre as marcações, 190 e 205, e entre as estimativas das respectivas marcações. A divergência entre as observações permaneceu, à cada janela temporal, com os valores maiores do que a divergência das marcações. Também, é possível observar que, na janela temporal 3, a divergência assume o maior valor, apesar do algoritmo ter realizado a separação

apenas de um componente.





Figura 5.81: Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações usando o algoritmo FastICA no domínio da frequência.


- **Algoritmo JADE**

Nas Figuras 5.82, 5.83 e 5.84, observa-se, através dos componentes das marcações estimadas, que ocorreu uma atenuação das interferências em cada um dos componentes. No componente da marcação 190, por exemplo, ocorreu uma atenuação de 9 dB em relação a interferência da rotação de 120, 1rpm e de 8 dB em relação ao ruído próprio.

No caso do componente estimado 205, ocorreu uma atenuação de 3 dB em relação a interferência de 304, 7rpm, que pertence ao ruído próprio. Além disto, pôde ser enfatizada uma rotação de valor um pouco menor do que a de 120, 1, que pertence também pertence ao componente estimado. Isto se deve ao fato de que o algoritmo conseguiu recuperar a variação da rotação ao longo do tempo.




(a)




(b)

Figura 5.82: Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo JADE no domínio da frequência.




(a)




(b)

Figura 5.83: Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado, pelo algoritmo JADE no domínio da frequência.



(a)



(b)

Figura 5.84: Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado, pelo algoritmo JADE no domínio da frequência.

A Figura 5.85 mostra a divergência KL entre as marcações e os respectivos componentes estimados das marcações que foram estimados pelo algoritmo no domínio da frequência. Pode ser observado que na janela temporal 3, a divergência entre os componentes tem um valor maior do que a divergência entre as marcações.






Figura 5.85: Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações, usando o algoritmo JADE, no domínio da frequência.

- **Algoritmo Newton-like**

As Figuras 5.86, 5.87 e 5.88, mostram os espectros das marcações e os respectivos componentes estimados. As interferências dos componentes estimados sofreram uma atenuação em relação as respectivas marcações mostrando a eficiência do algoritmo.




(a)




(b)

Figura 5.86: Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo Newton-like no domínio da frequência.




(a)




(b)

Figura 5.87: Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado, pelo algoritmo Newton-like no domínio da frequência.



(a)



(b)

Figura 5.88: Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado, pelo algoritmo Newton-like no domínio da frequência.

A Figura 5.89 mostra o gráfico da divergência KL entre as marcações e os componentes estimados usando o algoritmo Newton-like. A divergência entre os componentes das marcações permaneceram com os valores acima em relação a divergência entre as marcações. Isto mostra uma separação entre os espectros estimados de cada um dos componentes.





Figura 5.89: Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações usando o algoritmo Newton-like no domínio da frequência.


Uma outra forma de se realizar a separação cega de fontes é a utilização da fatoração de matrizes não negativas. A seguir serão mostrados dois algoritmos, com as suas respectivas função custo, que usam a fatoração de matrizes não negativas.

- **Algoritmo NMF usando a distância Euclidiana como função custo**

As Figuras 5.90, 5.91 e 5.92, mostram os espectros das marcações e os seus respectivos componentes estimados. O algoritmo não realizou a estimação dos componentes, de forma a atenuar as interferências em relação as marcações. Nos componentes estimados das marcações, 190 e 205, as interferências permaneceram com a mesma SIR das marcações.




(a)




(b)

Figura 5.90: Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo NMF, usando a distância Euclidiana como função custo, no domínio da frequência.




(a)




(b)

Figura 5.91: Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado pelo algoritmo NMF, usando a distância Euclidiana como função custo, no domínio da frequência.



(a)



(b)

Figura 5.92: Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado pelo algoritmo NMF, usando a distância Euclidiana como função custo, no domínio da frequência.

Na Figura 5.93 pode ser observado que, apesar dos componentes estimados não terem realizado uma melhora na SIR em relação as marcações, a divergência entre os componentes permaneceu com os valores acima da divergência entre as marcações. Isto acontece, pelo fato de que, os espectros dos componentes

estarem com características dos bins de frequências diferentes entre os seus componentes.






Figura 5.93: Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações usando o algoritmo NMF com a distância Euclidiana como função custo no domínio da frequência.

- **Algoritmo NMF usando a divergência de Kullback-Leibler como função custo**

A separação cega usando NMF com a divergência de Kullback-Leibler como função custo, melhorou a SIR apenas no componente da marcação 190, como pode ser observado na Figura 5.94. O componente da marcação 205, Figura 5.95, colocou o nível da interferência no mesmo patamar do componente estimado. Apesar do algoritmo ter melhorado a SIR, apenas do componente 190, o valor da divergência KL entre os componentes é maior do que as marcações. A Figura 5.97 mostra a divergência KL entre as marcações e os componentes estimados pelo algoritmo.




(a)




(b)

Figura 5.94: Análise DEMON, da terceira janela temporal, da marcação 190: (a) original e (b) estimado pelo algoritmo NMF, usando a divergência de Kullback-Leibler como função custo, no domínio da frequência.




(a)




(b)

Figura 5.95: Análise DEMON, da terceira janela temporal, da marcação 205: (a) original e (b) estimado pelo algoritmo NMF, usando a divergência de Kullback-Leibler como função custo, no domínio da frequência.



(a)



(b)

Figura 5.96: Análise DEMON, da terceira janela temporal, do ruído próprio: (a) original e (b) estimado pelo algoritmo NMF, usando a divergência de Kullback-Leibler como função custo, no domínio da frequência.

As Tabelas 5.5 e 5.6 mostram os níveis em dB das interferências, em relação as marcações e dos componentes estimados pelos algoritmos de ICA e de NMF em cada janela temporal.




Figura 5.97: Divergência KL entre as marcações 190 e 205; e entre os componentes estimados das respectivas marcações usando o algoritmo NMF com a divergência da Kullback-Leibler como função custo no domínio da frequência.

