



REDES NEURAIIS PARA MONITORAÇÃO DE ESTACIONARIEDADE DE SINAIS DE SONAR PASSIVO

Ricardo Rezende Ramos

Dissertação de Mestrado 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 Mestre em Engenharia Elétrica.

Orientador: José Manoel de Seixas

Rio de Janeiro
Setembro de 2011

REDES NEURAS PARA MONITORAÇÃO DE ESTACIONARIEDADE DE
SINAIS DE SONAR PASSIVO

Ricardo Rezende Ramos

DISSERTAÇÃO 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 MESTRE EM CIÊNCIAS EM ENGENHARIA
ELÉTRICA.

Examinada por:

Prof. José Manoel de Seixas, D.Sc.

Profa. Mariane Rembold Petraglia, Ph.D.

Prof. José Alfredo Ferreira Costa, Dr. Eng.

Prof. William Soares Filho, D.Sc.

RIO DE JANEIRO, RJ – BRASIL
SETEMBRO DE 2011

Ramos, Ricardo Rezende

Redes Neurais para Monitoração de Estacionariedade de Sinais de Sonar Passivo/Ricardo Rezende Ramos. – Rio de Janeiro: UFRJ/COPPE, 2011.

XII, 81 p.: il.; 29, 7cm.

Orientador: José Manoel de Seixas

Dissertação (mestrado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2011.

Referências Bibliográficas: p. 74 – 79.

1. Redes neurais. 2. Treinamento não supervisionado.
3. Clusterização. 4. Sonar passivo. I. de Seixas, José Manoel. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

Agradecimentos

- A Deus, o maior de todos.
- À minha família, meus pais, que me deram todo suporte necessário durante minha vida acadêmica, e meus filhos, por suportarem os momentos de ausência necessários para finalizar este trabalho.
- À minha namorada, Nathalie, pelo amor, apoio emocional e paciência, minha reserva de combustível imprescindível nas últimas voltas da corrida.
- Aos meus amigos, que sempre estiveram dispostos a me incentivar nos momentos de dificuldade, em especial, ao João Baptista Filho, pelas dicas sempre precisas no início deste trabalho, e também, ao Natanael Nunes Moura, pelas valiosas trocas de informações técnicas, pelo astral sempre pra cima e eternamente otimista, mesmo com a fragilidade da saúde, um verdadeiro exemplo de vida.
- À minha prima, Profa. Dra. Cheila Mothé, por me apresentar, ainda no final dos anos 90, ao desafiador e motivante mundo da pesquisa.
- Aos meus chefes, Gerente Geral Paulo Sérgio Alonso e Gerente Ronaldo Martins, da Petrobras, pelo apoio inicial à esta minha retomada de capacitação profissional e pelo constante incentivo à conclusão deste trabalho.
- Ao meu orientador, José Manoel de Seixas, pela paciência infinita nos piores momentos, pela postura paternal, quando problemas de ordem pessoal quase me fizeram desistir, e pela louvável, exemplar e reconhecida sabedoria empregada na orientação deste trabalho.

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

REDES NEURAIS PARA MONITORAÇÃO DE ESTACIONARIEDADE DE SINAIS DE SONAR PASSIVO

Ricardo Rezende Ramos

Setembro/2011

Orientador: José Manoel de Seixas

Programa: Engenharia Elétrica

Sinais de sonar passivo apresentam características não estacionárias, acarretando na necessidade de sua análise ser realizada em janelas. A mudança na estatística do sinal do sonar necessita ser detectada em tempo real, de forma que as técnicas de separação de interferências entre contatos, como a ICA, por exemplo, e os classificadores automáticos, geralmente fortemente baseados na estatística do sinal, tenham sua performance maximizada. Este trabalho tem por objetivo apresentar o desenvolvimento de um sistema neural de monitoração de sinais de sonar passivo, com base em uma rede não supervisionada ART modificada, que acompanha a estatística do sinal, de forma a indicar possíveis alterações. A rede ART modificada foi utilizada para fazer a clusterização dos espectros de frequência do sinal periodicamente. A análise DEMON foi utilizada para a obtenção dos espectros do sinal. Devido à elevada dimensão dos dados de entrada, foi utilizada uma técnica de pré-processamento do sinal para redução de dimensionalidade, a PCA. Adicionalmente, foi avaliado o impacto do uso de ICA na eficiência de um classificador MLP. Os resultados mostraram os benefícios, em termos da eficiência da classificação neural de contatos, da utilização de ICA no pré-processamento do sinal de sonar passivo.

Visando validar o sistema de monitoração proposto, alguns testes foram realizados fazendo uso da informação mútua e dos cumulantes cruzados de quarta ordem como figuras de mérito da não estacionariedade estatística. Nos melhores casos, uma eficiência de detecção de até 89% foi atingida, para os cumulantes cruzados como figura de mérito, e de até 75%, para a informação mútua como figura de mérito. Os resultados demonstram a aplicabilidade do sistema de monitoração proposto como ferramenta de auxílio ao operador de sonar na tomada de decisão.

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

NEURAL NETWORKS FOR STATIONARITY MONITORING OF PASSIVE SONAR SIGNALS

Ricardo Rezende Ramos

September/2011

Advisor: José Manoel de Seixas

Department: Electrical Engineering

Passive sonar signals present a nonstationary behavior in such a way that their analysis should be performed in windows. The sonar signal statistical fluctuations need to be detected in real time, so that the blind source separation techniques of interference between contacts, ICA, for instance, and the automatic classifiers, which usually rely on signal statistics, have their performance maximized. This work aims to present the development of a neural monitoring system of passive sonar signals based on an unsupervised modified ART network, which tracks the statistics of the signal in order to indicate possible changes. The ART network was used to perform the clustering analysis of the signal spectra periodically. The DEMON analysis was used to obtain the spectra of the signal. Due to the high dimensional data space, PCA was used in the preprocessing stage for dimensionality reduction. In addition, the impact of the passive sonar signal preprocessing with ICA on the efficiency of a MLP classifier was evaluated. The results pointed to the benefits of using ICA in terms of the efficiency of neural classification of contacts.

Aiming at validating the monitoring system some tests were performed by comparing the monitoring system response with the mutual information and the fourth-order cross-cumulants of the sonar signal, both being used as figures of merit. In the best results an efficiency up to 89% was accomplished, for the cross-cumulants as figure of merit, and up to 75%, for the mutual information. The results demonstrate the applicability of the proposed monitoring system to aid the sonar operator.

Sumário

Lista de Figuras	ix
Lista de Tabelas	xii
1 Introdução	1
1.1 Objetivos da Dissertação	2
1.2 Organização do Texto	3
2 Sistemas de Sonar Passivo	5
2.1 Descrição do Sistema de Sonar Passivo	7
2.2 Revisão da Literatura	9
3 Pré-processamento dos Dados	13
3.1 Análises Espectrais	14
3.1.1 Análise LOFAR	14
3.1.2 Análise DEMON	15
3.2 Redução de Dimensionalidade com PCA	17
3.3 Separação Cega de Fontes com ICA	18
3.3.1 Separação Cega de Fontes no Domínio da Frequência	20
3.4 Avaliação da Base de Dados	21
4 Sistema de Monitoração	30
4.1 Clusterização de Dados	32
4.2 Clusterização Neural do Sistema de Monitoração	35
4.3 Sistemática de Acompanhamento	37
4.4 Figuras de Mérito e Medidas de Desempenho	38
5 Testes do Sistema de Monitoração	41
5.1 Parâmetros de Sintonia do Sistema	41
5.2 Testes para o Ajuste de Parâmetros	45
5.3 Testes de Desempenho	51
5.3.1 Indicadores do Sistema de Monitoração	52

5.3.2	Intervalo entre Avaliações	53
5.3.3	Obtenção das Figuras de Mérito	53
5.3.4	Resposta do Sistema	54
5.4	Efeitos de ICA para Classificação Neural	64
5.4.1	Metodologia	64
5.4.2	Resultados	68
6	Conclusões e Perspectivas	71
	Referências Bibliográficas	74
A	Publicações	80
A.1	Capítulo de Livro	80
A.2	Artigos em Congressos	80

Lista de Figuras

2.1	Detecção de Sinal de Sonar Passivo.	6
2.2	Sistema de sonar passivo com um arranjo cilíndrico de hidrofones [11].	8
2.3	Diagrama do arranjo cilíndrico com os sensores usados na con- formação de feixes [11].	8
2.4	Evolução da energia (marcação x tempo) [4].	9
3.1	Diagrama em blocos da análise LOFAR.	14
3.2	Exemplo de janela utilizada pelo algoritmo TPSW com $p = 5$ e $n = 6$ [15].	15
3.3	Espectrograma da análise LOFAR da marcação 190° . A magnitude dos espectros está em dB.	16
3.4	Diagrama em blocos da análise DEMON.	16
3.5	Espectrograma da análise DEMON e espectro médio na marcação 190° .	17
3.6	Separação cega com ICA no domínio da frequência [4].	21
3.7	Análise DEMON: espectrogramas e espectros médios das marcações 190° , 205° e 76°	22
3.8	Análise DEMON: espectros médios das marcações 190° , 205° e 76° .	23
3.9	Análise PCA na marcação 190° : (a) curvas de carga para 20 espectros e (b) variação da curva de carga em função do número de espectros. .	26
3.10	Análise PCA na marcação 205° : (a) curvas de carga para 20 espectros e (b) variação da curva de carga em função do número de espectros. .	27
3.11	Evolução da energia extraída de cada conjunto de 20 espectros para as marcações (a) 190° e (b) 205°	28
3.12	Evolução da energia extraída de cada conjunto de 40 espectros para as marcações (a) 190° e (b) 205°	29
5.1	Histograma das distâncias entre os padrões de entrada do primeiro conjunto de 20 espectros da marcação 190°	45

5.2	<i>Clusters</i> formados com o critério de 1,5 vezes a primeira moda na marcação 190°: (a) final de uma clusterização e, (b) após a transformação para a clusterização seguinte. Os padrões de entrada são os pontos dentro dos <i>clusters</i> , dispostos de forma semielipsoidal. O ‘x’ indica o centro do <i>cluster</i>	46
5.3	<i>Clusters</i> formados com um ganho na primeira moda para obtenção de ρ , na marcação 190°.	46
5.4	Convergências da clusterização do segundo conjunto de espectros com (a) ρ igual 1,5 vezes a primeira moda e (b) ρ igual a 22 vezes a primeira moda. Ambas na marcação 190° e com $\alpha = 0,1$	47
5.5	Convergências da clusterização de seis conjuntos consecutivos de espectros com ρ igual a 22 vezes a primeira moda. Marcação 190° e com $\alpha = 0,02$, parada com 50 épocas e esquecimento de 40 épocas.	48
5.6	Histograma das distâncias entre os padrões de entrada do primeiro conjunto de 20 espectros da marcação 205°.	49
5.7	Convergências da clusterização de seis conjuntos consecutivos de espectros com ρ igual a 22 vezes a primeira moda. Marcação 205° e com $\alpha = 0,02$, parada com 50 épocas e esquecimento de 40 épocas.	50
5.8	Evolução da informação mútua entre a primeira janela e as janelas subsequentes para as misturas 5.8(a) e para as fontes extraídas por ICA 5.8(b).	55
5.9	(a) Evolução dos cumulantes cruzados entre marcações e (b) fontes extraídas por ICA.	56
5.10	Histogramas das distâncias entre os padrões de entrada do conjunto de 40 espectros.	57
5.11	Acompanhamento do número de <i>clusters</i> , do traço e do <i>crossstalk</i> das matrizes S_W e S_B . Marcação 190°.	62
5.12	Acompanhamento do número de <i>clusters</i> , do traço e do <i>crossstalk</i> das matrizes S_W e S_B . Marcação 205°.	63
5.13	Diagrama em blocos do sistema de classificação com LOFAR no pré-processamento [17].	66
5.14	Taxa de acerto média X Número de neurônios na camada escondida.	67
5.15	Diagrama em blocos do sistema de classificação com ICA + LOFAR no pré-processamento. A marcação 76° representa o ruído próprio.	67
5.16	Histogramas das saídas da rede treinada com pré-processamento LOFAR: classe 1 (esquerda) e classe 2 (direita). Taxa de acerto de 83,6%.	69
5.17	Histogramas das saídas da rede treinada com pré-processamento LOFAR + ICA (Akuzawa): classe 1 (esquerda) e classe 2 (direita). Taxa de acerto de 78,7%.	69

5.18	Histogramas das saídas da rede treinada com pré-processamento LO-FAR + ICA (JADE): classe 1 (esquerda) e classe 2 (direita). Taxa de acerto de 87,0%.	69
5.19	Histogramas das saídas da rede treinada com pré-processamento LO-FAR + ICA (FastICA): classe 1 (esquerda) e classe 2 (direita). Taxa de acerto de 88,1%.	70

Lista de Tabelas

5.1	Saídas lógicas que maximizam a probabilidade de detecção em função do ρ , na marcação 190°. Todas as variações na informação mútua são consideradas mudanças.	58
5.2	Saídas lógicas que maximizam a probabilidade de detecção em função do ρ , na marcação 190°. Apenas variações maiores que 2% na informação mútua são consideradas mudanças.	58
5.3	Saídas lógicas que maximizam a probabilidade de detecção em função do ρ , na marcação 205°. Todas as variações na informação mútua são consideradas mudanças.	58
5.4	Saídas lógicas que maximizam a probabilidade de detecção em função do ρ , na marcação 205°. Apenas variações maiores que 2% na informação mútua são consideradas mudanças.	59
5.5	Combinação das saídas lógicas das marcações, para $\rho = 1, 2.moda$, através da lógica “OU”. Todas as variações na informação mútua são consideradas mudanças.	60
5.6	Combinação das saídas lógicas das marcações, para $\rho = 1, 2.moda$, através da lógica “OU”. Apenas variações maiores que 2% na informação mútua são consideradas mudanças.	60
5.7	Combinação lógica para detecção de mudanças maiores que 2% nos cumulantes cruzados (entre marcações 190° e 205°).	64
5.8	Tabela de confusão para a rede treinada com pré-processamento LO-FAR.	68
5.9	Tabela de confusão para a rede treinada com pré-processamento LO-FAR + ICA (Akuzawa).	69
5.10	Tabela de confusão para a rede treinada com pré-processamento LO-FAR + ICA (JADE).	70
5.11	Tabela de confusão para a rede treinada com pré-processamento LO-FAR + ICA (FastICA).	70
5.12	Comparação das eficiências das configurações testadas.	70

Capítulo 1

Introdução

O ambiente do fundo do mar caracteriza-se por ser extremamente ruidoso e por produzir sinais acústicos de naturezas estatísticas distintas, tornando o ramo de acústica submarina um terreno fértil para engenheiros e pesquisadores. Os sistemas empregados na detecção e no processamento de áudio no meio submarino são conhecidos como sistemas de sonar [1]. Um destes sistemas, conhecido como sistema de sonar passivo, utiliza transdutores de som para sinal elétrico, conhecidos como hidrofones, responsáveis por captar o ruído do ambiente submarino. Outro sistema, o sonar ativo, também faz uso de hidrofones, porém se diferencia do sonar passivo pelo fato de emitir um sinal de áudio, e aguardar pelo retorno das reflexões do sinal emitido. O sonar passivo permanece em silêncio, apenas captando os ruídos do ambiente. Tais sinais de ruído são processados por uma cadeia de processamento com a finalidade de condicionar os sinais para as etapas de detecção e de classificação de contatos. A tarefa de classificação pode ser realizada por um operador de sonar (OS) e por classificadores automáticos.

Há décadas, o sistema de sonar passivo desperta profundo interesse no meio militar [1–4], sendo extensa sua aplicação na tarefa de identificação de embarcações inimigas, também conhecidas como contatos, em operações submarinas. Esta tarefa requer o uso de sistemas de hardware e software sofisticados, dado que o sinal de interesse, o ruído irradiado pelos contatos, é fortemente corrompido por outras fontes de ruído. Outro problema recorrente que prejudica a detecção do sinal é a interferência entre contatos. Os hidrofones são posicionados de maneira a formar arranjos (cilíndricos, por exemplo), sendo capazes de escutar a presença de contatos em todas as direções. Nestes arranjos, são usados filtros espaciais, chamados de formadores de feixe, para separar o ruído recebido e as diferentes direções (as marcações). Não raramente, o sinal de um contato interfere significativamente no sinal de outros contatos, principalmente, quando há a presença de dois ou mais contatos irradiando ruído em marcações próximas, dificultando a identificação e a classificação do contato tanto pelo OS como por sistemas automáticos.

Estudos recentes têm sido realizados com o objetivo de melhorar a performance dos sistemas de detecção de sinais de sonar passivo, com destaque para dois quesitos: o aumento da relação sinal-ruído e a atenuação da interferência entre contatos. Ambos produzem efeitos diretos e benéficos para os sistemas de classificação. Técnicas avançadas de pré-processamento vêm sendo avaliadas exaustivamente com esta finalidade. Entretanto, a performance destas técnicas é bastante sensível a alterações nas densidades de probabilidade dos sinais utilizados na estimação dos modelos de pré-processamento e classificação, em outras palavras, essas técnicas requerem processos estatisticamente estacionários. Caso ocorram alterações na estatística do sinal, indicando uma provável não estacionariedade, tais modelos estimados deixam de ser ótimos, demandando uma nova estimação, com base na nova densidade de probabilidade do sinal.

Sendo assim, uma ferramenta capaz de monitorar a estatística do sinal de sonar passivo é de grande valia para o OS, que passaria a ter um indicador de quando os modelos iriam requerer uma nova atualização. A disponibilização de tal sistema de apoio possui grande relevância, já que resulta em maiores rapidez e confiabilidade no processo de tomada de decisão, em um ambiente onde um simples equívoco pode ter um altíssimo custo material e humano.