Tabela 5.5: Nível em dB, das marcações (raw-data) e dos componentes estimados, pelos algoritmos de ICA, à cada janela temporal.

Rotação	Raw-data	Domínio do tempo			Domínio da frequência			Janela
		FastICA	JADE	Newton-like	FastICA	JADE	Newton-like	
Marcação 190⁰								
146,5	0	0	0	0	0	0	0	1
293,0	0	-1	1	-1	0	0	0	
99,6	-3	-2	-1	-2	-7	-7	-9	
304,7	-1	-1	-2	-4	-2	-8	-6	
146,5	0	0	0	0	0	0	-1	2
293,0	0	-1	-1	0	0	0	0	
99,6	-3	-2	-1	-3	-5	-7	-9	
304,7	-1	-3	-2	-4	-2	-3	-6	
146,5	0	0	0	0	0	0	0	3
293,0	0	0	0	0	0	0	0	
120,1	-1	-3	-5	-2	-8	-10	-7	
304,7	0	-2	0	-1	-8	-8	-15	
Marcação 205⁰								
99,6	0	0	1	0	0	0	-4	1
304,7	-1	-6	-6	-7	-1	-3	-4	
99,6	0	0	0	0	0	0	-4	2
304,7	-1	-5	-6	0	-4	-1	-4	
120,1	0	0	0	0	0	0	0	3
304,7	-1	-3	-5	-2	0	-14	-7	

Tabela 5.6: Nível em dB, das marcações (raw-data) e dos componentes estimados, pelos algoritmos NMF, à cada janela temporal.

Rotação	Raw-data	Domínio do tempo		Domínio da frequência		
		Dist. Euc.	Div. KL	Dist. Euc.	Div. KL	Janela
Marcação 190⁰						
146,5	0	-3	-1	0	0	1
293,0	0	-4	0	0	0	
99,6	-3	0	-2	-8	-2	
304,7	-1	-2	0	-3	-2	
Marcação 205⁰						
146,5	0	-2	-4	0	-3	2
293,0	0	0	-2	0	0	
99,6	-3	-4	-1	-6	-6	
304,7	-1	-1	-2	-3	-17	
Marcação 205⁰						
146,5	0	0	-4	0	-2	3
293,0	0	0	-1	0	0-2	
120,1	-1	-1	0	-1	-3	
304,7	0	0	0	0	0	
Marcação 205⁰						
99,6	0	0	0	0	0	1
304,7	-1	-3	-1	0	-1	
Marcação 205⁰						
99,6	0	0	0	0	0	2
304,7	-1	-2	-1	0	-3	
Marcação 205⁰						
120,1	0	0	0	0	0	3
304,7	-1	-3	-3	0	0	

Outra forma de medir o desempenho dos algoritmos de, ICA e NMF, é calcular, a resolução da amplitude das rotações, das marcações e dos componentes estimados, através da largura à meia altura (FWHM - Full Width Half Medium). As Tabelas 5.7 e 5.8 mostram, estas medidas, em cada uma das janelas temporais.

Os algoritmos de ICA, no domínio do tempo, praticamente não mudaram a largura à meia altura dos componentes estimados em relação as respectivas marcações. Enquanto que, no caso domínio da frequência, houve uma melhor resolução da amplitude, nos componentes estimados, em todas as janelas temporais. Para esta medida, os componentes que obtiveram uma melhor resolução de amplitude, foram os estimados pelo algoritmo Newton-like no domínio da frequência.

No caso dos algoritmos de NMF, a largura à meia altura dos componentes estimados no domínio do tempo, tiveram uma resolução de amplitude pior do que, a resolução, das respectivas marcações. Já no caso das estimativas dos componentes, no domínio da frequência, a NMF, que tem como função custo a distância Euclidiana, obteve uma melhor resolução de amplitude em todas as janelas temporais.

Pode-se concluir que os algoritmos de ICA mostraram um desempenho melhor do que os algoritmos NMF na separação cega dos sinais, além de melhorar a SIR à cada janela temporal

Tabela 5.8: Largura à meia altura das rotações, das marcações (raw-data) e dos componentes estimados, pelos algoritmos de NMF à cada janela temporal.

Raw-data	Domínio do tempo		Domínio da frequência		Janela
	Dist. Euclidiana	Div. KL	Dist. Euclidiana	Div. KL	
Marcação 190⁰					
146,5 ± 3,2	–	146,5 ± 10,8	146,5 ± 3,1	146,5 ± 2,8	1
293,0 ± 3,7	–	293,0 ± 7,0	293,0 ± 3,0	293,0 ± 2,9	
146,5 ± 3,7	146,5 ± 8,7	–	146,5 ± 2,8	146,5 ± 7,6	2
293,0 ± 3,7	293,0 ± 4,4	–	293,0 ± 2,6	293,0 ± 4,9	
146,5 ± 3,2	146,5 ± 6,5	–	146,5 ± 3,0	–	3
293,0 ± 3,2	–	–	293,0 ± 1,7	–	
Marcação 205⁰					
99,6 ± 11,0	–	99,6 ± 7,0	99,6 ± 3,0	99,6 ± 7,7	1
99,6 ± 11,0	99,6 ± 11,0	99,6 ± 12,4	99,6 ± 10,8	99,6 ± 10,5	2
120,1 ± 8,5	120,1 ± 7,7	120,1 ± 10,4	120,1 ± 6,1	120,1 ± 3,8	3
Ruído próprio					
304,7 ± 5,7	–	–	304,7 ± 3,1	304,7 ± 4,7	1
304,7 ± 5,7	304,7 ± 3,5	–	304,7 ± 4,1	304,7 ± 0,8	2
304,7 ± 3,3	304,7 ± 6,5	304,7 ± 9,8	304,7 ± 2,3	–	3

Tabela 5.7: Largura à meia altura das rotações, das marcações (raw-data) e dos componentes estimados, pelos algoritmos de ICA em cada janela temporal.