1.1 Objetivos da Dissertação

O objetivo fundamental deste trabalho é apresentar o desenvolvimento de um sistema de monitoração capaz de acompanhar a estatística do sinal de sonar passivo, provendo subsídios para os sistemas de pré-processamento e classificação. As técnicas de processamento de sinais utilizadas no ambiente de sonar passivo cada vez mais necessitam acessar estatísticas de ordem superior para estimação e parametrização de seus modelos. Este fato traz a necessidade de verificação da estacionariedade do sinal do sonar, pelo menos até a ordem de interesse. Diante desta realidade, uma técnica de acompanhamento foi concebida, consistindo em se observar o comportamento do sinal das marcações do sistema de sonar passivo periodicamente. A cada parada para avaliação é feita a clusterização de um conjunto de espectros de potência de um trecho especificado do sinal. É proposta a utilização de uma rede neural baseada na rede ART modificada (*Adaptive Resonance Theory*) [5], para a clusterização do sinal, devido à simplicidade de implementação, plasticidade e velocidade de processamento, o que foi observado em trabalhos anteriores [6]. Um conjunto de parâmetros é disponibilizado pelo sistema de monitoração a cada parada para observação, com base no resultado da clusterização, sendo considerados, o número de *clusters* formados, o posicionamento relativo destes *clusters* e as dispersões intra e extra-*cluster*. A evolução de tais parâmetros ao longo do sinal é

avaliada usando um processo de tomada de decisão, para indicar se houve ou não alteração na estatística do sinal.

A base de dados avaliada no trabalho consiste em sinais de áudio de navios reais captados por um sistema de sonar passivo instalado em um submarino da Marinha do Brasil, operando em condições reais em águas profundas. Estes sinais passam por uma cadeia de pré-processamento, similar à proposta em [3], que provê os dados de entrada do sistema de monitoração. Os dados de saída da cadeia de pré-processamento possuem dimensão elevada, de forma que a utilização da técnica de Análise de Componentes Principais (PCA) [7] é proposta para redução de dimensionalidade. Trabalhos anteriores obtiveram bons resultados com o uso de PCA em sinais de sonar passivo [8, 9].

Adicionalmente, considerando-se que o trabalho envolve a separação de fontes com Análise de Componentes Independentes (ICA, em inglês), foi avaliado o impacto da classificação de contatos no espaço dos componentes independentes. Um classificador neural *multilayer perceptron* (MLP) foi treinado com os espectros de potência disponibilizados pela análise espectral LOFAR, pré-processados com ICA. Os resultados mostraram os benefícios em termos da eficiência da classificação de contatos pela utilização de ICA no pré-processamento do sinal do sonar passivo.

1.2 Organização do Texto

O texto foi estruturado em 6 capítulos, incluindo o presente, que faz uma introdução do trabalho, descrevendo a motivação e o objetivo da dissertação.

O Capítulo 2 apresenta o tema Sistemas de Sonar Passivo, fazendo uma descrição resumida do ambiente submarino. É feita uma explanação sobre a tecnologia de sistemas de sonar passivo, na forma que são empregados neste trabalho. Apresenta-se tanto a forma que é feita a captação dos ruídos do fundo do mar, como a maneira que os sinais são visualizados pelo Operador de Sonar. Uma revisão da literatura sobre os trabalhos que vem sendo realizados nas áreas de pesquisa do escopo desta dissertação é apresentada ao final do capítulo.

O Capítulo 3 descreve com mais detalhes a forma como é feito o pré-processamento do sinal de sonar passivo, mostrando como são implementadas algumas das técnicas empregadas. São apresentadas as análises espectrais DEMON (*Detection of Envelope MOdulation on Noise*) e LOFAR (*LOw Frequency Analysis and Recording*) [1]. Na sequência, discorre-se sobre os aspectos teóricos de compactação de dados e separação cega de fontes, sobretudo, PCA e Análise de Componentes Independentes (ICA, em inglês) [10], respectivamente. Tais análises desempenham papel fundamental na cadeia de pré-processamento do sinal de sonar, tanto para o trabalho de visualização do Operador de Sonar, como para os sistemas automáticos

de detecção e classificação de contatos. No final do capítulo, é feita uma avaliação da base de dados utilizada neste trabalho.

O Capítulo 4 apresenta em detalhes a metodologia utilizada para o desenvolvimento do sistema de monitoração proposto. São mostrados os princípios de funcionamento do sistema de monitoração e a forma que este pode interagir com os sistemas de redução de interferências e de classificação, provendo subsídios para a tomada de decisão de atualizar ou não os modelos.

O capítulo seguinte dedica-se a descrever os testes do sistema de monitoração com a base de dados experimental, mostrando os resultados obtidos. É apresentada como é feita a sintonia dos parâmetros do sistema. São apresentados os resultados da validação do sistema de monitoração, utilizando como figura de mérito a medida de informação mútua. Ao final, são mostrados os resultados do projeto de um classificador neural que utiliza ICA no pré-processamento, para demonstrar o impacto do uso de ICA na classificação neural de contatos.

Finalmente, o Capítulo 6 apresenta as conclusões do trabalho e suas contribuições para a área de Detecção de Sinais de Sonar Passivo. São apontadas as perspectivas futuras, acompanhadas de sugestões de novos trabalhos.

Capítulo 2

Sistemas de Sonar Passivo

O funcionamento de um sistema de sonar passivo¹ [1] se baseia na captação do ruído irradiado por um alvo para, com este sinal acústico, realizar a detecção, a localização e a classificação do alvo. Para um submarino, fica claro concluir o porquê da opção pelo sistema de sonar passivo, uma vez que a emissão de um sinal, usando um submarino, na tentativa de identificar um alvo inimigo, na verdade, revelaria a posição do submarino. A Figura 2.1 ilustra de forma básica o cenário da detecção de sinal de um sonar passivo. O OS é o responsável pela detecção e pela classificação dos contatos que se aproximam do submarino, utilizando para esta tarefa os recursos auditivos e visuais do sistema de sonar passivo[11]. A detecção da presença e da posição de um contato pode ser feita, por exemplo, pela observação da energia que chega em cada direção (marcação) do sonar, e a classificação deste contato, através da audição do sinal da marcação e das análises espectrais deste sinal, como, por exemplo, as análises DEMON (*Detection Envelope MOdulation on Noise*) e LOFAR (*LOW Frequency Analysis and Recording*) [1]. Como se trata de um ser humano, o OS é passível de sofrer com a fadiga com o passar do tempo, de forma que sistemas classificadores automáticos ganham importância no auxílio à tomada de decisão em relação à detecção e à classificação dos contatos.

O sonar passivo permanece em silêncio escutando não apenas o ruído emitido pelos contatos, como também o ruído de fundo, ou seja, os ruídos emitidos por qualquer outra fonte presente no ambiente submarino, com potência suficiente para ser captada pelos sensores do sonar. Pode-se citar o ruído ambiente, o ruído de outras embarcações e o ruído irradiado pela própria embarcação onde o sonar está instalado, como fontes conhecidas que compõem o ruído de fundo que é captado pelos sensores do sonar passivo [6]. Além disso, o ruído irradiado pelo alvo sofre tanto perdas naturais pela propagação no meio, como flutuações de energia pela chegada no sensor de sinais atrasados em fase, devido à reflexão na superfície e no fundo do

¹SONAR = *SOund NAVigation and Ranging*

mar [6]. Nesta mesma referência, verifica-se que este efeito causado pela reflexão, ou reflexões, do ruído irradiado pelo alvo é ainda mais crítico quando a navegação ocorre em águas rasas, uma vez que o sensor fica mais próximo da superfície e do fundo do mar.

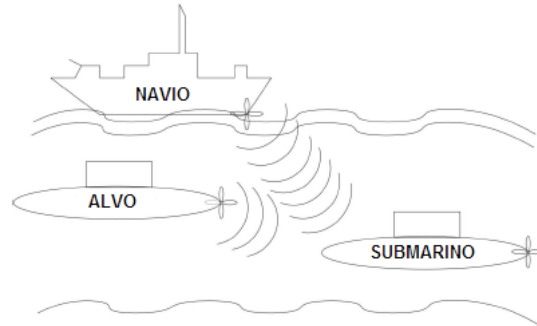


Figura 2.1: Detecção de Sinal de Sonar Passivo.

SOARES FILHO [6] fez uma descrição detalhada das fontes de ruído irradiado por embarcações, quais sejam, navios, submarinos e torpedos, podendo ser classificadas em três tipos: ruído de máquinas, ruído de hélice e ruído hidrodinâmico. No mesmo trabalho, são apresentados os tipos mais comuns de máquinas presentes em uma embarcação com propulsão Diesel-elétrica.

O ruído de máquinas tem origem na vibração mecânica das máquinas operando dentro de uma embarcação em movimento, sendo transmitido ao casco e acoplado à água. Já o ruído de hélice, mesmo este sendo parte das máquinas em operação, surge com um diferencial em relação ao ruído de máquinas. No caso, ele é gerado fora do casco da embarcação, pela rotação do hélice e pelo movimento da embarcação, estando em contato direto com a água. O ruído hidrodinâmico tem origem no contato da embarcação em movimento com fluxos irregulares de líquido. Os ruídos de máquinas e de hélice são os mais representativos no espectro do ruído irradiado pelas embarcações, na grande maioria dos casos [6].

Não bastasse o ambiente rico em fontes ruidosas de diferentes tipos, o ruído irradiado pelas embarcações sofre muitas modificações, que são variantes no tempo, durante sua propagação no meio oceânico, vindo a ser considerado não estacionário, quando captado pelos hidrofones do sistema de sonar passivo [6, 12].

Muitos dos algoritmos de processamento de sinais acústicos submarinos partem da premissa de que o ruído presente é estacionário, independente e Gaussiano, mesmo aqueles que fazem uso de estatísticas de ordem superior (cumulantes de terceira e de quarta ordem) [12]. Caso a estacionariedade não esteja garantida, e sejam verificadas flutuações momentâneas ou permanentes na estatística do sinal, a performance esperada destes algoritmos poderá ser afetada. Neste contexto, uma

ferramenta que seja capaz de apontar alterações significativas na estatística do sinal de sonar ganha importância. Esta se constitui em uma das principais motivações para o desenvolvimento desta dissertação.

2.1 Descrição do Sistema de Sonar Passivo

O sistema de sonar passivo utilizado para adquirir os sinais que formam a base de dados utilizada neste trabalho pertence à Marinha do Brasil, tendo sido descrito em detalhes em [11]. Os dados foram coletados por um submarino operando em águas profundas e com navios reais. Há mais de uma década, este ambiente vem fomentando diversos trabalhos de pesquisa [3, 6, 9, 11, 13–18].

A Figura 2.2, extraída de [11], ilustra o cenário de aplicação do sistema de sonar passivo em questão. O sistema, instalado em um submarino, é composto por um arranjo cilíndrico de hidrofones (CHA, em inglês), que forma feixes através da técnica atraso e soma. Este conformador de feixes (*beamformer*) trata-se de um filtro espacial que combina os sinais de diferentes hidrofones com o objetivo de enfatizar os sinais provenientes de uma marcação (direção) específica, em detrimento dos sinais de outras marcações. Neste arranjo cilíndrico, um feixe direcional é formado pelos sinais de 32 sensores adjacentes, conforme a Figura 2.3, extraída de [11]. Esta conformação de feixes tem a finalidade de estimar os sinais provenientes de cada marcação, possibilitando o cálculo da energia na direção e banda de frequência de interesse [3]. O sistema mantém uma vigilância omnidirecional com 96 bins de resolução, cada um formando um feixe, o que significa, em uma faixa que vai de 0° a 360° , uma resolução angular de $3,75^\circ$.

A Figura 2.4, extraída de [4], mostra o gráfico da evolução temporal da energia em função da marcação (marcação x tempo) gerado na análise *beamforming*. O eixo horizontal representa a marcação, 0 a 360° , e o eixo vertical representa o tempo, onde o intervalo entre duas marcas maiores corresponde a um minuto. Através da audição do sinal de áudio e do acompanhamento da energia presente em cada marcação em função do tempo é que o OS realiza a tarefa de detecção do contato. Geralmente, devido à proximidade entre os feixes, pode ocorrer interferência entre eles, o que prejudica o trabalho de detecção e classificação do contato pelo OS [13].

Neste contexto, a cadeia de pré-processamento do sistema do sonar passivo desempenha o importante papel, objetivando não apenas atenuar o ruído de fundo presente no sinal recebido, como também realizar a separação do sinal de interesse das possíveis interferências presentes, tais como outras fontes de ruído do ambiente submarino, o ruído próprio do submarino e os sinais de outras marcações. No Capítulo 3, são apresentadas algumas das técnicas utilizadas no pré-processamento do sinal de sonar passivo com o objetivo de otimizar o trabalho de detecção e clas-




Figura 2.2: Sistema de sonar passivo com um arranjo cilíndrico de hidrofones [11].

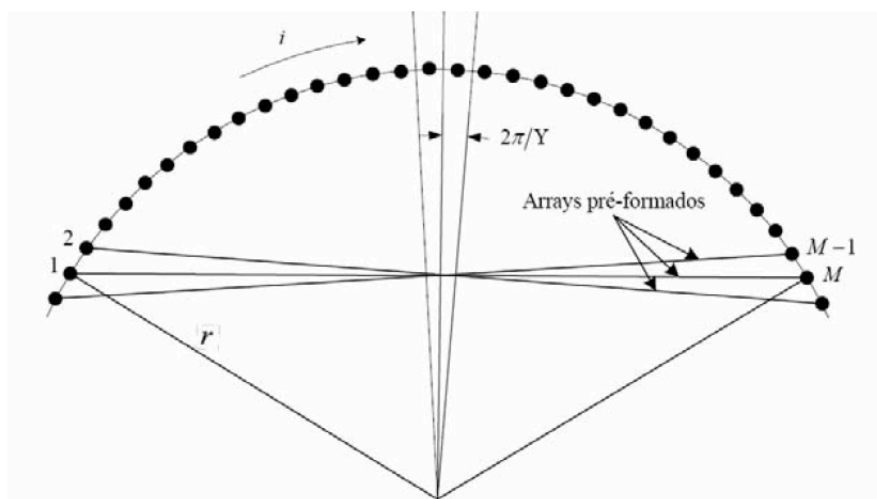


Figura 2.3: Diagrama do arranjo cilíndrico com os sensores usados na conformação de feixes [11].

sificação de contatos.

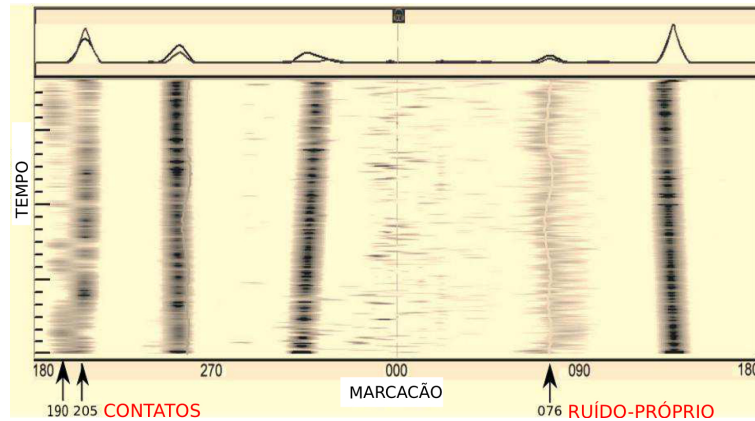


Figura 2.4: Evolução da energia (marcação x tempo) [4].

2.2 Revisão da Literatura

Boa parte dos trabalhos de pesquisa na área de sonar passivo possuem publicação restrita, devido ao sigilo decorrente do constante interesse militar por esta área de aplicação. O sistema de monitoração aqui proposto, da forma como foi concebido, possui um caráter de inovação, havendo assim uma escassez de trabalhos publicados com abordagem similar à que está sendo proposta. Alguns trabalhos encontrados aplicam as técnicas utilizadas nesta dissertação, porém, em alguns dos casos, em outros ambientes e com outros objetivos.

Ao longo das últimas três décadas, foi produzida uma farta literatura relacionada aos temas detecção e classificação de sinais de sonar passivo [3, 8, 14, 18–26], aplicados em distintos ambientes, todos fazendo uso de algum tipo de arquitetura neural para a tarefa.

KNIGHT *et al.* [2] apresentaram um abrangente tutorial sobre o tema de processamento digital de sinais de sonar. Foram abordados diversos aspectos sobre acústica submarina e sobre os impactos tecnológicos da adoção de sistemas eletrônicos digitais no desenvolvimento dos sistemas de sonar. O tutorial abrange tanto o sistema de sonar passivo como também o ativo. Deste trabalho, produzido pelos autores ainda no início dos anos 80, cabe destacar um detalhe que tem relação direta com o objetivo principal desta dissertação. São apontadas algumas premissas para o desenvolvimento das estruturas de hardware e software para processamento de sinais de sonar passivo, quais sejam:

1. estacionariedade e/ou ergodicidade do sinal;
2. ruído espacial e temporalmente independente;

3. modelos matematicamente convenientes para sinal, ruído e interferências estatísticas;
4. modelos matematicamente convenientes para distorções de canal e estruturas de recepção resultantes;
5. ausência de erros de implementação da eletrônica tais como tolerâncias em magnitude e fase, *jitter* de frequência e ruído do processamento digital.

De maneira geral, as premissas (4) e (5), nos dias atuais, já não apresentam os mesmos desafios que há 30 anos atrás, devido à consolidação de técnicas de modelagem, processamento digital e de implementação de hardware digital. Entretanto, as premissas (1), (2) e (3) permanecem a fomentar trabalhos de pesquisa e desenvolvimento de técnicas avançadas que levem em consideração as condições reais do ambiente submarino, ou seja, não estacionariedade, ruídos com correlação espacial e temporal, baixíssima relação sinal-ruído e a interferência entre marcações.

PERSSON e LEVONEN [27] propuseram um procedimento para condicionamento do sinal de sonar passivo, fazendo uso de um teste estatístico baseado no teste Kolmogorov-Smirnov (K-S) [28] e de um algoritmo de rejeição gradual de *outlier*. O teste estatístico é usado para a caracterização de não estacionariedades no sinal de sonar passivo, que uma vez detectadas, são tratadas como *outliers* pelo algoritmo de rejeição, que atua para suprimir tais não estacionariedades. As linhas espectrais do sinal de sonar passivo são aplicadas ao procedimento proposto e, caso a supressão dos *outliers* seja possível, é esperada uma melhora na identificação de contatos dos sistemas convencionais de sonar passivo. Os autores demonstram que a atuação combinada do teste K-S com o algoritmo de rejeição de *outliers* consegue encontrar e reduzir significativamente os componentes não estacionários do sinal de sonar passivo. A desvantagem deste procedimento fica por conta da necessidade de um conjunto de dados relativamente grande para conseguir boas estimativas.

PFLUG *et al.* [12] apresentaram um estudo sobre sinais captados por um arranjo vertical de hidrofones de embarcações navegando em águas rasas. Os hidrofones foram posicionados a 200 m da costa, próximo ao porto de San Diego, Califórnia, onde foi feito o trabalho de campo. Os sinais analisados foram os ruídos adquiridos, a uma taxa de 1500 amostras por segundo, por dois hidrofones posicionados a 116 m e 192 m de profundidade, onde buscou-se avaliar a estacionariedade e a gaussianidade [10] dos ruídos. Outros dois sinais, de hidrofones posicionados a 140 m e 170 m, foram adquiridos para análises de correlação do ruído entre marcações, também conhecida como correlação espacial. Foram geradas gravações de 30 min de duração. A posição dos navios durante o experimento foi acompanhada com o uso de radar, com atualização a cada 2 min.

Tanto o estudo da estacionariedade e da gaussianidade como o estudo da correlação espacial que foram conduzidos são de extrema relevância, uma vez que afetam diretamente os algoritmos de processamento de sinais acústicos submarinos, que partem da premissa de que o ruído é estacionário, Gaussiano e independente, para estimar seus modelos. A estacionariedade dos sinais é avaliada a partir do cálculo dos cumulantes de segunda, terceira e quarta ordens. Para computar os cumulantes ao longo de todo trecho dos sinais, foi utilizada uma janela deslizante de 1 segundo, com 15 pontos de *overlap*. Os sinais foram divididos em segmentos de 1 min para o processamento dos cumulantes. Os resultados revelaram períodos locais de não estacionariedade do ruído ambiente, de forma mais evidente nos cumulantes de segunda e quarta ordem, variância e *kurtosis* [10], respectivamente, nos instantes que apresentaram variação no tempo. Para validar a evidência de não estacionariedade, foi aplicado o teste estatístico K-S de duas amostras para identificar mudanças significativas nas distribuições de probabilidade acumuladas dos sinais avaliados. Os resultados validaram os indicativos das variações nos cumulantes de segunda e quarta ordem como sendo representativos da presença de instantes de não estacionariedade do ruído ambiente, em intervalos com duração de 2 a 6 min, ao longo da gravação de 30 min.

Para identificar e quantificar os intervalos de não-gaussianidade dos sinais, foi utilizado o teste K-S de 1 amostra. Os resultados indicaram a existência de períodos de não-gaussianidade no ruído que encontraram correspondência com os resultados dos cálculos dos cumulantes². A correlação entre marcações foi estimada através do cálculo do coeficiente de correlação de Pearson [29] entre os ruídos de cada marcação, e os resultados indicaram que estes são correlacionados e que a correlação vai de positiva para negativa conforme a distância entre os hidrofones aumenta.

VASSALI *et al.* [5] apresentaram um discriminador neural para classificação *on-line* de partículas em um experimento de alta taxa de eventos. O discriminador realiza uma clusterização dos dados de entrada a partir de uma arquitetura de rede neural baseada na camada de Kohonen com treinamento competitivo [7], chamada de rede ART modificada. O conjunto de dados que alimenta o discriminador é projetado em seus componentes principais para redução de dimensionalidade do espaço de entrada [7]. O discriminador obtém uma eficiência de classificação superior a 99,4%, para um falso alarme inferior a 2%. Os autores apresentam comparações da rede ART modificada com a rede perceptron multicamadas (MLP, em inglês) [7], mostrando que a primeira é mais rápida em tempo de execução. Os tempos de execução foram computados a partir de implementações dos discriminadores baseados em redes ART modificada e MLP em um processador digital de sinal (DSP, em

²Os cumulantes de ordens superiores, terceira ordem em diante, de processos aleatórios Gaussianos são nulos [10].

inglês) [30].

SOARES FILHO *et al.* [14] avaliaram o uso da análise de componentes principais (PCA) em sinais de sonar passivo no domínio da frequência, com o objetivo de classificar o ruído irradiado por navios. O estudo foi conduzido a partir de três abordagens distintas para extração e seleção dos componentes principais, quais sejam, a PCA linear, a PCA não-linear (NLPCA, em inglês) [31] e a análise de discriminação neural (NDA, em inglês) [32]. Todas as três técnicas foram implementadas utilizando métodos neurais no processo de extração das direções principais (PCA e NLPCA) e de discriminação (NDA).

SOARES FILHO *et al.* [14] concluíram que, em comparação com a NLPCA e a PCA, a NDA apresentou menor capacidade de retenção da informação do conjunto de dados analisado, o que ficou evidente pela curva de energia acumulada em função do número de componentes. Entretanto, o objetivo do trabalho foi encontrar a técnica com maior capacidade de discriminação. Em relação a este quesito, a NDA obteve o melhor desempenho, chegando a 93% de eficiência com apenas 3 componentes. Já a PCA e a NLPCA precisam de cerca de 33 componentes para atingir o mesmo nível de eficiência.

Capítulo 3

Pré-processamento dos Dados

Como foi mostrado no Capítulo 2, o ruído irradiado por um contato nas proximidades do submarino, captado pelos hidrofones do sistema de sonar passivo, chega até o conformador de feixes imerso no ruído de fundo, com a presença do ruído próprio do submarino e, em alguns casos, com interferências de outras marcações. Para detecção do contato, o OS pode acompanhar visualmente no gráfico marcação x tempo a variação da energia em uma dada marcação, como foi mostrado na Seção 2.1. Já para a classificação, ele conta com o áudio da marcação e com as análises espectrais realizadas no sinal, no caso, as análises DEMON e LOFAR [1]. Essas análises espectrais não apenas disponibilizam os recursos visuais para o trabalho de classificação do OS, como também fornecem os padrões de entrada para treinamento e operação dos classificadores automáticos que vêm sendo adotados como ferramenta de apoio à tomada de decisão.

Sistemas baseados em classificadores neurais vêm sendo testados com frequência, inclusive pela Marinha do Brasil, em uma série de trabalhos na área de processamento de sinais de sonar passivo [6, 8, 15, 18–20, 23–26]. A eficiência de classificadores projetados a partir de redes neurais depende fortemente do pré-processamento dos padrões de entrada utilizados em seu treinamento e em seu modo de operação. Esse tratamento dos dados inclui a filtragem do sinal, a demodulação, o janelamento do sinal para obtenção dos espectros, a estimação do ruído de fundo e a redução de dimensionalidade. Recentemente, técnicas de separação cega de fontes vêm sendo avaliadas para reduzir o efeito da interferência de contatos [3, 11, 13], sobretudo a ICA, constituindo-se em mais uma etapa da cadeia de pré-processamento.

Neste capítulo, na Seção 3.1, são descritos a forma como estão implementadas e o funcionamento das análises espectrais LOFAR e DEMON. Nas Seções 3.2 e 3.3, a técnica PCA, para redução de dimensionalidade, e ICA, para separação cega de fontes, respectivamente, são apresentadas. Ao final, é feita uma descrição da base de dados utilizada neste trabalho, através da aplicação nesta base de dados das técnicas descritas neste capítulo.

3.1 Análises Espectrais

Nesta seção, são apresentadas as análises espectrais LOFAR e DEMON e seu papel na cadeia de pré-processamento do sinal do sonar passivo.

3.1.1 Análise LOFAR

O objetivo da análise LOFAR é realizar uma análise espectral de banda estreita para obter os tons presentes no sinal de áudio de uma dada marcação, fornecendo os espectros que serão visualizados pelo OS para fazer a classificação dos contatos [11]. Essa análise na frequência é que, atualmente, tem sido utilizada no projeto de classificadores automáticos [15]. Esses tons presentes no espectro do ruído irradiado normalmente representam a vibração das máquinas da embarcação em funcionamento [6], conferindo uma espécie de assinatura acústica para cada classe de embarcação.

O diagrama em blocos da Figura 3.1 mostra uma maneira de como a análise LOFAR pode ser implementada, visando estimar o conteúdo espectral na faixa de frequência de interesse e realçar os tons espectrais que são relevantes no sinal da marcação [11, 15]. Inicialmente, o sinal na direção de interesse é separado em blocos de 1024 pontos e processado através da aplicação de uma janela de Hanning [30]. Após esta multiplicação, o sinal é transformado para o domínio da frequência usando-se a transformada rápida de Fourier (FFT) [30]. Esse procedimento de obtenção dos espectros a partir de transformada rápida de Fourier em janelas também é conhecido na literatura como STFT (*Short-Time Fourier Transform*) [33]. O módulo do espectro obtido é normalizado através da aplicação do algoritmo TPSW (*Two-Pass Split Window*) [1]. Esta normalização é implementada estimando-se o ruído de fundo presente em cada espectro e realizando-se a divisão do espectro ponto a ponto por esta estimativa. Uma janela de largura $2n + p$ pontos, conforme a Figura 3.2, extraída de [15], é utilizada para esta estimativa. A estimativa representa o valor médio calculado a partir do resultado da convolução da janela com os pontos do espectro. Esta normalização, além de remover a tendência de variação lenta no espectro, faz uma equalização dos tons que estão presentes no sinal, de forma que as amplitudes em todo o espectro fiquem próximas umas das outras [11]. Em [6, 15], é mostrado em detalhes como funciona e se especifica o algoritmo TPSW.




Figura 3.1: Diagrama em blocos da análise LOFAR.

pontos

Figura 3.2: Exemplo de janela utilizada pelo algoritmo TPSW com $p = 5$ e $n = 6$ [15].

O resultado da análise LOFAR é a disponibilização de espectrogramas para visualização do OS, como o que é mostrado na Figura 3.3. O eixo horizontal representa a frequência e o eixo vertical, o tempo. Através do espectrograma, o operador de sonar pode acompanhar como varia no tempo a densidade espectral do sinal. As linhas verticais mais escuras denotam valores mais altos de energia do espectro, correspondendo aos tons das máquinas da embarcação [11]. Esses espectros são utilizados para o treinamento e a operação dos classificadores automáticos baseados em redes neurais.

O espectrograma da Figura 3.3 abrange a faixa de frequência de 0 a 15kHz. Em [6], uma análise detalhada mostrou que para a classificação de navios, uma faixa de frequência de 0 a 3kHz foi suficiente para obter próximo de 90% de eficiência de um classificador neural MLP.

3.1.2 Análise DEMON

A análise DEMON realiza uma análise espectral de banda estreita, que busca fornecer informação sobre o ruído de cavitação do contato, que está relacionado ao hélice (frequência de rotação) e seus componentes (número de pás) [1]. Sua aplicação está atrelada à classificação do contato. O diagrama em blocos da Figura 3.4 mostra como funciona a análise DEMON [3]. O sinal adquirido é filtrado por um filtro passa-banda, ajustado na banda onde o sinal de interesse (cavitação) é mais frequente. Na sequência, o sinal é elevado ao quadrado, como em uma demodulação tradicional. O sinal é então decimado para chegar a uma frequência de amostragem

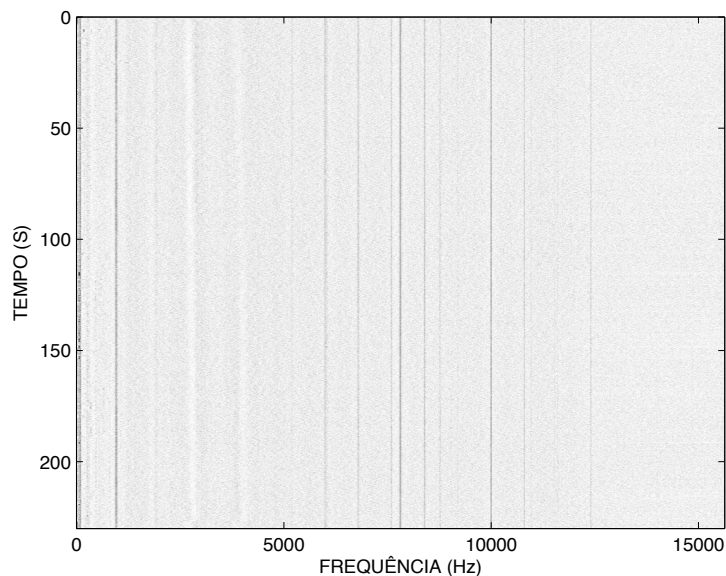


Figura 3.3: Espectrograma da análise LOFAR da marcação 190°. A magnitude dos espectros está em dB.

mais baixa, até atingir a banda que contém a faixa de rotações de interesse, por exemplo, de 0 a 1500 rpm (0 a 25 Hz). A FFT com base em janelas de Hanning [30] é aplicada em todo trecho de sinal, obtendo-se uma sequência de janelas de espectros do sinal. Finalizando, o algoritmo TPSW, como na análise LOFAR, é usado na normalização de cada espectro, reduzindo o ruído de fundo e enfatizando os picos de sinal do contato.

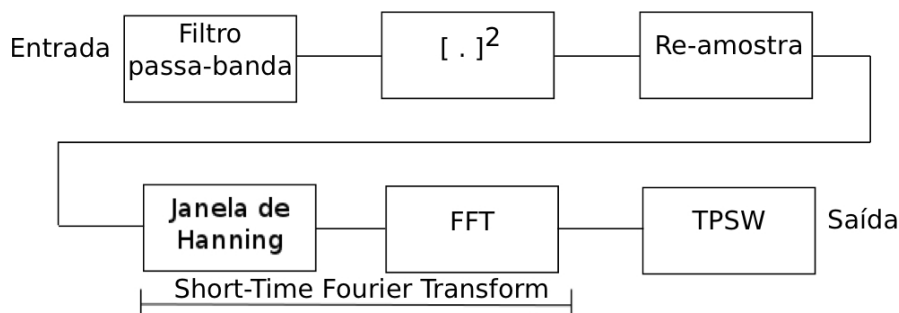


Figura 3.4: Diagrama em blocos da análise DEMON.

A Figura 3.5 mostra o resultado da análise DEMON aplicada ao sinal da marcação 190°. Observa-se a correspondência entre as linhas verticais mais evidentes no espectrograma e os picos do espectro médio. A identificação da ocorrência de interferência mútua entre marcações pode ser feita através da análise DEMON, o que será mostrado com mais detalhes na Seção 3.4.

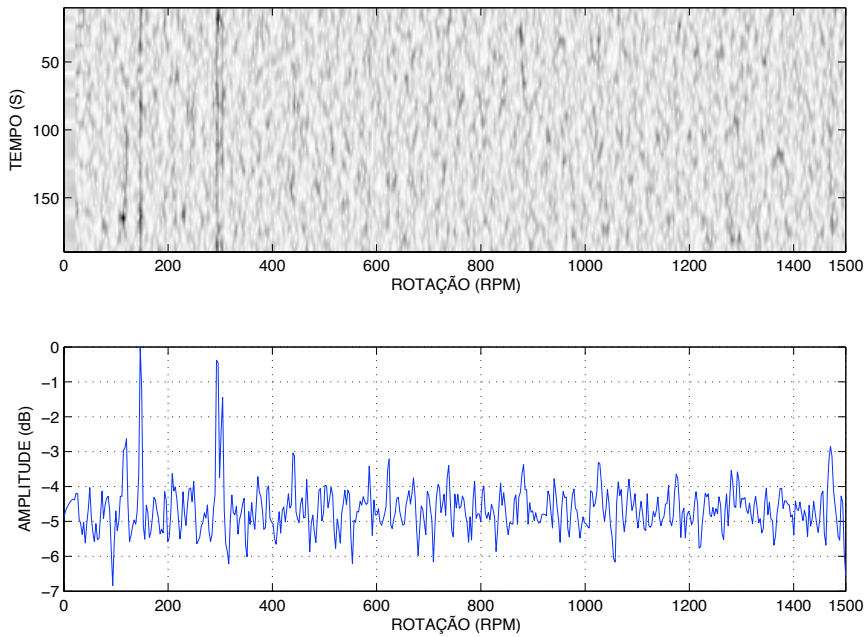


Figura 3.5: Espectrograma da análise DEMON e espectro médio na marcação 190°.

3.2 Redução de Dimensionalidade com PCA

A Análise de Componentes Principais (PCA) é uma técnica clássica usada em análise estatística multivariável para extração de características e compactação de dados [7]. A PCA tem origem na formulação matemática de uma representação de processos estocásticos como uma combinação linear de funções ortonormais, conhecida como expansão Karhunen-Loève [34]. Esta expansão, derivada originalmente para o caso analógico [34], encontra uma base de funções ortonormais que é ótima no sentido de minimizar o erro médio quadrático total na representação do processo estocástico original. Para fins de compactação, o propósito básico da PCA é remover a redundância contida nos dados originais, através de uma redução de dimensionalidade, onde esta redundância é medida explorando-se as correlações entre os dados analisados. Neste caso, a PCA funciona como uma técnica de compactação com perdas, tendo como meta a retenção do máximo de informação relevante sobre os dados originais nos componentes mais representativos. O detalhamento teórico da técnica, bem como sua aplicação em casos práticos, pode ser encontrado extensamente na literatura [7, 10, 14, 35], de forma que será feita apenas uma breve e simplificada descrição da técnica.

A abordagem básica em PCA é conceitualmente simples. Inicialmente, sejam os dados originais representados pelo processo estocástico de média zero \mathbf{X} de dimensões $n \times d$, sendo n o número de eventos e d a dimensão do espaço dos dados

originais. A matriz de covariância $\Sigma_{\mathbf{x}}$ de \mathbf{X} é calculada para todo o conjunto de dados disponível [36]. Em seguida, calculam-se os d autovalores λ_k e os d autovetores \mathbf{e}_k de $\Sigma_{\mathbf{x}}$, ordenando-os em ordem decrescente dos seus respectivos autovalores. Em outras palavras, a ordenação dos autovetores é tal que os respectivos autovalores $\lambda_1, \dots, \lambda_n$ satisfazem $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$. Na sequência, selecionam-se os l autovetores correspondentes aos l maiores autovalores, e constrói-se uma matriz \mathbf{A} de dimensões $d \times l$, com os autovetores selecionados distribuídos nas colunas, formando uma base ortogonal. Cada autovalor informa a quantidade de energia que cada autovetor principal correspondente representa do espaço dos dados originais. Os demais $d - l$ autovalores e autovetores são descartados, já que representam informação sem relevância do espaço dos dados originais. Como foi mostrado em [14], uma boa capacidade de reconstrução dos dados nem sempre significa boa capacidade de discriminação, requerendo cuidados nos critérios de corte. Finalmente, os dados originais são projetados nas direções dos autovetores em \mathbf{A} , através da seguinte transformação linear:

$$\mathbf{X}' = \mathbf{X}\mathbf{A}. \quad (3.1)$$

Os eventos transformados contidos em \mathbf{X}' representam as projeções dos dados originais nas direções principais.