Raw-data	Domínio do tempo			Domínio da frequência			Janela
	FastICA	JADE	Newton-like	FastICA	JADE	Newton-like	
Marcação 190⁰							
146,5 ± 3,2	146,5 ± 3,2	146,5 ± 3,8	146,5 ± 3,3	146,5 ± 3,2	146,5 ± 2,4	146,5 ± 0,6	1
293,0 ± 3,7	293,0 ± 3,7	293,0 ± 3,7	293,0 ± 3,4	293,0 ± 3,1	293,0 ± 3,0	293,0 ± 3,4	
146,5 ± 3,7	146,5 ± 3,5	146,5 ± 3,7	146,5 ± 3,1	146,5 ± 2,6	146,5 ± 2,4	146,5 ± 0,6	2
293,0 ± 3,7	293,0 ± 3,7	293,0 ± 4,0	293,0 ± 3,5	293,0 ± 3,3,0	293,0 ± 3,1	293,0 ± 2,7	
146,5 ± 3,2	146,5 ± 2,9	146,5 ± 3,3	146,5 ± 3,0	146,5 ± 2,5	146,5 ± 2,4	146,5 ± 2,2	3
293,0 ± 3,2	293,0 ± 3,2	293,0 ± 3,7	293,0 ± 3,3	293,0 ± 2,4	293,0 ± 2,2	293,0 ± 2,2	
Marcação 205⁰							
99,6 ± 11,0	99,6 ± 10,4	99,6 ± 11,0	99,6 ± 10,3	99,6 ± 10,8	99,6 ± 9,9	99,6 ± 9,9	1
99,6 ± 11,0	99,6 ± 10,4	99,6 ± 10,5	99,6 ± 10,9	99,6 ± 10,6	99,6 ± 9,7	99,6 ± 9,7	2
120,1 ± 8,5	120,1 ± 8,3	120,1 ± 7,9	120,1 ± 8,1	120,1 ± 3,0	120,1 ± 4,2	120,1 ± 3,9	3
Ruído próprio							
304,7 ± 5,7	304,7 ± 5,7	304,7 ± 5,7	304,7 ± 7,7	304,7 ± 6,3	304,7 ± 6,4	304,7 ± 6,4	1
304,7 ± 5,7	304,7 ± 5,7	304,7 ± 4,1	304,7 ± 7,4	304,7 ± 6,2	304,7 ± 6,4	304,7 ± 6,4	2
304,7 ± 3,3	304,7 ± 3,2	304,7 ± 3,2	304,7 ± 3,2	304,7 ± 3,0	304,7 ± 3,4	304,7 ± 3,3	3

5.2.3 Análise da estacionaridade

Os sinais de sonar passivo são não estacionários, devido as características do ambiente acústico submarino e as condições externas (vento, condições climáticas, etc.). Devido a isto, se faz necessário a monitorização, destes sinais, para que toda vez que ocorra uma mudança nas estatísticas, dos sinais, a matriz de separação seja atualizada. Uma forma de implementar esta monitoração é através de agrupamento, dos espectros das análises, utilizando redes neurais [67]. Este agrupamento pode ser baseado em um treinamento não supervisionado.

A ideia central é fazer um sistema que realize o agrupamento dos espectros, das

análises, DEMON e LOFAR, e observar quando ocorre uma mudança na estatística. A análise da estacionaridade foi realizada com os espectros da análise DEMON, sendo possível aplicar o mesmo critério nos espectros da análise LOFAR.

Cada espectro da análise DEMON tem 513 bins de frequências. Foi realizada uma análise de componentes principais (PCA) [18] e [68], com o objetivo de fazer uma redução na dimensão dos dados. A Figura, 5.98, mostra a curva de energia acumulada. Desta forma, o processo de agrupamento pode ser realizado projetando os dados somente em dois componentes.




Figura 5.98: Energia acumulada.

Para o agrupamento, foi utilizada uma rede ART modificada (Adaptive Resonance Theory) [69]. O treinamento é competitivo e baseado em uma camada de Kohonen, adicionando um neurônio para cada novo padrão de entrada. Os parâmetros de controle são, o raio de vigilância do agrupamento e da taxa de aprendizagem. O raio de vigilância é definido pelo valor mais provável, obtido, a partir da medição da distância Euclidiana de todos os padrões de entrada de dados.

O modelo conceitual do agrupamento consiste em:

- Informações obtidas do operador sonar, mostram que os sinais de sonar passivo devem ser avaliados a cada 10 segundos para a verificação das alterações estatísticas. Como a análise DEMON apresenta uma realização a cada 500 ms, então, se faz necessário a aquisição de 20 espectros, que corresponde aos 10 segundos;
- Como a dimensão dos dados é elevada, uma PCA foi utilizada para reduzir

esta dimensão;

- Os agrupamentos são formados a partir destas 20 realizações;
- Mudança no número de agrupamentos são avaliadas, em conjunto com as mudanças dos possíveis centro dos agrupamentos; e
- Mudança na estatísticas são, então, identificadas.

Agrupar é criar um neurônio para cada conjunto de espectros, semelhantes, entre cada padrão de entrada. A Figura 5.99, mostra a evolução do número de agrupamentos. Esta informação mostra que existe, um ou mais de um novo grupo para cada agrupamento para cada observação. Pode ser observado que ocorreu uma grande variação da observação 7 para a 8, pelo fato de que o número de agrupamentos passou de 3 para 5. Isto mostra uma forte indicação de que ocorreu uma mudança significativa das estatísticas dos espectros dos sinais.




Figura 5.99: Número de grupos após a observação de cada agrupamento.

5.2.4 Classificação de contatos

Uma parte importante, no processamento, de um sistema de sonar passivo é a realização da classificação de um contato após a detecção, do mesmo, em uma determinada direção de interesse. Neste trabalho, o classificador foi desenvolvido usando redes neurais. Através da análise LOFAR, que é baseada na estimação espectral, as características relevantes dos contatos são apresentadas, tais como, ruído de vi-

bração e de maquinário, que permite o treinamento da rede para a classificação do contato.

Dependendo da resolução na estimação da direção de chegada e da posição que o contato se encontra, em relação aos outros contatos que estão no cenário de operação, a interferência entre estes contatos pode acontecer, contaminando os sinais que estão sendo adquiridos e tornando ainda mais difícil a classificação por parte do operado sonar.

A ideia é utilizar um sistema de classificação automático com o propósito de apoiar o operador sonar na decisão de identificar um contato, especialmente na presença de múltiplos alvos. Neste trabalho, foram usados apenas dois contatos, que serviram como um indicativo de possibilidade de classificação de múltiplos alvos. Com o objetivo de melhorar a classificação, algoritmos de separação cega de fontes foram utilizados, de forma à minimizar a interferência entre os contatos. Os algoritmos foram aplicados após a análise LOFAR, como um passo no pré-processamento da classificação, tanto no treinamento da rede quanto na classificação, de forma a recuperar as características relevantes dos contatos que devem ser classificados.

- **Classificador Neural**

Foram utilizados sinais experimentais de duas marcações, 190 e 205 que estão sofrendo a interferência cruzada todo o tempo, além do ruído próprio. Resultados foram obtidos a partir dos espectros, de 2.048 bins de frequência, da análise LOFAR de cada uma das marcações. Cada uma das marcações tem um tempo aproximado de 180 segundos. Como, cada janela temporal tem ~ 6 ms, isto resulta num total de ~ 3000 janelas temporais para cada uma das marcações.

As janelas temporais, de cada uma das marcações foram divididas em três conjuntos: treinamento, validação e teste. Os espectros, da análise LOFAR de cada uma das marcações, foram escolhidos de forma alternada, pares e ímpares.

Para que pudesse ser feito uma avaliação do pré-processamento, usando a separação cega de fontes, o classificador neural foi treinado usando os espectros da análise LOFAR, sem e com o pré-processamento usando os algoritmos de BSS.

Foi calculado um espectro médio, a partir, da janela temporal da análise de cada uma das marcações, conforme é mostrado na Figura 5.100. Pode-se observar uma semelhança entre os espectros de cada uma das classes. Então, algoritmos de BSS foram aplicados nestes espectros com o objetivo de melhorar as características de cada uma das classes, melhorando, desta forma, a eficiência na classificação.




Figura 5.100: Espectro médio da análise LOFAR de cada uma das marcações.

Tabela 5.9: Número de neurônios na camada escondida em relação ao melhor índice SP de cada algoritmo.

Pré-processamento	Neurônios	$SP \times 100$
LOFAR	6	84,60
LOFAR+FastICA	4	99,74
LOFAR+JADE	4	98,44
LOFAR+Newton-like	3	99,97
LOFAR+dist. Euc.	5	91,15
LOFAR+div. KL	5	88,56

A escolha do número de neurônios na camada escondida dos classificadores foi realizada de maneira iterativa. Inicialmente, uma rede neural com uma única camada escondida e dois neurônios foi treinada e a eficiência, da rede, foi estimada através do índice SP . Novos neurônios foram sendo adicionados à camada escondida e o treinamento recomeçava até que o índice SP se estabilizasse próximo ao seu máximo [65]. A Tabela 5.9 mostra o número de neurônios para cada um dos classificadores com os seus respectivos índices SP . Pode ser observado que o pré-processamento usando o algoritmo Newton-like obteve um melhor índice SP com um menor número de neurônios na camada escondida.

As Figuras de 5.101 a 5.105 mostram os espectros da análise LOFAR referentes a cada um dos componentes estimados, pelos algoritmos de separação cega. Pode ser observado que os algoritmos de ICA, realizaram a estimação, dos componentes, de maneira mais eficaz do que os algoritmos de NMF.




Figura 5.101: Espectro médio da análise LOFAR de cada componente estimado pelo algoritmo FastICA.




Figura 5.102: Espectro médio da análise LOFAR de cada componente estimado pelo algoritmo JADE.




Figura 5.103: Espectro médio da análise LOFAR de cada componente estimado pelo algoritmo Newton-like.




Figura 5.104: Espectro médio da análise LOFAR de cada componente estimado pelo algoritmo NMF, usando a distância Euclidiana como função custo.






Figura 5.105: Espectro médio da análise LOFAR de cada componente estimado pelo algoritmo NMF, usando a divergência de Kullback-Leibler como função custo.

A Figura, 5.106(a), apresenta a saída da rede neural, utilizando apenas os espectros obtidos pela análise LOFAR, mostrando que as classes estão misturadas. Isto significa que a análise LOFAR, sem nenhum processamento, não é suficiente para a separação das classes de maneira eficiente. Este fato, pode ser comprovado pelo baixo valor do produto SP mostrado através da curva ROC, Figura 5.106(b). Nesta Figura, pode ser observado que o ponto cujo o valor de SP é máximo se encontra distante do eixo de probabilidade de detecção. Então, foi realizado um processamento posteriormente a análise LOFAR, usando os algoritmos de separação cega de fontes, com o objetivo de melhorar o desempenho na classificação das classes.




(a) Saída do classificador neural utilizando os espectros da análise LOFAR.




(b) Curva ROC do classificador.

Figura 5.106: Classificação utilizando os espectros da análise LOFAR.




(a) Saída do classificador neural, utilizando os espectros da análise LOFAR, processados pelo algoritmo FastICA.




(b) Curva ROC do classificador.

Figura 5.107: Classificação utilizando o algoritmo FastICA como pós-processamento dos espectros da análise LOFAR.




(a) Saída do classificador neural, utilizando os espectros da análise LOFAR processados pelo algoritmo JADE.




(b) Curva ROC do classificador.