3.3 Separação Cega de Fontes com ICA

A Análise de Componentes Independentes (ICA, em inglês) consiste em uma técnica de separação cega de fontes em uma mistura, que explora a não-gaussianidade dos sinais para estimação da matriz de separação [10]. Para isto, busca-se encontrar um modelo linear de representação onde os componentes sejam estatisticamente independentes. O modelo mais simples pode ser representado na forma compacta:

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

onde $\mathbf{s}(t) = [s_1(t), \dots, s_n(t)]^T$ representa os sinais das n fontes. Os n sinais observados são adquiridos para formar $\mathbf{x}(t) = [x_1(t), \dots, x_n(t)]^T$, que são os sinais que se encontram disponíveis. \mathbf{A} representa a matriz de mistura $n \times n$. A recuperação das fontes $\mathbf{s}(t)$ deve ser feita utilizando-se somente as observações $\mathbf{x}(t)$, considerando a independência estatística entre as fontes. Isto só pode ser conseguido através do cálculo iterativo da matriz de separação \mathbf{B} ($n \times n$), uma vez que somente as observações $\mathbf{x}(t)$ estão disponíveis. Caso a matriz \mathbf{A} fosse conhecida, o problema se resolveria facilmente através de sua inversão. Sendo assim, as estimativas $\mathbf{y}(t)$ das

fontes $\mathbf{s}(t)$, são obtidas a partir de:

$$\mathbf{y}(t) = \mathbf{B}\mathbf{x}(t).$$

Para estimação da matriz \mathbf{B} , algumas abordagens têm sido pesquisadas, como os algoritmos FastICA [37], JADE [38] e Akuzawa [39]. Tais abordagens vêm sendo aplicadas ao problema do sonar passivo [3]. Uma descrição resumida destes algoritmos será feita a seguir.

FastICA

O algoritmo FastICA estima o vetor $\mathbf{w}(k)$, sendo este uma das colunas da matriz ortogonal de separação \mathbf{B} . O algoritmo aplica PCA e requer dados branqueados antes do processo de estimação [10]. A derivação do algoritmo resulta na seguinte regra de atualização para \mathbf{w} :

$$\mathbf{w}(k) = E\{\mathbf{x}(\mathbf{w}(k-1)^T \mathbf{x})^3\} - 3\mathbf{w}(k-1) \quad (3.2)$$

O FastICA converge em poucas iterações devido à sua convergência cúbica [37]. Pela regra 3.2, os vetores $\mathbf{w}(k)$ são estimados um por vez. A extensão da regra para obtenção de todos os vetores $\mathbf{w}(k)$ em paralelo encontra-se detalhada em [10].

JADE

O algoritmo *Joint Approximate Diagonalization of Eigenmatrices* (JADE) se baseia na busca da solução do problema de autovalores do tensor cumulante [10], realizando uma diagonalização do tensor através da decomposição dos autovalores [38]. O tensor cumulante é um operador linear definido por cumulantes de quarta ordem. Esta operação linear gera uma matriz que tem a seguinte forma:

$$\mathbf{F}_{ij}(M) = \sum_{kl} m_{kl} cum(\mathbf{x}_i \mathbf{x}_j \mathbf{x}_k \mathbf{x}_l), \quad (3.3)$$

onde m_{kl} são os elementos da matriz M , alvo da transformação. O algoritmo JADE usa os cumulantes de segunda e quarta ordem. O primeiro realiza o branqueamento dos dados, produzindo uma matriz de branqueamento \mathbf{W} que diagonaliza a matriz $\mathbf{F}(\mathbf{M}_i)$, conforme a equação 3.4, produzindo matrizes de dados branqueados.

$$\mathbf{Q} = \mathbf{W}\mathbf{F}(\mathbf{M}_i)\mathbf{W}^T \quad (3.4)$$

A matriz de separação pode ser estimada pelo produto $\mathbf{V}\mathbf{W}$, onde \mathbf{V} é uma matriz de rotação que faz as matrizes cumulantes tão diagonais quanto possível.

A minimização da soma dos quadrados dos elementos fora da diagonal da Equação 3.4 é equivalente à maximização da soma dos quadrados dos elementos da diagonal. A maximização do algoritmo JADE fornece uma diagonal conjunta aproximada de $\mathbf{F}(\mathbf{M}_i)$, conforme

$$\mathbf{J}_{JADE}(\mathbf{W}) = \sum_i ||diag(\mathbf{W}\mathbf{F}(\mathbf{M}_i)\mathbf{W}^T)||^2 \quad (3.5)$$

onde $diag(.)$ representa a soma dos quadrados da diagonal. A maximização da função \mathbf{J}_{JADE} é uma maneira de realizar uma diagonalização conjunta aproximada da matriz $\mathbf{F}(\mathbf{M}_i)$ [10]. As matrizes \mathbf{M}_i são escolhidas das automatrizes dos tensores cumulantes.

Extensão do Algoritmo Quasi-Newton

O algoritmo apresentado por AKUZAWA [39] apresenta uma variação do método de Newton para ICA [10], sendo apresentado na realidade como um método quasi-Newton estendido. O método utiliza a *kurtosis* como função objetivo, aplicando uma otimização de segunda ordem no processo de busca dos componentes independentes. Este algoritmo apresenta a vantagem de não requerer o branqueamento dos dados. Assim como os algoritmos de otimização baseados no método de Newton, este método possui alto custo computacional, perdendo em performance, neste quesito, em comparação com o JADE e o FastICA [39].

3.3.1 Separação Cega de Fontes no Domínio da Frequência

A separação de fontes com base em ICA aplicada no sinal de sonar passivo vem obtendo bons resultados, conforme observado em trabalhos recentes [3, 4, 13]. Inicialmente, as técnicas de separação cega de fontes eram aplicadas no domínio do tempo. Entretanto, recentemente, as análises no domínio da frequência vêm ganhando terreno e apresentando resultados promissores. O diagrama da Figura 3.6, extraída de [4], mostra como é aplicada a ICA no domínio da frequência, para a separação de fontes em sinais de sonar passivo. As misturas apresentadas ao bloco ICA são constituídas das médias das magnitudes dos espectros de cada marcação, provenientes da análise DEMON, resultando em 3 misturas médias. A ICA faz a estimação da matriz de separação para, na sequência, obter os espectros médios estimados.




Figura 3.6: Separação cega com ICA no domínio da frequência [4].



3.4 Avaliação da Base de Dados

As gravações utilizadas neste trabalho foram feitas em um submarino em condições reais em águas profundas. Os sinais dos contatos foram produzidos por navios reais, de classes desconhecidas para os usuários. Por razões de sigilo militar, a Marinha não revela a classe a que pertencem os navios utilizados. As gravações correspondem aos ruídos irradiados detectados nas marcações 190° e 205° do CHA do sistema de sonar passivo instalado na popa da embarcação. Além destas marcações, o áudio do ruído próprio da embarcação onde estava instalado o CHA, gravado na marcação 76°, também foi disponibilizado.



Cada gravação possui pouco mais que 200 segundos de duração. Para este trecho de sinal, a análise DEMON disponibiliza em torno de 400 espectros de 513 pontos cada. Cada espectro corresponde a uma janela de tempo de, aproximadamente, 0,5 segundos de sinal. Este intervalo corresponde ao tempo de apresentação de cada espectro. Este valor foi obtido experimentalmente de forma a minimizar a perda de resolução espectral em função da aplicação do *overlap* de 97% utilizado na obtenção dos espectros do sinal temporal. Devido a este *overlap*, o número mínimo de espectros a serem gerados pela análise DEMON, considerados para formar o conjunto a ser avaliado, sem que haja perda de informação temporal, é de 40 espectros, equivalente a, aproximadamente, 20 segundos.

A aplicação da análise DEMON nos sinais das marcações 190°, 205° e 76°, resulta nos espectrogramas da Figura 3.7, onde também são mostrados os respectivos espectros médios. Os espectros foram gerados a partir da aplicação de um filtro passa-banda de 1-2 kHz, da STFT de 1024 pontos com *overlap* de 97%, sendo normalizados pela aplicação do algoritmo TPSW. Visualmente, percebe-se a correlação entre os picos dos espectros médios com as linhas verticais mais evidentes (escuras) nos espectrogramas.



Uma visualização mais detalhada dos espectros médios das marcações 76°, 190° e 205°, evidencia a ocorrência de interferência mútua entre as marcações, como pode



(a) Marcação 190° .




(b) Marcação 205° .




(c) Marcação 76° .


Figura 3.7: Análise DEMON: espectrogramas e espectros médios das marcações 190° , 205° e 76° .



(a) Marcação 190°.



(b) Marcação 205°.



(c) Marcação 76°.

Figura 3.8: Análise DEMON: espectros médios das marcações 190°, 205° e 76°.

ser observado na Figura 3.8. O áudio característico do ruído próprio na marcação 76° , evidenciado pelo pico de 0 dB na rotação de 304,7 rpm no espectro médio da Figura 3.8(c), pode ser observado, com certa atenuação, nos espectros médios das marcações 190° e 205° . Outras interferências prejudiciais ao trabalho de detecção do Operador de Sonar são observadas nos espectros médios das marcações 190° e 205° . No caso da marcação 190° , na Figura 3.8(a), percebe-se a presença do ruído da marcação 205° , em torno de 120,1 rpm, e também, com potências ainda mais altas, o primeiro harmônico do sinal de interesse da marcação em 293 rpm e o ruído próprio em 304,7 rpm. Já no caso da marcação 205° , na Figura 3.8(b), além do ruído próprio em 304,7 rpm, percebe-se a presença de componentes de frequência interferentes em torno de 120,1 rpm.

Retornando à Figura 3.7(b), o espectrograma da marcação 205° deixa evidente um desvio na rotação do ruído irradiado pelo contato ao longo do tempo, aproximadamente de 0 a 100 segundos. Este desvio pode ter tido origem, por exemplo, numa alteração de velocidade e/ou rumo do navio. Este desvio tem o efeito observado no espectro médio em torno de 120,1 rpm. Estas mudanças de comportamento e a presença das interferências entre marcações dificultam o trabalho de classificação do Operador de Sonar.

O sistema de monitoração proposto neste trabalho foi pensado para observar o comportamento estatístico do sinal. Para isso, os espectros obtidos a partir da análise DEMON foram utilizados como dados de entrada do sistema de monitoração. A técnica de acompanhamento se baseia em clusterizar os dados de entrada em agrupamentos, o que requer dimensões reduzidas para otimização de desempenho [35]. Em função disto, foi testada a técnica de PCA para a tarefa de redução de dimensionalidade dos espectros. Selecionou-se a marcação 190° para aplicação da técnica de PCA para avaliação do conjuntos de espectros do sinal. O algoritmo de cálculo da PCA utilizado nesta etapa emprega a técnica de decomposição em valores singulares (SVD, em inglês) [40] para obter os autovalores e autovetores da matriz de correlação do conjunto de dados.

A informação obtida de especialistas indicou que o sinal do sonar passivo deve ser avaliado a cada 10 segundos, aproximadamente, para se verificar se houve uma mudança significativa na sua estatística. Sendo esta uma escolha empírica, este intervalo foi adotado como ponto de partida para o desenvolvimento do sistema. Na análise DEMON, em um intervalo de, aproximadamente, 10 segundos, 20 janelas são aplicadas ao sinal, disponibilizando 20 espectros correspondentes a cada uma das janelas.


Aplicando-se a PCA ao primeiro conjunto de 20 espectros, obtém-se a curva de carga da Figura 3.9(a). Pode-se observar que os dois primeiros componentes já retêm mais de 95% da energia do conjunto de dados. Para avaliar o efeito do

tamanho do conjunto de espectros, e, conseqüentemente, do intervalo de tempo de avaliação do sinal, na curva de carga, a PCA foi aplicada a outros valores arbitrários do tamanho do conjunto de espectros. Na Figura 3.9, pode-se observar que à medida que se aumenta o número de espectros, o valor acumulado dos autovalores cresce mais lentamente. Considerando a curva de carga para o conjunto de 100 espectros, com dois componentes se retém pouco mais do que 40% da energia e, numa comparação com a curva do conjunto de 20 espectros, para se reter 95%, são necessários nove componentes.


O mesmo procedimento foi aplicado à marcação 205°, observando-se comportamento análogo, conforme a Figura 3.10. Nota-se, apenas, uma pequena diferença nas curvas de carga da marcação 205°, em relação às da marcação 190°. No caso, considerando apenas dois componentes, a curva de carga da marcação 205° tende a extrair mais energia para todos os intervalos analisados. Essa tendência é também observada para a energia extraída com outros números de componentes.

A análise PCA foi estendida aos demais conjuntos de espectros das duas marcações, com a finalidade de se observar o nível de energia extraída em cada conjunto analisado. Foram considerados conjuntos de espectros de dois tamanhos, a cada parada para avaliação, no caso, 20 e 40 espectros. Tais conjuntos correspondem a intervalos de tempo de, respectivamente, 10 e 20 segundos. O intervalo de avaliação de 10 segundos atende à informação obtida de especialistas, enquanto que o intervalo de 20 segundos, conforme foi explicado anteriormente, está relacionado à forma de obtenção do espectros (STFT com *overlap*), de forma a não haver perda de informação.

As Figuras 3.11(a) e 3.11(b) mostram o resultado da análise das marcações 190° e 205°, respectivamente, para conjuntos de 20 espectros. Percebe-se que na marcação 190°, com dois componentes, se representa mais de 94% da variância do sinal, consistentemente, em todos os conjuntos. No caso da marcação 205°, analogamente, mais de 95%. As Figuras 3.12(a) e 3.12(b) mostram o resultado das análises das mesmas marcações para conjuntos de 40 espectros. No caso de 20 espectros, apenas dois componentes são utilizados para obtenção do padrão de representação da variância do sinal, mostrado na Figura 3.11. Quando são utilizados 40 espectros, são necessários 4 componentes para atingir um padrão similar de representação da variância do sinal.




(a)

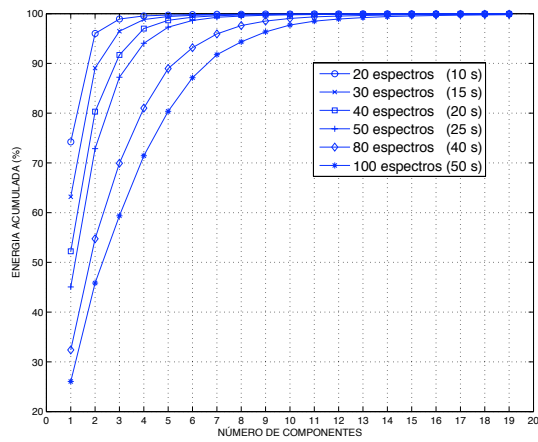


(b)

Figura 3.9: Análise PCA na marcação 190°: (a) curvas de carga para 20 espectros e (b) variação da curva de carga em função do número de espectros.




(a)

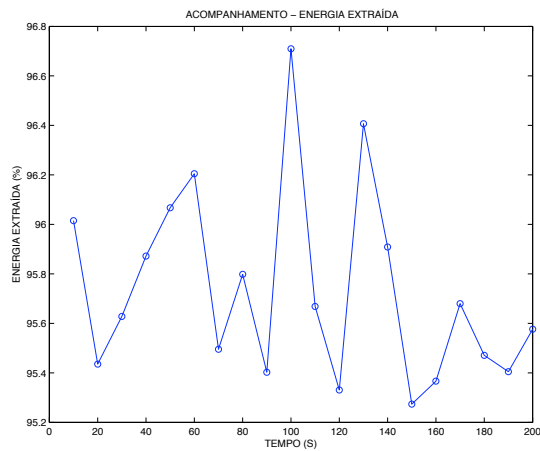


(b)

Figura 3.10: Análise PCA na marcação 205°: (a) curvas de carga para 20 espectros e (b) variação da curva de carga em função do número de espectros.




(a)

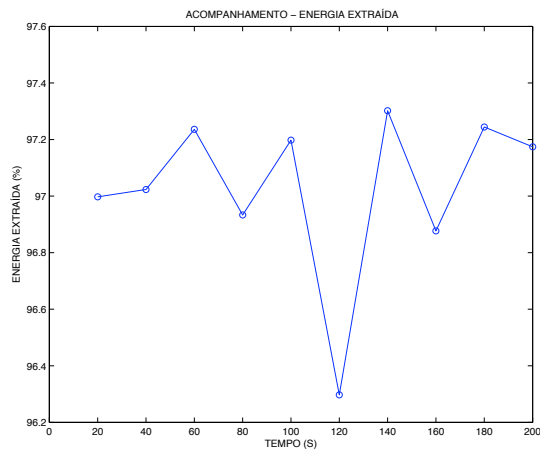


(b)

Figura 3.11: Evolução da energia extraída de cada conjunto de 20 espectros para as marcações (a) 190° e (b) 205° .



(a)



(b)

Figura 3.12: Evolução da energia extraída de cada conjunto de 40 espectros para as marcações (a) 190° e (b) 205° .

Capítulo 4

Sistema de Monitoração

O sistema de monitoração proposto neste trabalho, com o objetivo de acompanhar o comportamento estatístico do sinal do sonar passivo, processa o sinal em um ambiente não supervisionado [41]. A monitoração contínua do sinal do sonar, que deve ser realizada em janelas de tempo especificado e de duração cuidadosamente selecionada, é requerida devido ao comportamento não estacionário apresentado pelos ruídos captados pelo sistema de 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 novos padrões de comportamento, e ser de baixa complexidade de implementação, para ser integrada nos sistemas embarcados da cadeia de processamento do sinal do sonar. Sistemas inteligentes com estas características de aprendizado, como as redes neurais [7], por exemplo, dependem fortemente do conjunto de dados para um projeto eficiente, e requerem cuidados específicos em todas as fases de projeto.

Um sistema de aprendizado, de forma geral, funciona em dois modos: o modo de treinamento e o modo de operação. Durante a fase de treinamento, também conhecida como aprendizado, o sistema busca aprender através da experiência, ou seja, através de repetidas interações com o conjunto de dados, segundo uma regra de aprendizado ou algoritmo de treinamento. HAYKIN [7] descreveu dois tipos conhecidos de aprendizado, quais sejam, com professor e sem professor. No aprendizado com professor, ou treinamento supervisionado, existe um conhecimento prévio sobre o conjunto de dados de treinamento. O “professor” é quem detém tal conhecimento do ambiente de geração dos dados, que é representado por pares de entrada e saída. O treinamento consiste em se apresentar uma entrada ao sistema de aprendizado e comparar sua saída, conhecida como resposta real, com a resposta desejada que o “professor” conhece. O erro (diferença) entre a resposta real e a resposta desejada é utilizado para ajustar os parâmetros internos do sistema de aprendizado. Este processo é repetido iterativamente até que o sistema de aprendizado possa assumir o papel do professor, em outras palavras, até que o professor transfira o seu conhe-

cimento para o sistema de aprendizado. Do ponto de vista estatístico, seria como encontrar a solução ótima, ou chegar tão próximo quanto se queira desta condição, em um problema de otimização. A partir deste momento, o sistema de aprendizado está pronto para entrar no modo de operação, passando a reconhecer/classificar de forma independente os dados de entrada.

No aprendizado sem professor, dois tipos são conhecidos [7]: o aprendizado não supervisionado ou auto-organizado e o aprendizado por reforço. Este último, também conhecido como programação neurodinâmica, está ligado à programação dinâmica no contexto da teoria de controle ótimo, o que foge ao escopo deste trabalho, podendo ser encontrada uma descrição detalhada sobre o tema em [42]. O aprendizado não supervisionado não emprega um professor no projeto do sistema de aprendizado. O processo consiste em realizar uma busca de características diretamente no conjunto de dados de entrada, segundo alguma medida de similaridade [41]. Com base nesta medida de similaridade é possível estabelecer um critério para formação de agrupamentos com os dados de entrada, para, desta forma, classificá-los de acordo com o agrupamento a que pertençam.

Um método simples de aprendizado não-supervisionado foi introduzido por RUMELHART e ZIPSER [43], sendo chamado de aprendizado competitivo. Um sistema de aprendizado não-supervisionado usando aprendizado competitivo como regra de treinamento pode ser implementado por uma rede neural de duas camadas, sendo, uma de entrada e outra de competição [7]. A camada de entrada apenas apresenta os dados disponíveis para a camada de competição. Esta, por sua vez, é formada por neurônios que irão competir entre si pelo dado de entrada, segundo uma regra de similaridade. A definição do vencedor é do tipo “o vencedor leva tudo”, ou seja, o neurônio com maior similaridade vence a competição e sua saída é ligada, enquanto a saída dos demais é desligada.

Os aprendizados supervisionado e não supervisionado, além da tarefa de reconhecimento de padrões, também conhecida como classificação, podem ser utilizadas para o treinamento de sistemas de aprendizado com outras finalidades, como por exemplo, aproximação de funções, controle, filtragem, formação de feixe. A definição do algoritmo e do tipo de aprendizado vai depender da natureza da aplicação [7]. As redes neurais são comumente utilizadas como sistemas de aprendizado devido à sua conhecida capacidade natural de obtenção e armazenamento de conhecimento e de torná-lo disponível para uso. HAYKIN [7] descreve uma série de características favoráveis ao uso das redes neurais, não limitadas a estas, tais como: mapeamento não-linear, generalização, resposta a evidências e tolerância a falhas.

O sistema de monitoração desenvolvido neste trabalho propõe o uso de uma rede neural, com treinamento não-supervisionado, para acompanhar as flutuações estatísticas no sinal de sonar passivo, com base em um algoritmo de clusterização

com aprendizado competitivo. Neste capítulo, será mostrado o modelo conceitual do sistema de monitoração proposto, finalizando com a sistemática de acompanhamento elaborada para o sistema.

4.1 Clusterização de Dados

Clusterização, expressão derivada do termo em inglês *clustering*, é uma técnica de análise exploratória de um conjunto de dados, que visa formar subconjuntos de dados que possuam algum tipo de similaridade entre eles. Como essa análise exploratória não utiliza informação prévia da natureza dos dados e de como eles estão relacionados, a clusterização é, na grande maioria dos casos, uma técnica não supervisionada. Há, ainda, exemplos de uso de algoritmos desenvolvidos para clusterização não-supervisionada que foram adaptados para aplicações em ambientes supervisionados [6, 44, 45]. Em geral, a clusterização pode ser encontrada em alguns contextos com o nome de aprendizado não supervisionado e aprendizado sem um professor (em reconhecimento de padrões), entre outros como, taxonomia numérica (em biologia e ecologia), tipologia (nas ciências sociais), e particionamento (em teoria dos grafos) [41].

Um subconjunto, também referido como agrupamento ou *cluster*, contém dados que são mais similares entre si do que os dados contidos por outros *clusters*. Existem diversas formas de quantificar a similaridade (ou dissimilaridade) entre dados. A escolha adequada de uma medida de similaridade é fundamental para uma clusterização atingir resultados satisfatórios. Cuidados especiais devem ser tomados tanto com a medida de similaridade (ou dissimilaridade) utilizada, como com os critérios específicos adotados para a formação e avaliação dos *clusters*. Dependendo da escolha que se faça desses critérios, pode-se chegar a resultados distintos para a clusterização. Um simples exemplo, inspirado em [41], para ilustração, seria considerar o seguinte grupo de animais: cavalo, cachorro, gato (mamíferos); cobra (réptil); dourado, salmão (peixes) e sapo (anfíbio). Na maneira que estão divididos, já representam o resultado de uma clusterização pelo critério de classes de animais: (1) mamíferos, (2) répteis, (3) peixes e (4) anfíbios. Caso o critério fosse o ambiente onde vivem, resultaria em 3 *clusters*: cavalo, cachorro, gato, cobra (fora d'água); dourado salmão (dentro d'água) e sapo (ambos). No caso do sapo, estaria contido em um *cluster* entre os outros dois, já que pode viver nos dois ambientes.

Dentre os cuidados aos quais se deve estar atento ao se iniciar um processo de clusterização de dados, cabem ser destacados os seguintes [41]:

- Seleção de características (pré-processamento)
- Medida de similaridade (ou dissimilaridade)

- Algoritmos de clusterização
- Validação e interpretação dos resultados

Para cada uma destas etapas, existem técnicas disponíveis, amplamente detalhadas na literatura [7, 41, 46, 47], cabendo ao projetista avaliar a aplicabilidade caso a caso. Diferentes escolhas podem levar a resultados de clusterização diferentes.

A primeira etapa de seleção de características consiste no primeiro contato com o conjunto de dados. Trata-se do pré-processamento dos dados, tema que já foi abordado no Capítulo 3, cujo conteúdo também se aplica no contexto da clusterização. Em [7, 41, 46], encontra-se extenso material sobre extração e seleção de características.

Medidas de Proximidade

A expressão medida de proximidade é aqui usada porque é possível encontrar uma similaridade ou dissimilaridade entre os dados, dependendo das definições adotadas. De uma forma ou de outra, uma medida de proximidade tem a importante tarefa de encontrar características similares nos dados, visando formar agrupamentos naturais destes dados. Do ponto de vista geométrico, os dados podem ser descritos por vetores em um espaço d -dimensional. Colocado desta forma, um método simples de medir a proximidade entre os dados seria através do cálculo da distância entre eles. A distância entre dois vetores $d_{\mathbf{x},\mathbf{x}}$ do conjunto de dados X , é definida como medida de dissimilaridade (MD), sendo uma função que deve obedecer as seguintes condições [41]:

$$d_{\mathbf{x},\mathbf{x}} : X \times X \rightarrow \mathbb{R} \quad (4.1)$$

$$\exists d_0 \in \mathbb{R} : -\infty < d_0 \leq d(\mathbf{x}, \mathbf{y}) < +\infty \quad (4.2)$$

$$d_{\mathbf{x},\mathbf{x}}(\mathbf{x}, \mathbf{x}) = d_0 \quad \forall \mathbf{x} \in X \quad (4.3)$$

$$d_{\mathbf{x},\mathbf{y}}(\mathbf{x}, \mathbf{y}) = d_{\mathbf{y},\mathbf{x}}(\mathbf{y}, \mathbf{x}), \quad \forall \mathbf{x}, \mathbf{y} \in X \quad (4.4)$$

$$d_{\mathbf{x},\mathbf{y}}(\mathbf{x}, \mathbf{y}) = d_0 \quad \text{se, somente se, } \mathbf{x} = \mathbf{y} \quad (4.5)$$

$$d_{\mathbf{x},\mathbf{z}}(\mathbf{x}, \mathbf{z}) \leq d_{\mathbf{x},\mathbf{y}}(\mathbf{x}, \mathbf{y}) + d_{\mathbf{y},\mathbf{z}}(\mathbf{y}, \mathbf{z}), \quad \forall \mathbf{x}, \mathbf{y}, \mathbf{z} \in X \quad (4.6)$$

Cabe destacar o resultado da Equação 4.5, que indica que o valor mínimo de dissimilaridade d_0 entre dois vetores em X só ocorre quando tais vetores são iguais.

Sob condições análogas às que foram estabelecidas para MD, define-se s como medida de similaridade (MS), porém, neste caso, a medida possui um valor máximo s_0 quando dois vetores em X forem iguais [41], ao invés de um valor mínimo, como d_0 para MD.

Uma classe de MD largamente utilizada é conhecida como distância de Minkowski, cuja forma é dada pela Equação 4.7 [46]:

$$d_{\mathbf{x},\mathbf{y}}(\mathbf{x}, \mathbf{y}) = \left(\sum_{k=1}^d |x_k - y_k|^q \right)^{1/q}, \quad (4.7)$$

onde $q \geq 1$. A variação do parâmetro q define diferentes tipos de distâncias. As mais conhecidas são [46]:

- Distância de Manhattan ($q = 1$):

$$d_{\mathbf{x},\mathbf{y}}(\mathbf{x}, \mathbf{y}) = \sum_{k=1}^d |x_k - y_k| \quad (4.8)$$

- Distância Euclidiana ($q = 2$):

$$d_{\mathbf{x},\mathbf{y}}(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{k=1}^d |x_k - y_k|^2} \quad (4.9)$$

Uma importante propriedade da distância Euclidiana é ser invariante a uma rotação ou translação arbitrária no espaço de características. O quadrado da distância Euclidiana costuma ser utilizado pelas técnicas de otimização, dentro dos seus algoritmos para fins de comparação de distância, tendo como característica destacar os padrões mais distantes do centro da distribuição dos dados [48]. Outra MD comumente utilizada é a distância de Mahalanobis [46], dada pela Equação 4.10, que difere da distância Euclidiana por ser invariante a fatores de escala e por levar em consideração a correlação existente entre os dados.

$$d_{\mathbf{x},\mathbf{y}}(\mathbf{x}, \mathbf{y}) = \sqrt{(\mathbf{x} - \mathbf{y})^T \Sigma^{-1} (\mathbf{x} - \mathbf{y})}, \quad (4.10)$$

onde Σ é a matriz de covariância. Se Σ for a matriz identidade, a Equação 4.10 se torna a distância Euclidiana, dada pela Equação 4.9.

Uma MD disponível, que faz uma subestimação da distância de Mahalanobis [41], é conhecida como norma l_∞ , que é dada por

$$d_{\mathbf{x},\mathbf{y}}(\mathbf{x}, \mathbf{y}) = \max w_i |x_i - y_i|, \quad 1 \leq i \leq l \quad (4.11)$$

onde cada $w_i \geq 0$ representa um peso associado a cada diferença $|x_i - y_i|$.

Algoritmos de Clusterização

Uma série de algoritmos consolidados encontra-se disponível na literatura [41, 46]. Os mais utilizados são: os sequenciais; os hierárquicos, como, por exemplo, os aglomerativos baseados na teoria dos grafos; os de otimização de funções, como, por exemplo, o *k-means*, e os competitivos, como os mapas auto-organizáveis [7] e a teoria de ressonância adaptativa (ART). Este último conceito contempla o algoritmo que será utilizado neste trabalho para a clusterização do sinal de sonar.

4.2 Clusterização Neural do Sistema de Monitoração

A rede ART foi originalmente proposta por GROSSBERG [49], com o objetivo de se modelar como as redes neurais biológicas seriam capazes de reconhecer novos padrões e lembrarem-se deles para uso futuro. Isto ficou conhecido como o dilema estabilidade-plasticidade [46], ou seja, capacidade de aprendizado adaptativo sem prejuízo para a capacidade de generalização. Diferentes estruturas de rede ART, cada uma com um objetivo, dependendo do cenário de aplicação, foram propostas a partir da original. Algumas destas estruturas são destacadas a seguir, conforme a aplicação e o tipo de aprendizado:

- Aprendizado supervisionado:
 - ARTMAP, para dados binários [44];
 - Fuzzy-ARTMAP, para dados analógicos [45].

- Aprendizado não-supervisionado:
 - ART-1, para dados binários [50];
 - ART-2, para dados analógicos [51];
 - ART-2a, para dados analógicos [52];
 - ART-3, para dados analógicos [53];
 - Fuzzy-ART, para dados analógicos [54].

O modelo de rede selecionado para este trabalho se baseia numa variante do tipo ART-2. Esta rede já foi testada como classificador nos ambientes de sonar passivo [6] e de física de partículas [5]. Ela procura simplificar a estrutura mais complexa de implementação da rede ART-2. O treinamento da rede deste trabalho se baseia na camada de Kohonen [55] com treinamento competitivo não-supervisionado. A

formação de agrupamentos com esta rede consiste em atribuir um neurônio a cada centro do agrupamento, sendo que a partir da similaridade entre cada padrão de entrada e o vetor de pesos do neurônio, será definido se o neurônio será treinado ou se um novo neurônio será criado. Para um dado padrão de entrada, o neurônio que exibir a menor distância Euclidiana para este padrão será declarado o neurônio vencedor, considerando que esta distância seja menor que o valor definido para o raio de vigilância do centro do agrupamento. Este neurônio será treinado de acordo com a seguinte regra:

$$\mathbf{w}_{k+1} = (1 - \alpha)\mathbf{w}_k + \alpha\mathbf{x}_k, \quad (4.12)$$

onde α é o coeficiente de aprendizagem, \mathbf{w} , o vetor de pesos associado ao neurônio e \mathbf{x} , o vetor de entrada.

O raio de vigilância do agrupamento impõe uma região limitada de atuação do neurônio. Geometricamente, esta região equivale ao volume máximo de cada agrupamento. É esperado que, após um certo número de passos de treinamento, o vetor de pesos de cada neurônio convirja para o centróide do agrupamento correspondente. Caso o padrão de entrada recebido não seja similar a nenhum dos neurônios, automaticamente a rede cria um novo agrupamento, atribuindo ao seu vetor de pesos o vetor de entrada recebido. Essa capacidade de adaptação, de forma simples e rápida, da estrutura da rede a partir da chegada de padrões de entrada não mapeados, confere à esta variante da rede ART boa plasticidade neuronal.

A rede proposta foi implementada com um processo de esquecimento, que consiste em eliminar da rede um neurônio que permaneça inativo (não treinado) por um determinado número de passos de treinamento. A escolha do número de passos de inatividade do neurônio para que este seja esquecido é feita experimentalmente.

A rede ART foi escolhida por seu treinamento ser do tipo não supervisionado, o que se enquadra no contexto do sonar passivo, e pela simplicidade de implementação, essenciais para aplicações em tempo real, conforme requer o ambiente. Adicionalmente, a rede ART modificada tem na plasticidade neuronal uma característica fundamental, já que se pretende monitorar alterações no comportamento estatístico do sinal do sonar passivo. Segundo CARPENTER *et al.* [52], ao final do treinamento, após exposições sucessivas dos dados de entrada, os neurônios se ajustam de forma a representar a distribuição de probabilidade das amostras da entrada. Esta é outra característica da rede ART que motivou a sua escolha para atingir o principal objetivo deste trabalho, que é o acompanhamento da estatística do sinal de sonar passivo.

4.3 Sistemática de Acompanhamento

Para a monitoração do sinal de sonar passivo, foi proposto o seguinte modelo conceitual do sistema, para cada marcação a ser acompanhada:

- Selecionar N espectros do sinal do sonar passivo;
- Clusterizar o conjunto de N espectros, apresentando os N espectros à rede ordenados aleatoriamente, a cada época de treinamento;
- Avaliar as mudanças no número de clusters e possíveis deslocamentos dos centros destes clusters;
- Identificar as mudanças na estatística;
- Repetir o procedimento para todo trecho de sinal avaliado.

Partindo do modelo conceitual, e após a avaliação da base de dados mostrada na Seção 3.4, a seguinte sistemática foi adotada para o acompanhamento do sinal do sonar usando clusterização não supervisionada com a rede ART modificada:

1. Recebimento do grupo de N espectros;
2. Remoção da média;
3. Aplicação de PCA para obtenção das direções principais;
4. Observação da curva de carga obtida através de PCA aplicada ao grupo de N espectros recebidos;
 - Ordenação dos componentes principais em ordem decrescente dos respectivos autovalores;
 - Seleção dos componentes que garantam um patamar mínimo especificado na curva de carga;
5. Projeção dos dados (espectros) nos maiores componentes principais considerados;
6. Normalização das projeções para conter variáveis padronizadas;
7. Clusterização com a rede ART modificada com esquecimento;
 - Registro de informações sobre o número de *clusters* formados, sobre o posicionamento e a dispersão destes *clusters*.
8. Avaliação e indicação;
9. Volta para 1, para reiniciar o procedimento para o próximo grupo de N espectros, mantendo-se os clusteres formados na análise do grupo atual de espectros.

No passo 3, as direções principais são calculadas para cada conjunto de espectros a ser clusterizado. No passo 4, é feito um controle do valor acumulado da curva de carga. Caso este valor caia abaixo de um limiar mínimo a ser especificado pelo projetista, o controle determina o aumento do número de projeções (de 1 em 1) até atingir (ou ultrapassar) o limiar mínimo. A variação do valor acumulado da curva de carga pode ser acompanhada pelo sistema, podendo ser tomada como parâmetro de indicação de mudança da estatística do sinal do sonar, o que caberia ser observado durante a avaliação realizada pelo sistema de monitoração.