Figura 5.108: Classificação utilizando o algoritmo JADE como pós-processamento dos espectros da análise LOFAR.




(a) Saída do classificador neural, utilizando os espectros da análise LOFAR processados pelo algoritmo Newton-like.




(b) Curva ROC do classificador.

Figura 5.109: Classificação utilizando o algoritmo Newton-like como pós-processamento dos espectros da análise LOFAR.




(a) Saída do classificador neural, utilizando os espectros da análise LOFAR processados pelo algoritmo NMF, usando como função custo a distância Euclidiana.




(b) Curva ROC do classificador.

Figura 5.110: Classificação utilizando o algoritmo NMF, com a distância Euclidiana como função custo, nos espectros da análise LOFAR.



(a) Saída do classificador neural, utilizando os espectros da análise LOFAR processados pelo algoritmo NMF, usando como função custo a divergência de Kullback-Leibler.



(b) Curva ROC do classificador.

Figura 5.111: Classificação utilizando o algoritmo NMF, com a divergência de Kullback-Leibler como função custo, nos espectros da análise LOFAR.

A Tabela 5.10 mostra um resumo do desempenho, obtido para cada um dos classificadores, através do índice SP ótimo. Pode ser observado que o classificador que obteve a maior eficiência foi aquele cujo os espectros foram processados pelo algoritmo Newton-like.

Tabela 5.10: Eficiência da discriminação obtida por cada um dos classificadores.

Processamento	SP × 100	Eficiência classe 1	Eficiência classe 2
LOFAR	84,60	86,94	82,29
LOFAR+FastICA	99,74	99,71	99,76
LOFAR+JADE	98,44	99,35	97,53
LOFAR+Newton-like	99,97	100	99,94
LOFAR+Dist. Euc.	91,15	94,24	88,12
LOFAR+Div. KL	88,56	89,95	87,47

Capítulo 6

Conclusões e Trabalhos Futuros

Sistemas de sonar passivo são importantes em diversas áreas de acústica submarina, tanto em aplicações civis quanto em militares. Em muita das vezes, os sinais do sistema de sonar passivo estão suscetíveis à interferência cruzada de fontes acústicas presentes em diferentes direções de interesse e do ruído ambiente que, em determinadas situações, está presente com grande intensidade. Além disto, o ruído da propulsão do navio onde o conjunto de hidrofones estão instalados, também pode interferir nos sinais provenientes dos alvos, empobrecendo a eficiência da classificação e identificação dos alvos. A separação cega de fontes é um método utilizado para o processamento de sinais, que visa a recuperação de fontes dos sinais de interesse, a partir de suas versões misturadas. Neste trabalho, foram utilizados a análise de componentes independentes (ICA) e a fatoração de matrizes não negativas (NMF) para a realização da separação.

A ideia de se usar a separação cega de fontes é melhorar as análises que são realizadas pelo sistema de sonar passivo, ajudando, desta forma, ao operador de sonar na detecção e classificação de contatos. Por isto, se faz necessário aumentar a complexidade nos sistemas de sonar passivo, tornando-os mais autônomos para a realização da detecção e classificação dos contatos. O objetivo é que o sistema de sonar passivo possa mostrar com mais clareza as características dos alvos a serem detectados.

A ideia neste trabalho foi utilizar dados simulados para verificar o comportamento da separação cega, tanto no domínio do tempo quanto no domínio da frequência, para ver onde a separação tem melhor eficácia, além de verificar qual algoritmo tem melhor desempenho nestes domínios.

Após esta análise com os dados simulados, foram utilizados dados experimentais adquiridos em um sistema de sonar passivo, que está instalado nos submarinos, da Marinha do Brasil, com o objetivo de verificar o comportamento dos algoritmos e das técnicas utilizadas quando se está trabalhando com dados reais.

Medidas de desempenho foram utilizadas para avaliar, as análises e os algoritmos,

tanto no caso dos dados simulados quanto dos dados experimentais. Pôde-se concluir que os algoritmos de ICA, Newton-like e JADE, no domínio da frequência, tiveram um desempenho melhor do que os algoritmos de NMF.

Esperava-se uma melhor performance dos algoritmos de NMF, pelo fato deles não terem a restrição da independência entre os componentes. Porém, a medida que a SIR começava diminuir nos contatos, no caso dos dados simulados, os algoritmos de NMF, tanto no domínio de tempo quanto no domínio da frequência, começavam a misturar os sinais.

Outro ponto importante neste trabalho, foi a monitoração da estacionaridade dos sinais da análise DEMON, utilizado o método de agrupamento para a verificação da mudança da estatística dos sinais para a realização da atualização da matriz de separação. Um sistema usando redes neurais não supervisionadas teve um desempenho para esta monitoração.

Foi também proposto uma operação do sistema que monitora, tanto as análises DEMON e LOFAR para ver a necessidade da aplicação dos métodos de separação cega.

6.1 Trabalhos Futuros

Poderão ser desenvolvimentos novos algoritmos de separação cega aplicados à sinais de sonar passivo com as seguintes vertentes:

- ICA com ruído;
- ICA aplicando misturas convolutivas;
- NMF utilizando outras divergências.

Além disto, um estudo mais detalhado do ruído ambiente poderá ser realizado para que, este ruído, seja colocado como mais um fonte no modelo de separação cega, podendo melhorar ainda mais a SIR entre os sinais.

Finalmente, desenvolver um sistema que possa ser instalado e operar, nas análises DEMON e LOFAR, nos submarinos da Marinha do Brasil para que o sistema de sonar passivo tenha maior robustez na detecção e classificação de contatos.

Referências Bibliográficas

- [1] JOHNSON, D. H., DUDGEON, D. E., *Array Signal Processing: Concepts and Techniques*. Prentice Hall Signal Processing Series, 1993.
- [2] NIELSEN, R. O., *Sonar Signal Processing*. Artech House Inc, Nortwood, 1991.
- [3] FAN, W., ZHANG, X., JIANG, B., “A New Passive Sonar Bearing Estimation Algorithm Combined with Blind Source Separation”, *Computational Sciences and Optimization, International Joint Conference on*, v. 1, pp. 15–18, 2010.
- [4] Silva, S. R. (ed.), *Advances in Sonar Technology*. 1 ed. InTech, February 2009.
- [5] BURDIC, W. S., *Underwater Acoustic System Analysis*. Prentice-Hall, 1984.
- [6] URICK, R., *Principles of Underwater Sound for Engineers*. McGraw-Hill, 1983.
- [7] KRIM, H., VIBERG, M., “Two decades of array signal processing research: The parametric approach”, *IEEE Signal Processing Magazine*, v. 13, n. 4, pp. 67–94, July 1996.
- [8] DINIZ, P. S. R., SILVA, E. A. B. D., NETTO, S. L., *Digital Signal Processing: System Analysis and Design*. Cambridge University Press, 2002.
- [9] BRIGHAM, E., *Fast Fourier Transform and its Application*. Prentice Hall Signal Processing Series, 1988.
- [10] STRUZINSKI, W. A., LOWE, E. D., “A Performance Comparison of Four Noise Background Normalization Schemes for Signal Detection Systems”, *J. Acoust. Soc. Am.*, v. 76, n. 6, pp. 1738–1742, Dec. 1984.
- [11] STRUZINSKI, W. A., LOWE, E. D., “The Effect of Improper Normalization on Performance of an Automated Energy Detector”, *J. Acoust. Soc. Am.*, v. 78, n. 3, pp. 936–941, September 1985.
- [12] L., H., TREES, V., *Detection, Estimation and Modulation Theory, Part I*. John Wiley and Sons, Inc., 2001.

- [13] FILHO, W. S., SEIXAS, J. M., MOURA, N. N., “Preprocessing Passive Sonar Signals for Neural Classification”, *IET Radar, Sonar and Navigation*, v. 5, n. 6, pp. 605–612, July 2011.
- [14] MOURA, N. N. D., FILHO, W. S., SEIXAS, J. M. D., “Classificação Neural de Sinais de Sonar Passivo com base em Componentes Independentes”, *VIII Congresso Brasileiro de Redes Neurais*, , outubro 2007.
- [15] MOURA, N. N., CALÔBA, L. P., SEIXAS, J. M., “Classificação Neural de Sinais de Sonar Passivo”, *XVII Congresso Brasileiro de Automática*, pp. 1–6, Setembro 2008.
- [16] HAYKIN, S., *Neural Networks, A Comprehensive Foundation*. Prentice Hall, segunda edição, 1999.
- [17] TORRES, R. C., SEIXAS, J. M. D., FILHO, W. S., “Classificação de sinais de sonar passivo utilizando componentes principais não-lineares”, *Learning and nonlinear models*, v. 1, n. 4, pp. 208–222, 2004.
- [18] W., S.-F., MANOEL DE SEIXAS, J., PEREIRA CALOBA, L., “Principal component analysis for classifying passive sonar signals”, *ISCAS*, v. 3, pp. 592–595, May 2001.
- [19] PEYVANDI, H., FAZAEEFAR, B., AMINDAVAR, H., “Determining class of underwater vehicles in passive sonar using hidden Markov with Hausdorff similarity measure”, *Proceedings of International Symposium on Underwater Technology*, pp. 258–261, April 1998.
- [20] L.MARPLE, BROTHERTON, T., “Detection and classification of short duration underwater acoustic signals by Prony method”, *International Conference on Acoustics, Speech, and Signal Processing*, v. 2, pp. 1309–1312, May 1991.
- [21] ROSS, D., *Mechanics of Uderwater Noise*. New York: Pergamon Press, 1976.
- [22] OJA, A. H. E., “Independent Component Analysis: Algorithms and Applications”, *Neural Networks*, v. 4, n. 13, pp. 411–430, 2000.
- [23] CICHOCKI, A., ZDUNEK, R., AMARI, S.-I., “Csiszár’s Divergences for Non-negative Matrix Factorization: Family of New Algorithms”, *Proceedings of Sixth International Conference on Independent Component Analysis and Blind Source Separation, Charleston, SC*, pp. 5–8.
- [24] HYVÄRINEN, A., KARHUNEN, J., OJA, E., *Independent Component Analysis*, September 2001.

- [25] CICHOCKI, A., ZDUNEK, R., PHAN, A. H., *et al.*, *Nonnegative Matrix and Tensor Factorizations Applications to Exploratory Multi-way Data Analysis and Blind Source Separation*, 2009.
- [26] ANS, B., HÉRAULT, J., “Circuits neuronaux à synapses modifiables: décodage de messages composites par apprentissage non supervisé”, *C. R. De l’Académie des Sciences*, v. III, n. 13, pp. 525–528, 1984.
- [27] ANS, B., HÉRAULT, J., JUTTEN, C., “Adaptive neural architectures: detection of primitives. Independent Component Analysis”, *Proceedings of Cognitiva’85*, pp. 593–597, Paris, France 1994.
- [28] ANS, B., HÉRAULT, J., JUTTEN, C., “Détection de grandeurs primitives dans une message composite par une architecture de calcul neuromimétique en apprentissage non supervisé”, *Actes du Xème colloque GRETSU*, pp. 1017–1022, Nice, France 1985.
- [29] JUTTEN, C., HÉRAULT, J., “Blind separation of sources, part I: An adaptive algorithm based on neuromimetic architecture”, *Signal Processing*, v. 24, n. 1, pp. 1–10, 1991.
- [30] CARDOSO, J. F., “Blind identification of independent signals”, *Workshop on Higher-Order Spectral Analysis*, , Vail, Colorado 1989.
- [31] COMMON, P., “Separation of Stochastic Processes”, *Workshop on Higher-Order Spectral Analysis*, pp. 174–179, Vail, Colorado 1989.
- [32] COMMON, P., “Separation of sources using high-order cumulants”, *SPIE Conference on Advanced Algorithms and Architectures for Signal Processing*, v. XII, pp. 170–181, San Diego 1989.
- [33] COMMON, P., “Independent Component Analysis, A new concept”, *Signal Processing*, v. 36, pp. 287–314, 1994.
- [34] BELL, A. J., SEJNOWSKI, T. J., “The Independent Components of natural scenes are edge filters”, *Vision Research*, v. 37, n. 23, pp. 3327–3338, 1997.
- [35] HYVARINEN, A., “Fast and Robust Fixed-Point Algorithms for Independent Component Analysis”, *IEEE Transactions on Neural Networks*, v. 10, n. 3, pp. 626–634, 1999.
- [36] CARDOSO, J. F., “Blind Signal Separation: Statistical and Principles”, *Proceedings of the IEEE*, v. 10, n. 10, pp. 2009–2025, October 1998.