4.4 Figuras de Mérito e Medidas de Desempenho

A avaliação da eficiência do sistema de monitoração, no que se refere à detecção de alterações no comportamento estatístico do sinal de sonar passivo, deve dispor de medidas com esta finalidade. Em relação ao acompanhamento estatístico, caso as fontes que compõem o sinal de sonar fossem conhecidas, tal tarefa seria bem simples. Entretanto, como já foi explicado nos capítulos anteriores, não se dispõe de qualquer informação sobre os sinais irradiados pelos contatos. Adicionalmente, estes sinais podem sofrer de interferência mútua, atrasos por reflexão, propagação por canais variantes no tempo, entre outros dificultantes. A detecção destes sinais é feita de forma completamente cega, sendo realizada a partir das misturas captadas pelos hidrofones em cada marcação. Como foi visto na Seção 3.3.1, uma das formas de se melhorar a detecção e a identificação das fontes da mistura explora a independência estatística entre as fontes na estimação do modelo de separação.

Figuras de Mérito

Uma das figuras de mérito estatísticas que serão utilizadas para validar o funcionamento do sistema de monitoração é a informação mútua [56]. Uma vez que a informação mútua carrega toda informação sobre a estatística do sinal, ela pode ser utilizada para verificar se tanto as misturas como as fontes estimadas estão sofrendo alguma alteração no comportamento estatístico. Desta forma, a indicação do sistema de monitoração se houve alguma mudança pode ser validada por comparação direta com o que indica o valor da informação mútua.

Largamente utilizada em teoria da informação, a informação mútua, em termos práticos, mede a quantidade de informação que uma variável aleatória carrega sobre outra, ou seja, a dependência mútua entre essas variáveis. A informação mútua entre duas variáveis \mathbf{x} e \mathbf{y} discretas é definida pela Equação 4.13 [56].

$$I(\mathbf{x}, \mathbf{y}) = \sum_{y \in \mathbf{y}} \sum_{x \in \mathbf{x}} p(x, y) \log \left(\frac{p(x, y)}{p_1(x)p_2(y)} \right), \quad (4.13)$$

onde $p(x, y)$ é a função de distribuição de probabilidade conjunta de \mathbf{x} e \mathbf{y} , e $p_1(x)$ e $p_2(y)$ são as funções de distribuição de probabilidade marginais de \mathbf{x} e \mathbf{y} , respectivamente. É fácil perceber que, aplicando-se a definição formal de independência estatística [57], se \mathbf{x} e \mathbf{y} forem independentes, $p(x, y) = p_1(x) \cdot p_2(y)$. Nesta situação, $I(\mathbf{x}, \mathbf{y}) = 0$ ($\log 1 = 0$). Como $I(\mathbf{x}, \mathbf{y})$ é sempre não negativa, o valor mínimo da informação mútua entre duas variáveis aleatórias ocorre quando elas forem independentes. Na prática, é raro isto acontecer, de forma que valores próximos a zero indicam que as variáveis são aproximadamente independentes.

As funções de distribuição de probabilidade, quando não são conhecidas, devem ser estimadas por algum método de estimação não paramétrico, como o método da janela de Parzen-Rosenblatt e o método do histograma [29, 46]. No caso deste trabalho, o método de estimação do histograma é utilizado. Um detalhamento da teoria de estimação não paramétrica e dos principais métodos conhecidos pode ser encontrado em [29].

Outra figura de mérito que será utilizada é o cálculo dos cumulantes cruzados de quarta ordem. Em [58], foi apresentada a derivação de um algoritmo para o cálculo da medida de cumulantes cruzados de quarta ordem, para independência entre variáveis aleatórias, dada pela Equação 4.14, que é minimizada pelo algoritmo JADE para ICA.

$$\mu_{\mathbf{cum}}^4(\mathbf{x}) = \sum_{i,j=1}^n \sum_{k,l=1}^n \mathbf{cum}\{x_i, x_j, x_k, x_l\}^2, \quad (4.14)$$

onde \mathbf{x} é um vetor aleatório de componentes x_1, \dots, x_n com média zero e $\mathbf{cum}\{x_i, x_j, x_k, x_l\}$ é o cumulante cruzado de quarta ordem das variáveis aleatórias x_i, x_j, x_k, x_l .

Os cumulantes de ordem k de uma variável aleatória x , são definidos em [36], como os coeficientes na expansão em série de Taylor da função geradora de cumulantes, de forma similar aos momentos [57], dada por

$$K(z) = \ln E [\exp(z^T x)]. \quad (4.15)$$

O cumulante de ordem k da variável aleatória x passa a ser definido em termos de seus momentos de ordens indo até k . Os cumulantes de segunda, terceira e quarta ordens, se x possui média zero, são dados por [10]

$$\kappa_1 = 0 \quad (4.16)$$

$$\kappa_2 = E\{x^2\} \quad (4.17)$$

$$\kappa_3 = E\{x^3\} \quad (4.18)$$

$$\kappa_4 = E\{x^4\} - 3[E\{x^2\}]^2 \quad (4.19)$$

Com exceção do cumulante de quarta ordem, os demais são iguais aos respectivos momentos centrais. Estatísticas de ordem superior a quatro raramente são utilizadas na prática [10]. Os cumulantes de terceira e quarta ordens são conhecidos como *skewness* e *kurtosis*, respectivamente. Em [10], encontra-se a definição dos cumulantes cruzados para o caso de vetores aleatórios multivariáveis e para quando a variável aleatória não possui média zero.

Uma característica importante, explorada pela ICA, é que variáveis e processos aleatórios gaussianos possuem cumulantes iguais a zero a partir da terceira ordem [10]. A *kurtosis* carrega informação da não gaussianidade de uma variável aleatória, de forma que muitos algoritmos de ICA buscam a maximização deste cumulante para a separação de fontes não gaussianas. Uma variável aleatória que segue uma distribuição de Laplace [10], que apresenta um acentuado pico em seu valor central, possui um valor alto de *kurtosis*. Já uma variável de distribuição uniforme, com seu formato achatado e plano, possui um baixo valor. O cumulante *skewness* fornece informação sobre a assimetria da distribuição de uma variável aleatória.

Medidas de Desempenho

Duas medidas de desempenho largamente utilizadas na teoria de detecção de sinais são as clássicas probabilidades de detecção e de falso alarme. Para o sistema de monitoração deste trabalho, ambas são calculadas para conferir um grau de confiança ao sistema. A primeira informa a eficiência em termos de acertos de indicação de alteração da estatística do sinal. A segunda, em termos dos erros, ou seja, aqueles instantes em que o sistema indica que houve alteração, quando não houve qualquer evidência. Outra medida é a probabilidade de “perda do alvo”. Neste caso, o sistema não faz qualquer indicação de mudança da estatística, quando, na verdade, há evidências indicando mudança. Para o cálculo destas probabilidades, as evidências do comportamento estatístico do sinal serão obtidas com base nas figuras de mérito apresentadas anteriormente.

Capítulo 5

Testes do Sistema de Monitoração

Neste capítulo, é feita uma descrição dos parâmetros do sistema de monitoração e do procedimento adotado para sintonizá-los. Na sequência, são mostrados os efeitos da variação dos parâmetros na clusterização dos espectros do sinal de sonar. O capítulo prossegue com a apresentação dos resultados dos testes do sistema de monitoração, onde, tendo como base o acompanhamento da estatística do sinal, são comparadas as indicações do sistema e as figuras de mérito, no caso, a informação mútua e os cumulantes cruzados. Ao final, adicionalmente, são avaliados os efeitos na eficiência da classificação neural de contatos, em função do uso de ICA no pré-processamento do sinal de sonar passivo, no domínio do tempo.

5.1 Parâmetros de Sintonia do Sistema

Antes de se iniciar o acompanhamento do sinal de sonar, o primeiro passo para que se possa colocar o sistema em operação consiste no ajuste de parâmetros de sintonia, quais sejam:

- Parâmetros de pré-processamento e limiar de energia
- Parâmetros de clusterização neural

Pré-processamento e limiar de energia

Na grande maioria dos cenários onde se pretende utilizar um sistema de aprendizado, o pré-processamento dos dados brutos consiste em etapa fundamental, tanto para a fase de treinamento como para a fase de operação do sistema. No caso do sistema de monitoração proposto, não é diferente. No Capítulo 3, foi mostrada a cadeia de pré-processamento a qual o sinal de sonar é submetido, até que este seja disponibilizado para visualização do OS, desde a conformação de feixes até as telas

com o gráfico marcação x tempo e com os espectrogramas das análises espectrais DEMON e LOFAR.

O sistema de monitoração utiliza uma rede neural para a clusterização dos espectros da análise DEMON. Os N espectros contidos na matriz X de dimensões $N \times d$ representam os dados de entrada do sistema de monitoração, que são pré-processados antes de serem apresentados à camada de entrada da rede. Devido à elevada dimensão dos espectros (513), a PCA (Seção 3.2) é utilizada para redução de dimensionalidade, como foi mostrado na Seção 3.4, de forma a representar da melhor maneira possível, o espaço de características do conjunto de dados de entrada. O uso da PCA pelo sistema fica a cargo do projetista, podendo ser facilmente desabilitada de acordo com a análise preliminar dos dados. Considerando V a matriz $l \times d$ das l direções principais de maior energia, que foram selecionadas para projeção dos espectros, as projeções X' são obtidas por

$$X'_{N \times l} = X_{N \times d} \cdot V_{l \times d}^T, \quad l \leq d. \quad (5.1)$$

Naturalmente, só haverá redução de dimensionalidade, caso l esteja no intervalo $1, \dots, d - 1$.

Após a redução de dimensionalidade, as projeções X' dos espectros têm suas variáveis centralizadas, pela subtração de μ_i , e normalizadas, pela divisão por σ_i , respectivamente, média e desvio padrão de cada variável de X' , da seguinte forma:

$$\frac{\mathbf{x}'_k - \underline{\mu}}{\underline{\sigma}} \quad (5.2)$$

onde $\underline{\mu} = [\mu_1, \dots, \mu_l]$ e $\underline{\sigma} = [\sigma_1, \dots, \sigma_l]$, de modo que cada padrão de entrada \mathbf{x}'_k em X' , onde $k = 1, \dots, N$, contenha variáveis padronizadas.

A aplicação da PCA ao conjunto de espectros X resulta na obtenção da curva de carga, através da qual se detecta qual percentual de energia é extraído de X pelo número de direções principais utilizadas na projeção, conforme foi mostrado na Seção 3.4.

Foi criado um parâmetro, chamado limiar de energia, o qual representa o valor mínimo que se deseja atingir para o número de componentes considerado para formar os padrões de entrada. Para um dado número de componentes, o sistema sabe o valor da energia que estes componentes retêm de X . Caso este valor caia abaixo do limiar de energia, o sistema de monitoração determina o aumento do número de projeções (de 1 em 1) até atingir um número mínimo para o limiar especificado. O sistema inicia utilizando 2 componentes para redução de dimensionalidade. Para iniciar os testes do sistema, o valor de 90% foi especificado para o limiar de energia. Para um conjunto de espectros de tamanho $N = 20$, apenas 2 componentes já superam com folga este limiar, enquanto que, para um conjunto de tamanho $N = 40$, já são

necessários 4 componentes para superar este limiar, o que foi mostrado na Seção 3.4.

Caso haja indicação de que este valor não tenha sido atingido ao longo da monitoração do sinal, esta poderia ser mais uma indicação da mudança da estatística do sinal do sonar, o que deve ser mérito de avaliação.

Parâmetros de clusterização neural

Tais parâmetros estão diretamente associados ao processo de clusterização pela rede ART modificada. Os parâmetros são:

- Fator de aprendizado, α
- Parada por convergência dos centros, η
- Parada por não criação de *clusters*
- Número de épocas para esquecimento de *clusters*
- Raio de vigilância dos *clusters*, ρ

O **fator de aprendizado** α surge na regra de atualização dos centros, conforme foi mostrado na Equação 4.12, da Seção 4.2, que segue repetida a seguir

$$\mathbf{w}_{k+1} = (1 - \alpha)\mathbf{w}_k + \alpha\mathbf{x}_k.$$

Neste trabalho, inicialmente, o valor $\alpha = 0.1$ foi utilizado. A idéia desta regra, combinada com uma escolha adequada de valor para α , é fazer com que o centro vencedor na camada competitiva seja atualizado de forma a dar um passo pequeno e a caminhar suavemente na direção do padrão de entrada \mathbf{x}_k . O valor de α também afeta a estabilidade da curva de aprendizado do treinamento, valores muito altos acarretam em alta velocidade de convergência, mas podem gerar oscilações elevadas e, em alguns casos, levam à instabilidade. Valores mais baixos, tornam a convergência mais suave, entretanto a deixam mais lenta.

A **parada por convergência dos centros** ocorre se, ao final de cada época (uma passada de todo conjunto de padrões) do treinamento ART, a variação combinada de todos os centros \mathbf{w} , representados pela matriz \mathbf{W} , for menor que o valor estabelecido para η . A variação combinada dos centros é calculada por

$$\sum_i \sum_j (\mathbf{W}_k - \mathbf{W}_{k-1})^2 \tag{5.3}$$

onde a operação de elevar ao quadrado significa produto ponto a ponto, j indica que o somatório é feito ao longo das colunas e i , ao longo das linhas. Neste trabalho,

foi especificado o valor $\eta = 10^{-9}$. A escolha do valor adequado para η , assim como α , deve ser feito experimentalmente, a partir de observações de várias rodadas de treinamento. O valor de η tem influência direta na duração do treinamento e, caso a convergência não seja atingida pela diminuição das atualizações dos centros dos *clusters*, ou seja, caso o valor calculado pela Equação 5.3 não chegue a ficar menor que η , o próximo parâmetro, parada por não criação de *clusters*, se encarregará de encerrar o treinamento.

A **parada por não criação de *clusters*** foi implementada para evitar que o treinamento se prolongue indefinidamente, caso o valor de η não seja atingido. Durante o treinamento ART, um contador registra se não ocorreu criação de algum *cluster*, sendo incrementado a cada época. Caso haja a criação de novo *cluster*, antes que seja atingido um número máximo especificado para a parada por não criação sucessiva de *clusters*, o contador é zerado. Logo, a parada por não criação de *clusters* só ocorre quando o treinamento permanece por sucessivas épocas, até um número máximo desejado, sem criação de novo *cluster*. A especificação do valor máximo para este parâmetro é experimental, devendo ser observadas as curvas de convergência do treinamento. Inicialmente, foi especificado o número de 10 épocas sucessivas sem criação de novo *cluster* para que o treinamento seja encerrado.

O **esquecimento de *clusters*** foi implementado no treinamento ART. Ele monitora se um *cluster* ficou muito tempo sem ser atualizado pela regra da Equação 5.3, ou seja, sem receber um padrão de entrada em sua área de cobertura por um determinado número de épocas. Se isto acontecer, este *cluster* é esquecido, ou seja, é eliminado do treinamento. Foi especificado que, com 8 iterações com o *cluster* inativo, ele é esquecido.

Como foi mostrado no Capítulo 4, a definição do tamanho da área de atuação do *cluster*, que é determinada pelo seu **raio de vigilância**, trata-se de uma etapa crítica para os resultados da clusterização. O procedimento adotado para essa escolha consiste em se calcular as distâncias entre todos os padrões de entrada do conjunto a ser clusterizado. A medida de distância utilizada foi o quadrado da distância Euclidiana, dada pela Equação 4.9. Sendo assim, as distâncias entre os padrões de entrada é feita de acordo com a Equação 5.4.

$$d(\mathbf{x}_{i,j}, \mathbf{x}_{k,j}) = \sum_{j=1}^d |x_{i,j} - x_{k,j}|^2, \quad i, k = 1, \dots, N \quad \forall \quad i \neq k \quad (5.4)$$

onde N é o tamanho do conjunto de padrões de entrada. O vetor de distâncias \mathbf{d} conterá todas as distâncias calculadas.

5.2 Testes para o Ajuste de Parâmetros

Um ponto de partida para parametrização do sistema é a observação dos padrões de entrada. Para tanto, foi computado o vetor de distâncias \mathbf{d} e preenchido um histograma com o conteúdo do vetor. Neste ponto, são utilizados conjuntos de 20 espectros, que após a aplicação de PCA, são requeridos apenas dois componentes principais para extrair mais de 90% de energia do sinal, como foi demonstrado na Seção 3.4. A Figura 5.1 mostra o histograma preenchido com as distâncias do primeiro conjunto de 20 espectros da marcação 190° . Através deste histograma, é possível parametrizar o valor do raio de vigilância inicial ρ . O projetista possui liberdade para escolher a forma de obtenção de ρ . Inicialmente, optou-se por obter o valor de ρ como 1,5 vezes o valor da primeira moda do histograma das distâncias entre os padrões de entrada [15].




Figura 5.1: Histograma das distâncias entre os padrões de entrada do primeiro conjunto de 20 espectros da marcação 190° .

Uma vez definido ρ , foi feita uma primeira tentativa de clusterização do conjunto de padrões de entrada, considerando os demais parâmetros especificados de acordo com o que foi mostrado na Seção 5.1. A escolha do raio inicial como sendo 1,5 vezes a primeira moda do histograma, no caso, 0,47 (equivalente à frequência superior a 60), acarretou no mapeamento final de *clusters* da Figura 5.2(a). Na sequência, o sistema foi acionado para clusterização do segundo conjunto de 20 espectros, conforme a sistemática de acompanhamento descrita na Seção 4.3. Nas épocas iniciais do segundo conjunto, foi possível observar que um número elevado de *clusters* estavam sendo mapeados, após a mudança para a nova base PCA, em uma região distante da incidência dos padrões de entrada, ocasionando na criação de um número elevado de novos *clusters*. Esta mesma situação pode ser observada nos demais conjuntos de

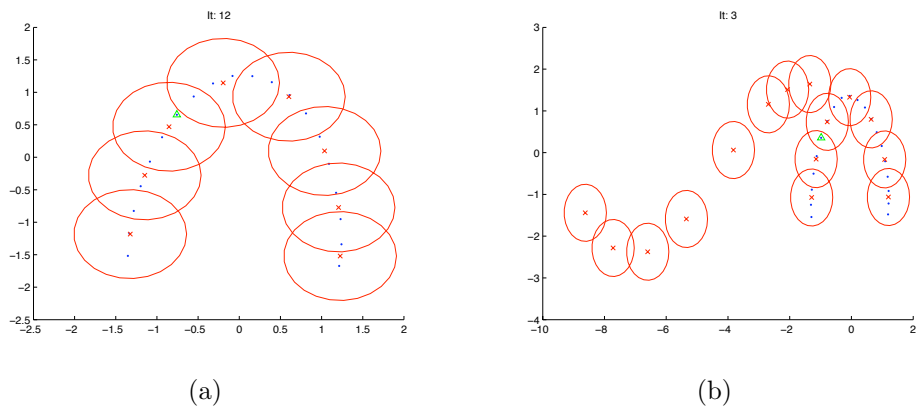


Figura 5.2: *Clusters* formados com o critério de 1,5 vezes a primeira moda na marcação 190° : (a) final de uma clusterização e, (b) após a transformação para a clusterização seguinte. Os padrões de entrada são os pontos dentro dos *clusters*, dispostos de forma semielipsoidal. O 'x' indica o centro do *cluster*.