- [37] A. PAPOULIS, S. U. P., *Probability, Random Variables and Stochastic Process*. McGraw-Hill, 2002.
- [38] SPIEGEL, M. R., SCHILLER, J. J., SRINIVASAN, R. A., *Probability and Statistic*. McGraw Hill - 2 ed., 2000.
- [39] HYVARINEN, A., KARHUNEN, J., OJA, E., “Independent Component Analysis: Algorithms and Applications”, *Helsinki University of Technology, Neural Networks*, v. 13, n. 4-5, pp. 411–430, 2000.
- [40] KIM, T. H., WHITE, H., “On more robust estimation of skewness and kurtosis”, *Financial Research Letters*, v. 1, pp. 56–73, 2004.
- [41] WELLING, M., “Robust higher order statistic”, *Proceedings of the Tenth International Workshop on Artificial Intelligence and Statistics*, pp. 405–412, january 2005.
- [42] COVER, T. M., THOMAS, J. A., *Elements of Information Theory*. John Wiley and Sons, New York, 1991.
- [43] SHANNON, C. E., “A mathematical theory of communication”, *he Bell System Technical Journal*, pp. 379–423, July 1948.
- [44] GEORGIEV, P., RALESCU, A., RALESCU, D., “Cross-cumulants measure for independence”, *Journal of Statistical Planning and Interference*, v. 137, pp. 1085–1098, 2006.
- [45] CARDOSO, J. F., “High-order constrast for independent component analysis”, *Neural Computation*, v. 11, n. 1, pp. 157–192, 1999.
- [46] WEGMAN, E. J., “Maximum likelihood estimation of a probability density function”, *Sanhya: The Indian Journal of Statistic*, , n. 37, pp. 211–224, 1975.
- [47] GRENANDER, U., *Abstract Inference (Probability and Mathematical Statistics)*. John Wiley and Sons, 1981.
- [48] PARZEN, E., “On estimation of a probability density function and mode”, *Annals of Mathematical Statistics*, v. 33, n. 3, pp. 1065–1076, September 1962.
- [49] SILVERMAN, B., *Density Estimation for Statistic and Data Analysis*. London Chapman & Hall, 1986.

- [50] TAYLOR, C. C., “Bootstrap choice of the smoothing parameter in kernel density estimation”, *Biometrika*, v. 76, n. 4, pp. 705–712, 1989.
- [51] SHAOLIN, L., SEJNOWSKI, T., “Adaptive Separation of mixed Broadband Sound Sources with Delays by a Beamforming Herault-Jutten Network”, *IEEE Journal of Oceanic Engineering*, v. 20, pp. 73–79, 1995.
- [52] YAN, D. P., J.PEACH, “Comparison of Blind Souce Separation Algorithms”, *Advances in Neural Networks and Applications*, pp. 18–21, 2000.
- [53] AKUZAWA, T., MURATA, N., “Multiplicative Nonholonomic Newton-like Algorithm.”, *Chaos, Solutions and Fractals*, v. 12, n. 4, pp. 785–793, January 2001.
- [54] AKUZAWA, T., “New Fast Factorization Method for Multivariate Optimazation and its Realization as ICA Algorithm”, *Proceedindgs of International Conference on Independent Component Analysis and Sginal Separation (ICA 2001). San Diego, California*, v. 9, n. 13, pp. 114–119, December 2001.
- [55] AKUZAWA, T., “Extended Quasi-Newton Method for ICA”, *Proc. Int. Workshop Independent Component Analysis. Blind Source Separation*, pp. 521–525, 2000.
- [56] LEE, D. D., SEUNG, S. H., “Learning the parts of objects by non-negative matrix factorization”, *Nature*, v. 401, pp. 788–791, October 1999.
- [57] SMITH, L. I., “A tutorial on Principal Components Analysis”, february 2002.
- [58] GRAY, R. M., “Vector Quantization”, *IEEE ASSP Magazine*, pp. 4–29, April 1984.
- [59] BERRY, M., BROWNE, M., LANGVILLE, A., *et al.*, “Algorithms and applications for approximate nonnegative matrix factorization”, *Computational Statistics and Data Analysis*, v. 1, pp. 155–173, 2007.
- [60] LEE, D. D., SEUNG, H. S., “Algorithms for Non-negative Matrix Factorization”, *In Advances Neural Information Processing*, v. 13 (Proc. NIPS*2000). MIT Press, 2001.
- [61] FÉVOTTE, C., IDIER, J., “Algorithms for nonnegative matrix factorization with the β -divergence”, *Available: <http://hal.archives-ouvertes.fr/hal-00522289/fr/>*, v. Online, 2010.