Figura 5.3: *Clusters* formados com um ganho na primeira moda para obtenção de ρ , na marcação 190° .





Figura 5.4: Convergências da clusterização do segundo conjunto de espectros com (a) ρ igual 1,5 vezes a primeira moda e (b) ρ igual a 22 vezes a primeira moda. Ambas na marcação 190° e com $\alpha = 0,1$.


espectros a cada parada para nova clusterização. Esta escolha de tamanho de raio de vigilância criou uma dificuldade no acompanhamento pelo número de *clusters*, devido à instabilidade causada pela geração excessivamente numerosa de *clusters*. Além disso, muitos *clusters* são esquecidos durante o processo. Como o objetivo deste trabalho é fazer um acompanhamento do sinal de entrada com a maior sensibilidade possível, esta instabilidade não seria adequada para detectar alterações na natureza estatística do sinal.

Os esquecimentos de muitos *clusters* podem ser explicados pelo fato de que, a cada novo conjunto de 20 espectros clusterizados, a base ortogonal formada pelas duas direções principais obtidas por PCA, que é usada para projeção dos dados de entrada, tende a ser diferente da base obtida no conjunto de espectros anterior. A proposta é que os *clusters* formados ao final de uma etapa de avaliação devam ser passados para a etapa subsequente, objetivando um acompanhamento contínuo do sinal do sonar. Estes *clusters* obtidos ao final de uma clusterização são, então, mapeados para a nova base ortogonal formada pelo novo conjunto de padrões de entrada, antes do início da clusterização do novo trecho de sinal. Devido à possível mudança de coordenadas, frequentemente, a área de cobertura destes *clusters* na nova base passa a não receber mais entradas do novo conjunto, como observado na Figura 5.2(b).


Assim, optou-se por aumentar o valor do raio inicial. A nova escolha foi fazê-lo aproximadamente igual a 6,9, correspondendo à segunda estrutura na distribuição das distâncias, equivalente a uma frequência próxima a 30. Isto é implementado através de um fator de ganho de ρ , que permaneceu sendo calculado de forma automática como a primeira moda do histograma de distâncias. Com esta nova escolha, a área de cobertura dos *clusters* aumentou, de forma que permitiu um acompanha-




(a) Convergência do primeiro conjunto.




(b) Convergência do segundo conjunto.




(c) Convergência do terceiro conjunto.



(d) Convergência do quarto conjunto.



(e) Convergência do quinto conjunto.



(f) Convergência do sexto conjunto.

Figura 5.5: Convergências da clusterização de seis conjuntos consecutivos de espectros com ρ igual a 22 vezes a primeira moda. Marcação 190° e com $\alpha = 0,02$, parada com 50 épocas e esquecimento de 40 épocas.





Figura 5.6: Histograma das distâncias entre os padrões de entrada do primeiro conjunto de 20 espectros da marcação 205°.


mento mais estável do sinal. A Figura 5.3 mostra os *clusters* formados no final de uma das etapas de clusterização (escolhida ao acaso) e suas respectivas áreas de cobertura, quando é utilizado um ganho de 22 no valor da primeira moda. Cabe ressaltar que as distâncias entre os centros \mathbf{d} e o raio de vigilância ρ utilizados pelo algoritmo são distâncias quadráticas. Para se obter as distâncias métricas reais, deve-se retirar a raiz quadrada destes valores. As distâncias observadas nos gráficos serão sempre as distâncias métricas reais. A utilização de distâncias quadráticas, especialmente no caso das distâncias entre os padrões de entrada, permite dar mais peso a padrões que caem mais afastados do centro da distribuição (*outliers*). Esta característica tende a favorecer o sistema de monitoração, que busca acompanhar e identificar, justamente, as alterações no comportamento estatístico dos padrões de entrada.

Outra observação importante no ajuste dos parâmetros do sistema está na curva de aprendizado do treinamento. A Figura 5.4 mostra as curvas de aprendizado nas clusterizações do segundo conjunto de espectros da marcação 190° para os dois valores de ρ testados anteriormente. Pelo resultado instável do treinamento para ρ igual a 22 vezes o valor da primeira moda, concluiu-se que seria necessário reavaliar o fator de aprendizado α .


A partir deste ponto, várias simulações foram feitas com valores de α menores que 0,1, com a finalidade de estabilizar a convergência da clusterização. Resultados aceitáveis em termos de estabilidade foram atingidos com $\alpha = 0,02$. Naturalmente que essa diminuição tornou o treinamento mais lento, sendo necessárias mais épocas para atingir a convergência. Desta forma, foi necessário aumentar o valor do critério




(a) Convergência do primeiro conjunto.




(b) Convergência do segundo conjunto.




(c) Convergência do terceiro conjunto.



(d) Convergência do quarto conjunto.



(e) Convergência do quinto conjunto.



(f) Convergência do sexto conjunto.

Figura 5.7: Convergências da clusterização de seis conjuntos consecutivos de espectros com ρ igual a 22 vezes a primeira moda. Marcação 205^o e com $\alpha = 0,02$, parada com 50 épocas e esquecimento de 40 épocas.

de parada pelo número máximo de épocas, passando de 10 para 50. O número máximo de épocas para esquecimento de *cluster* inativo também foi aumentado de 8 para 40.

A Figura 5.5 mostra as curvas de aprendizado para seis conjuntos consecutivos de espectros da marcação 190°. Percebe-se que mesmo com a diminuição de α , o algoritmo consegue convergir em poucas épocas. Além disso, conclui-se também que o critério de parada por número máximo de épocas poderia ficar em torno de 30, quando a convergência já foi atingida, considerando-se os piores casos, observados nas Figuras 5.5(a), 5.5(b), 5.5(e).

Estendendo o que foi feito para a marcação 205°, mantiveram-se as especificações dos parâmetros $\alpha = 0,02$, ρ obtido com um ganho de 22 no valor da primeira moda do histograma de distâncias entre os padrões de entrada, parada com 50 épocas sem criação de novo *cluster* e 40 épocas para esquecimento de *cluster* inativo. A Figura 5.6 mostra o histograma das distâncias entre os padrões de entrada para o primeiro conjunto de 20 espectros. O valor de ρ ficou em, aproximadamente, 7,0. A Figura 5.7 mostra os resultados obtidos para as curvas de aprendizado dos primeiros seis conjuntos de espectros da marcação 205°. De forma análoga aos resultados da marcação 190°, o treinamento poderia ser encerrado com 30 épocas sem prejuízo para a convergência.

5.3 Testes de Desempenho

Estes testes buscaram avaliar se o acompanhamento feito pelo sistema de monitoração está indicando corretamente os momentos que possam ter ocorrido alguma alteração no comportamento estatístico do sinal. Para isso, os sinais das marcações 190° e 205 são avaliados pelo sistema de monitoração, que indica se houve alguma mudança a partir da avaliação de um conjunto de parâmetros da clusterização dos espectros do sinal. O sistema de redução de interferências estima uma matriz de separação das misturas (sinais das marcações) através de ICA, como foi mostrado no Capítulo 3. Através da inspeção visual do espectrograma do sinal, do espectro médio e do cálculo da informação mútua entre as fontes estimadas, os resultados são analisados para verificação da eficiência da separação. Como foi visto no Capítulo 3, os algoritmos de ICA utilizam as estatísticas do sinal, sobretudo, a *kurtosis*, para fazer a estimação do modelo de separação. Porém, se estas estatísticas sofrerem variação no tempo, o modelo de separação deixa de ser o ótimo, podendo se afastar consideravelmente desta condição ótima. Neste caso, o sistema de monitoração faria o acompanhamento do sinal e daria uma indicação para o sistema de separação de interferências que, baseado nesta indicação, poderia re-estimar o modelo.

5.3.1 Indicadores do Sistema de Monitoração

A indicação de alterações no comportamento estatístico do sinal monitorado pelo sistema é feita com base nos *clusters* formados a cada intervalo para avaliação. O sistema acompanha e avalia os seguintes parâmetros:

- Número de *clusters* formados;
- Dispersão *intracluster*
- Dispersão *extracuster*;

No caso do primeiro parâmetro, o índice é gerado com base na ocorrência de variação do número de *clusters* entre avaliações. Já o segundo e o terceiro parâmetros, menos óbvios, são responsáveis por índices calculados a partir de duas matrizes, definidas em [46], a matriz de espalhamento *intracluster* \mathbf{S}_W e a matriz de espalhamento *entrecluster* \mathbf{S}_B , dadas pelas Equações 5.5 e 5.6.

$$\mathbf{S}_W = \sum_i^c \mathbf{S}_i = \sum_i^c \sum_{\mathbf{x} \in D_i} (\mathbf{x} - \mathbf{m}_i)(\mathbf{x} - \mathbf{m}_i)^T, \quad (5.5)$$

onde $\mathbf{x} \in D_i$ representa todos os dados pertencentes ao *cluster* i , \mathbf{m}_i , o vetor médio dos dados $\mathbf{x} \in D_i$ e c o número de *clusters*.

$$\mathbf{S}_B = \sum_i^c n_i (\mathbf{m}_i - \mathbf{m})(\mathbf{m}_i - \mathbf{m})^T, \quad (5.6)$$

onde n_i é o número de dados no *cluster* i e \mathbf{m} representa o vetor médio de todo conjunto de dados D .

DUDA *et al.* [46] definem o traço (somatório dos elementos da diagonal principal) das matrizes \mathbf{S}_W e \mathbf{S}_B como uma medida escalar para ambas. Sendo assim, os traços de ambas as matrizes serão utilizados como índices para acompanhar o comportamento estatístico dos espectros do sinal do sonar.

Observa-se que a matriz \mathbf{S}_W , na Equação 5.5, a menos do fator multiplicativo $1/(n-1)$, se comporta como uma matriz de covariância [57]. Desta forma, outro índice a ser acompanhado, conhecido como *crossstalk*, será gerado a partir da matriz \mathbf{S}_W . O valor do *crossstalk* é obtido a partir da soma dos valores absolutos dos elementos fora da diagonal principal. O *crossstalk* possui informação sobre a correlação entre distintas dimensões dos dados de entrada [57]. No caso da matriz \mathbf{S}_W , assim como a matriz de covariância, por ela ser simétrica em relação à diagonal principal, basta que se utilize, no cálculo do *crossstalk*, a soma dos quadrados dos elementos da parte superior direita ou inferior esquerda da matriz, excluindo-se os elementos

da diagonal principal. Tanto a obtenção das matrizes de espalhamento aqui definidas, como do *crossstalk*, são de fácil implementação e baixo custo computacional, caracterizando-se por somas e multiplicações e corridas em matrizes.

5.3.2 Intervalo entre Avaliações

Na Seção 5.2, foi justificada a necessidade de se utilizar um intervalo de 20 ao invés de 10 segundos. Com 20 segundos, um conjunto de 40 espectros é disponibilizado pela análise DEMON. Foi mostrado que devido à forma de obtenção dos espectros através da aplicação da STFT com *overlap*, este é o número mínimo de espectros disponíveis, sem que haja perda de informação do sinal temporal [4]. Do ponto de vista estatístico, um número maior de amostras fica disponível para representar o espaço do conjunto de espectros. A partir deste ponto, os resultados são gerados com conjuntos de 40 espectros, ou seja, o intervalo entre paradas para avaliação do sistema de monitoração passa a ser de 20 segundos.

5.3.3 Obtenção das Figuras de Mérito

Para avaliar o comportamento estatístico do sinal com uso das figuras de mérito informação mútua e cumulantes cruzados apresentadas na Seção 4.4, foram adotadas as seguintes estratégias:

- **Informação mútua:**

- Divide-se o conjunto de espectros completo de cada mistura (marcação), em 10 janelas de 40 espectros cada (aprox. 20 segundos).
- Obtém-se o espectro médio de cada janela, resultando um vetor de dimensão 1 x 513.
- Calcula-se a informação mútua entre o vetor médio da primeira janela e o vetor médio da segunda, entre o vetor médio da primeira e o vetor médio da terceira, assim sucessivamente até a décima janela.
- Gera-se um vetor com 9 medidas de informação mútua para cada mistura.

Este procedimento é aplicado a cada marcação. O mesmo é feito com as fontes estimadas pelo modelo de separação, conforme foi descrito na Seção 3.3.1, com a diferença de que não é necessário tirar a média das fontes, já que é obtida uma fonte para cada uma das três misturas utilizadas na extração das fontes, totalizando três fontes. Neste caso da estimação das fontes, a matriz \mathbf{B} de separação é obtida, através do algoritmo Akuzawa, com o primeiro conjunto de espectros, e a separação das demais fontes é realizada com esta primeira matriz de separação.

- **Cumulantes cruzados:**

- Em cada uma das 10 janelas, calcula-se o cumulante cruzado de quarta ordem entre os vetores dos espectros médios de cada mistura, resultando em três medidas em cada janela dos seguintes cruzamentos de misturas: $190^\circ \times 205^\circ$, $205^\circ \times 76^\circ$ e $190^\circ \times 76^\circ$.
- Gera-se um vetor com 10 medidas de cumulantes cruzados para cada cruzamento de misturas.


O mesmo procedimento é feito sobre as fontes extraídas por ICA.

A Figura 5.8(a) mostra o resultado do cálculo da informação mútua para as misturas. Observa-se uma maior variação no caso da mistura correspondente à marcação 205° . A marcação 76° , que representa o ruído próprio da embarcação, permanece praticamente inalterada durante todo o trecho de sinal avaliado. A Figura 5.8(b) mostra o resultado do cálculo da informação mútua aplicado às fontes extraídas por ICA. Percebe-se que o comportamento observado nas fontes extraídas permanece quase idêntico ao apresentado pelas misturas. Este resultado demonstra que fazer a monitoração a partir dos sinais das marcações já é suficiente para acompanhar as variações estatísticas do sinal do sonar passivo, ao menos com esta base de dados. Apesar das variações serem pequenas em termos percentuais, inclusive em certos trechos da mistura 205° , que apresenta as maiores variações, espera-se que o sistema de monitoração seja capaz de dar alguma indicação a respeito.


O resultado dos cálculos dos cumulantes cruzados pode ser observado na Figura 5.9. Percebe-se que, pelo critério de independência com base nos cumulantes cruzados de quarta ordem, as misturas, como era de se esperar, apresentam dependência entre si, conforme a Figura 5.9(a). Após a extração das fontes por ICA, o resultado da Figura 5.9(b) evidencia que, mesmo com as variações no comportamento estatístico mostrado pelos cálculos da informação mútua da Figura 5.8, a matriz de separação obtida na primeira janela consegue extrair fontes independentes. Esta independência estatística é assumida com base no critério dos cumulantes cruzados de quarta ordem, de acordo com o que foi provado em [58].

5.3.4 Resposta do Sistema

Uma vez calculadas as figuras de mérito, as respostas do sistema de monitoração puderam ser obtidas e avaliadas. Devido ao aumento do número de padrões de entrada de 20 para 40 espectros, correspondendo a um aumento no intervalo de tempo entre avaliações de, aproximadamente, 10 para 20 segundos, um novo histograma de distâncias entre os padrões de entrada foi gerado pelo sistema. A partir deste novo histograma, é feita nova escolha do raio de vigilância inicial. A Figura 5.10 mostra




(a) Misturas.

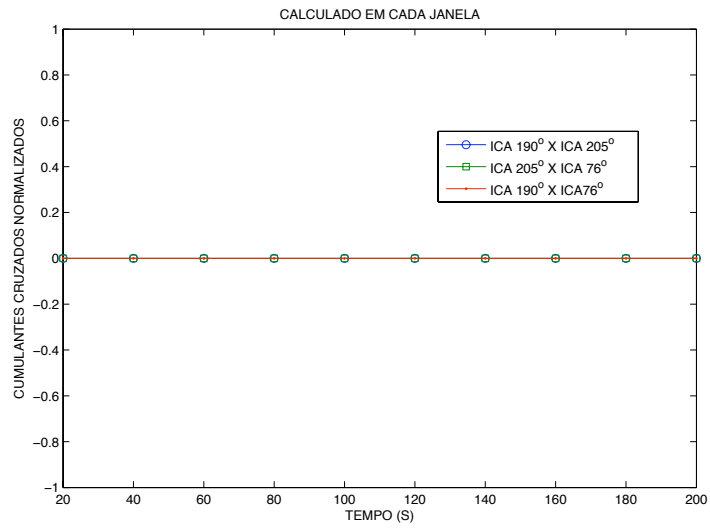


(b) Fontes extraídas.

Figura 5.8: Evolução da informação mútua entre a primeira janela e as janelas subsequentes para as misturas 5.8(a) e para as fontes extraídas por ICA 5.8(b).



(a) Misturas.



(b) Fontes extraídas.

Figura 5.9: (a) Evolução dos cumulantes cruzados entre marcações e (b) fontes extraídas por ICA.

os histogramas gerados para os primeiros conjuntos de 40 espectros das marcações 190° e 205° .




Figura 5.10: Histogramas das distâncias entre os padrões de entrada do conjunto de 40 espectros.