- [62] FÉVOTTE, C., BERTIN, N., DURRIEU, J.-L., “Nonnegative matrix factorization with the Itakura-Saito divergence. With application to music analysis”, *Neural Computation*, v. 21, n. 3, pp. 793–830, March 2009.
- [63] MOURA, N. N. D., SEIXAS, J. M. D., RAMOS, R. R., *Passive Sonar Signal Detection and Classification Based on ICA*, chapter 5, In: N. Z. Koley (Org.). *Sonar Systems*. IN-TECH, pp. 93–104, 2011.
- [64] RIEDMILLER, M., BRAUN, H., “A direct adaptive method for faster background learning, the RPROP algorithm”, *Proc. of Int. Conf. on Neural Networks*, pp. 586–591, 1993.
- [65] FILHO, E. F. S., MOURA, N. N. D., SEIXAS, J. M. D., “Neural Passive Sonar Classification using Independent Component Analysis”, *X Congresso Brasileiro de Inteligência Computacional (CBIC 2011)*, , Novembro 2011.
- [66] ANJOS, A. D., TORRRES, R., SEIXAS, J., “Neural triggering system operating on high resolution calorimetry information”, *Nuclear Instruments and Methods in Physics Research*, , n. 1, pp. 134–138, 2006.
- [67] RAMOS, R. R., *Redes Neurais para Monitoração de Estacionaridade de sinais de sonar passivo SINAIS DE SONAR PASSIVO*. M.Sc. dissertation, Universidade Federal do Rio de Janeiro, 2011.
- [68] CHIN-HSING, LEE, J.-D., LIN, M.-C., “Classification of Underwater Signals Using Neural Networks”, *Tamkang Journal of Science and Engineering*, v. 3, n. 1, pp. 31–48, 2000.
- [69] VASSALI, M. R., SEIXAS, J. M., CALÔBA, L. P., “A Neural Particle Discriminator based on a Modified ART Architecture”, *IEEE International Symposium on Circuits and Systems*, v. 2, pp. 121–124, May 2002.

Appendix

Apêndice A

Trabalhos Publicados

Apresentação de Trabalhos

1. **Moura, N. N.**; Igor Paladino; J. M. Seixas. Non-Negative Matrix Factorization for Improving Passive Sonar Signal Detection. 2011. X Congresso Brasileiro de Inteligência Computacional.
2. E. F. Simas Filho; **Moura, N. N.**; J. M. Seixas . Neural Passive Sonar Signal Classification using Independent Component Analysis. 2011. X Congresso Brasileiro de Inteligência Computacional.
3. Ricardo Ramos; **Moura, N. N.**; J. M. Seixas. Monitoração da Estacionariedade de Sinais de Sonar Passivo. 2011. X Encontro de Tecnologia em Acústica Submarina.
4. E. F. Simas Filho; **Moura, N. N.**; J. M. Seixas. Classificadores Neural de Sinais de Sonar Passivo usando Separação Cega de Sinais como Processamento. 2011. X Encontro de Tecnologia em Acústica Submarina.
5. **Moura, N. N.**; Igor Paladino; J. M. Seixas . Fatoração de Matrizes não Negativas para a Separação Cega de Fontes em Sinais de Sonar Passivo. 2011. X Encontro de Tecnologia em Acústica Submarina.
6. **Moura, N. N.**; J. M. Seixas. Passive Sonar Signal Detection using Independent Component Analysis as Preprocessing. 2010. 39th International Congress and Exposition on Noise Control Engineering.
7. **Moura, N. N.**; E. F. Simas Filho; J. M. Seixas. Narrow band Short-Time Frequency- Domain Blind Signal Separation of Passive Sonar Signals. 2009. 8th Conference on Independent Component Analysis.

8. **Moura, N. N.**; W. Soares Filho; J. M. Seixas. Classificação Neural de Sinais de Sonar Passivo com Base em Componentes Independentes. 2009. VIII Encontro de Tecnologia em Acústica Submarina.
9. **Moura, N. N.**; Felipe F. Graef; J. M. Seixas. Detecção e Classificação de Sinais de Sonar Passivo usando Redes Neurais. 2009. VIII Encontro de Tecnologia em Acústica Submarina.
10. **Moura, N. N.**; Calôba; J. M. Seixas. Classificação neural de sinais de sonar passivo. 2008. XVII Congresso Brasileiro de Automática.
11. **Moura, N. N.**; J. M. Seixas; W. Soares Filho; Ana Greco. Independent Component Analysis for Optimal Passive Sonar Signal Detection. 2007. International Conference on Intelligent Systems Design and Applications.
12. **Moura, N. N.**; E. F. Simas Filho; J. M. Seixas; Ana Greco. Análise DEMON sobre Fontes Independentes do Sinal de Sonar Passivo. 2007. VI Encontro de Tecnologia em Acústica Submarina.

Trabalhos Publicados em Jornais/Revistas

1. E. F. Simas Filho; J. M. Seixas; **Moura, N. N.**; Haddad, D. B.; Faier, J. M.; Maria C. S. Albuquerque. Independent Component Analysis and Blind Signal Separation: Theory, Algorithms and Applications. 2012. Learning and Nonlinear Models Journal of the Brazilian Neural Network Society, vol. 10, Iss. 1, p. 51 - 69.
2. W. Soares Filho; J. M. Seixas; **Moura, N. N.**. Preprocessing Passive Sonar Signals for Neural Classification. 2011. vol. 5, number: 6. IET Radar Sonar and Navigation, General Articles, p. 605 - 612.
3. **Moura, N. N.**; J. M. Seixas; W. Soares Filho. Classificação Neural de Sinais de Sonar Passivo com Base em Componentes Independentes. Learning and Nonlinear Models (1676-2789), p. 10 - 19, 14 mar. 2009.

Capítulo de Livros Publicados

1. **Moura, N. N.**; J. M. Seixas; Ricardo Ramos. Passive Sonar Signal Detection and Classification Based on ICA.. In: Z. Kolev. (Org.). Sonar Systems. : Intech, 2011, p. 93-104.
2. **Moura, N. N.**; E. F. Simas Filho; J. M. Seixas. Independent Component Analysis for Passive Sonar System Processing. In: Sergio Rui Silva. (Org.). Advances in Sonar Tecnology. Viena: Intech, 2009, p. 91-110.