Observa-se que o critério de escolha do raio de vigilância ρ , com as distribuições exibidas pelas distâncias entre os padrões de entrada em ambas as marcações, deve passar a ser a maior moda. Neste caso, como o valor de ρ tem influência direta nos resultados da clusterização, buscou-se avaliar vários valores de ganho aplicado ao valor da maior moda, em uma faixa de $(1, 0$ a $1, 5)$, em passos de $0, 1$. Com este aumento de padrões de entrada, foram necessários 4 componentes principais para atingir um limiar mínimo de energia de 93%. O valor do limiar foi aumentado, pois com o valor anterior de 90%, o número de componentes não ficava constante ao longo de todo trecho de sinal. Quando isto acontece, o sistema deve reiniciar a monitoração, uma vez que há um aumento na dimensão dos dados de entrada. Os demais parâmetros de sintonia foram mantidos os mesmos que foram especificados na Seção 5.2.

Para cada valor de ganho, o sistema foi acionado para realizar cinco avaliações de cada marcação, gerando-se cinco vetores lógicos de indicação do comportamento da estatística do sinal monitorado, com base no número de *clusters* criados. No caso, para criação dos vetores lógicos, se o acompanhamento mostrar que houve mudança no número de *clusters*, para mais ou para menos, o nível lógico “1” é setado, indicando que houve mudança na estatística, caso contrário, é setado o nível lógico “0”. Estes vetores lógicos são comparados com as figuras de mérito, para computação das medidas de desempenho do sistema, sobretudo, as probabilidades de detecção, falso alarme e perda do alvo. Como a rede ART é sensível à inicialização, seus resultados finais podem variar, desta forma, para cada valor de ganho, é selecionado o melhor resultado, dentre as cinco rodadas, que maximize a probabilidade de detecção.

Nesta avaliação do efeito da variação de ρ , foi utilizada como figura de mérito

Tabela 5.1: Saídas lógicas que maximizam a probabilidade de detecção em função do ρ , na marcação 190°. Todas as variações na informação mútua são consideradas mudanças.

ρ_i/S_j	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	<i>Acertos</i>	<i>Acertos (%)</i>
$\rho_1 = 1, 0.moda$	1	1	0	1	1	1	1	0	6	75
$\rho_2 = 1, 1.moda$	0	1	1	0	0	0	1	1	4	50
$\rho_3 = 1, 2.moda$	1	1	0	0	0	1	1	1	5	63
$\rho_4 = 1, 3.moda$	0	0	1	0	0	1	1	1	4	50
$\rho_5 = 1, 4.moda$	1	1	1	0	0	1	1	0	5	63
$\rho_6 = 1, 5.moda$	1	0	0	0	0	1	1	1	4	50

Tabela 5.2: Saídas lógicas que maximizam a probabilidade de detecção em função do ρ , na marcação 190°. Apenas variações maiores que 2% na informação mútua são consideradas mudanças.

ρ_i/S_j	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	<i>Acertos</i>	<i>Acertos (%)</i>
$\rho_1 = 1, 0.moda$	1	0	0	1	1	1	1	0	5	63
$\rho_2 = 1, 1.moda$	0	0	0	0	0	1	1	0	8	100
$\rho_3 = 1, 2.moda$	0	0	0	0	0	1	1	0	8	100
$\rho_4 = 1, 3.moda$	0	0	0	0	0	1	1	1	7	88
$\rho_5 = 1, 4.moda$	0	0	0	0	0	1	1	1	7	88
$\rho_6 = 1, 5.moda$	0	0	1	0	0	1	1	0	7	88
Var. <i>I (%)</i>	0,2	0,8	1,6	0,7	1,0	3,6	2,6	0,7	-	-

Tabela 5.3: Saídas lógicas que maximizam a probabilidade de detecção em função do ρ , na marcação 205°. Todas as variações na informação mútua são consideradas mudanças.

ρ_i/S_j	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	<i>Acertos</i>	<i>Acertos (%)</i>
$\rho_1 = 1, 0.moda$	0	1	1	0	1	1	0	1	5	63
$\rho_2 = 1, 1.moda$	1	1	1	1	0	1	1	1	7	88
$\rho_3 = 1, 2.moda$	1	1	1	1	0	1	1	1	7	88
$\rho_4 = 1, 3.moda$	1	1	1	0	0	1	1	1	6	75
$\rho_5 = 1, 4.moda$	1	1	1	1	0	1	1	0	6	75
$\rho_6 = 1, 5.moda$	1	1	1	0	0	1	1	1	6	75

Tabela 5.4: Saídas lógicas que maximizam a probabilidade de detecção em função do ρ , na marcação 205°. Apenas variações maiores que 2% na informação mútua são consideradas mudanças.

ρ_i/S_j	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	Acertos	Acertos (%)
$\rho_1 = 1, 0.moda$	0	1	1	0	1	1	0	1	5	63
$\rho_2 = 1, 1.moda$	1	1	1	1	0	1	1	1	5	63
$\rho_3 = 1, 2.moda$	1	1	1	1	0	1	1	1	6	75
$\rho_4 = 1, 3.moda$	1	1	1	0	0	1	1	1	4	50
$\rho_5 = 1, 4.moda$	1	1	1	1	0	1	1	0	4	50
$\rho_6 = 1, 5.moda$	1	1	1	0	0	1	1	1	4	50
Var. I (%)	4,2	0,8	5,0	9,4	2,2	6,8	0,6	5,7	-	-

as curvas de evolução da informação mútua das misturas, mostradas na Figura 5.8(a). Esta escolha é razoável, no sentido de que o sistema de monitoração está operando com os espectros dos sinais das marcações (misturas). As Tabelas 5.1, 5.2, 5.3 e 5.4 mostram os resultados das análises. Para cada marcação, foram obtidos os vetores lógicos de acompanhamento da estatística, segundo a evolução do número de *clusters*. Cada vetor é o que apresentou a maior probabilidade de detecção correta dentre 5 outros. Em cada tabela, estão computadas as quantidades de acertos de cada vetor lógico e os respectivos percentuais, considerando um total de 8 indicações. Devido às variações da informação mútua somente estarem disponíveis a partir de 40 segundos, os vetores lógicos são gerados a partir do instante que é possível computar a primeira variação entre avaliações, neste caso de 40 para 60 segundos. Por este motivo, os vetores lógicos só possuem 8 valores disponíveis, que correspondem às variações em intervalos de 20 segundos até o final do sinal, em 200 segundos.

As Tabelas 5.1 e 5.3 contêm os resultados que consideram que qualquer variação no valor da informação mútua da marcação (Figura 5.8(a)), por menor que seja, é tomada como uma mudança na estatística. Com esta consideração, o caso da marcação 190° é o mais crítico, já que em apenas dois intervalos, 140-160 e 160-180 segundos, as variações não superam 2%, ainda assim, não muito mais do que isto, sequer chegando aos 2,5%. Nestas situações, as melhores probabilidades de detecção foram obtidas com $\rho_3 = 1, 2.moda$, para a marcação 190°, e com $\rho_2 = 1, 1.moda$ e $\rho_3 = 1, 2.moda$, para a marcação 205°.

Uma outra comparação foi realizada, considerando-se que as variações no valor da informação mútua menores que 2%, não são tomadas como indicativo de alterações no comportamento estatístico do sinal da marcação. Estes resultados são apresentados nas Tabelas 5.2 e 5.4. Os valores percentuais da variação da informação mútua são mostrados na última linha das tabelas, para fins de obtenção

Tabela 5.5: Combinação das saídas lógicas das marcações, para $\rho = 1,2.moda$, através da lógica “OU”. Todas as variações na informação mútua são consideradas mudanças.

Saídas Lógicas	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	<i>Acertos</i>	%
S_{m190°	1	1	0	0	0	1	1	1	5	63
S_{m205°	1	1	1	1	0	1	1	1	7	88
$S = S_{m190^\circ} \text{OU} S_{m205^\circ}$	1	1	1	1	0	1	1	1	7	88

Tabela 5.6: Combinação das saídas lógicas das marcações, para $\rho = 1,2.moda$, através da lógica “OU”. Apenas variações maiores que 2% na informação mútua são consideradas mudanças.

Saídas Lógicas	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	<i>Acertos</i>	%
S_{m190°	0	0	0	0	0	1	1	0	8	100
S_{m205°	1	1	1	1	0	1	1	1	6	75
$S = S_{m190^\circ} \text{OU} S_{m205^\circ}$	1	1	1	1	0	1	1	1	6	75

das probabilidades de detecção. Em ambas as marcações, as maiores probabilidades de detecção corretas foram obtidas para $\rho_2 = 1,1.moda$ e $\rho_3 = 1,2.moda$. Desta forma, considerando-se todos os resultados obtidos, o raio de vigilância que apresentou maiores probabilidades de detecção foi para $\rho_3 = 1,2.moda$.

Numa situação real, cada marcação estaria sendo monitorada em paralelo pelo sistema de monitoração. Desta forma, seria possível indicar para o OS, de maneira independente, através dos vetores lógicos, as mudanças no comportamento estatístico de cada marcação. Entretanto, seria interessante que os vetores lógicos pudessem ser combinados de forma que apenas uma indicação lógica fosse capaz de informar ao OS do Sonar se houve alguma alteração.

Fazendo uso da operação lógica “OU”, e combinando-se os resultados dos melhores casos das Tabelas 5.1, 5.2, 5.3 e 5.4, para $\rho = 1,2.moda$, foram obtidas as saídas lógicas das Tabelas 5.5 e 5.6. No caso em que todas as variações na informação mútua são consideradas como mudança na estatística, a lógica “OU” combinando os vetores lógicos das duas marcações melhora a eficiência da detecção. O mesmo não ocorre para quando se considera apenas as variações na informação mútua acima de 2%. Neste último caso, conforme a Tabela 5.6, uma combinação lógica “E” funcionaria melhor. Entretanto, como não é possível tomar esta decisão em tempo real, é mais interessante utilizar uma combinação lógica “OU” para fornecer apenas um vetor lógico de indicação de mudança do comportamento estatístico dos sinais das marcações em conjunto.

Esta avaliação que considera que o sistema detecta variações maiores que 2% é

mais razoável do que aquela na qual ele detecta qualquer variação. Nesta última, seria necessário um sistema com processadores de precisão infinita, o que não existe em implementações práticas. Desta forma, o desempenho do sistema de monitoração terá como base os resultados obtidos na Tabela 5.6. Considerando um patamar de 2% de variação no valor da informação mútua, o melhor resultado atingiu uma eficiência de detecção correta de 75%.

Para a estimação da matriz de separação das misturas por ICA, os sinais das duas marcações, 190° e 205°, são utilizadas em conjunto pelo algoritmo de estimação, que pode também utilizar o ruído próprio (76°). Tanto variações estatísticas das duas marcações como de uma ou de outra, isoladamente, podem afetar a qualidade da separação por ICA. Desta forma, a utilização da combinação lógica dos vetores de resposta do sistema de monitoração é interessante.

As respostas do sistema para os vetores lógicos da Tabela 5.5, em termos do acompanhamento do número de *clusters*, do traço e do *crosstalk* das matrizes S_W e S_B , são mostradas nas Figuras 5.11 e 5.12, respectivamente para as marcações 190° e 205°. Para facilitar a visualização, a variação da informação mútua é mostrada novamente. Percebe-se que os valores dos traços das matrizes S_W e S_B também poderiam ser utilizados para geração dos vetores lógicos. A única diferença entre as matrizes é que a matriz S_B guarda relação direta com o número de *clusters* criados, ao contrário da matriz S_W , cuja relação com o aumento ou a diminuição do número de *clusters* é inversa. Em termos numéricos, as matrizes possuem os elementos fora da diagonal principal iguais a menos do sinal trocado, enquanto que os elementos das diagonais principais são distintos, como pode ser visto nos exemplos abaixo obtidos em determinado instante do acompanhamento:

$$S_{W_k} = \begin{pmatrix} 4.0983 & 2.4873 & -1.6415 & 3.7049 \\ 2.4873 & 31.1192 & 10.5843 & 8.1679 \\ -1.6415 & 10.5843 & 24.7002 & -11.2828 \\ 3.7049 & 8.1679 & -11.2828 & 29.3775 \end{pmatrix}$$


$$S_{B_k} = \begin{pmatrix} 34.9017 & -2.4873 & 1.6415 & -3.7049 \\ -2.4873 & 7.8808 & -10.5843 & -8.1679 \\ 1.6415 & -10.5843 & 14.2998 & 11.2828 \\ -3.7049 & -8.1679 & 11.2828 & 9.6225 \end{pmatrix}$$

Porém, como a geração dos vetores lógicos independe do fato se a variação foi para mais ou para menos, o valor do traço de ambas as matrizes pode ser utilizado. A relação complementar entre essas matrizes é conhecida. Os processos de clusterização que as utilizam como critério de otimização, caso utilizem como meta a minimização de S_W , fatalmente estarão maximizando S_B . Isto ocorre devido ao


fato de S_W e S_B estarem relacionadas com a matriz de espalhamento total de todo o conjunto de dados S_T segundo a Equação 5.7.

$$S_T = S_W + S_B, \quad (5.7)$$


onde S_T não depende dos *clusters* formados, ao contrário de S_W e S_B [46]. Quanto ao *crosstalk*, nenhuma correlação com a variação da estatística do sinal foi encontrada.




(a) Informação mútua das misturas.




(b) Número de *clusters*.




(c) Traço de S_B .



(d) Traço de S_W .




(e) *Crosstalk* de S_B .




(f) *Crosstalk* de S_W .

Figura 5.11: Acompanhamento do número de *clusters*, do traço e do *crosstalk* das matrizes S_W e S_B . Marcação 190°.


Com relação à figura de mérito cumulantes cruzados, a Tabela 5.7 mostra a obtenção do desempenho do sistema de monitoração com base na combinação lógica




(a) Informação mútua das misturas.



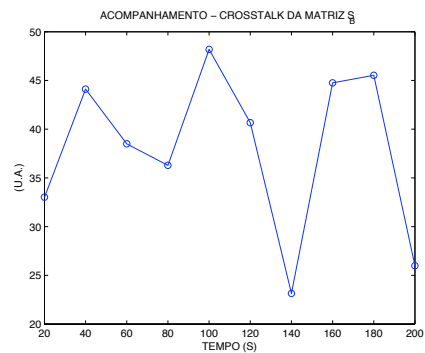
(b) Número de *clusters*.



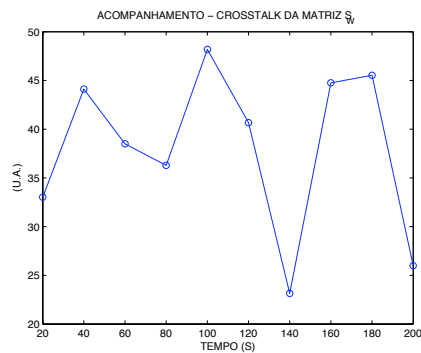
(c) Traço de S_B .



(d) Traço de S_W .



(e) *Crosstalk* de S_B .



(f) *Crosstalk* de S_W .

Figura 5.12: Acompanhamento do número de *clusters*, do traço e do *crosstalk* das matrizes S_W e S_B . Marcação 205°.

Tabela 5.7: Combinação lógica para detecção de mudanças maiores que 2% nos cumulantes cruzados (entre marcações 190° e 205°).

S. Lóg.	S_0	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	Ac.	%
S_{m190°	0	0	0	0	0	0	1	1	0	2	22
S_{m205°	1	1	1	1	1	0	1	1	1	8	89
OU	1	1	1	1	1	0	1	1	1	8	89
Var. μ_{cum}^4 (%)	1085,4	178,1	1770,1	14,3	97,4	10,8	19,4	99,6	330,0	-	-

da resposta da monitoração do sistema das marcações 190° e 205°. Neste caso, a probabilidade de detecção correta do sistema de monitoração atinge 89%. A variação percentual dos cumulantes cruzados, indicada na última linha da Tabela 5.7, é calculada a partir dos valores dos cumulantes entre as marcações 190° e 205°, mostrados na Figura 5.9(a).

5.4 Efeitos de ICA para Classificação Neural

O efeito da utilização de ICA na etapa de pré-processamento do sinal de sonar passivo, visando diminuir a interferência entre marcações e atenuar o ruído de fundo, vem sendo alvo de investigação [3, 11, 13, 59]. Os resultados destes trabalhos vem consolidando o uso de ICA para melhorar a eficiência da detecção e classificação de contatos. Nesta seção, será apresentado um trabalho desenvolvido no escopo desta dissertação, onde se buscou projetar um classificador neural para identificação de contatos detectados pelo sistema de sonar passivo [17]. O efeito da aplicação de ICA no pré-processamento dos sinais de entrada do classificador também foi avaliado, a partir da comparação da eficiência da classificação com e sem aplicação da ICA. Os três algoritmos de ICA apresentados na Seção 3.3 foram avaliados, para efeitos de comparação de desempenho da classificação. Essa avaliação buscou comprovar a importância do sistema de monitoração da estatística do sinal de sonar passivo para a classificação de contatos, uma vez que o sistema poderá subsidiar a tomada de decisão de re-estimar os modelos neurais de classificação.

5.4.1 Metodologia

A base de dados para o treinamento do classificador consistiu de gravações de ruídos irradiados por navios nas marcações 190° e 205°. Adicionalmente, o áudio do ruído próprio gravado na marcação 76° também foi utilizado, porém somente para a etapa de pré-processamento com ICA, com o objetivo de se verificar o efeito da inclusão do ruído próprio na estimação da matriz de separação feita pela análise ICA. O

classificador também é avaliado sem a inclusão do ruído próprio. Tanto os ruídos irradiados pelos navios, como o ruído próprio consistem em gravações de pouco mais do que 200 segundos de duração. Estes sinais foram processados de forma a se obter os espectros que serão utilizados como dados de entrada do classificador neural. Para isto, utilizou-se a análise LOFAR, conforme o diagrama da Figura 3.1 da Seção 3.1.1. Os espectros foram gerados a partir da aplicação da STFT de 2048 pontos sem *overlap*, sendo normalizados pela aplicação do algoritmo TPSW.

O classificador neural utilizado para discriminar as classes é uma rede neural perceptron multicamadas (MLP, em inglês) [7]. A camada de entrada da rede é alimentada pelos pontos dos espectros obtidos pela análise LOFAR. Todos os neurônios das camadas escondida e de saída possuem função de ativação do tipo tangente hiperbólica. A rede neural foi treinada com o algoritmo de aprendizado supervisionado *backpropagation* resiliente [60]. Este algoritmo apresentou menor custo computacional que o *backpropagation* tradicional e que outros algoritmos em uma série de simulações, além de uma maior robustez frente à escolha inicial dos parâmetros de treinamento.

Os sinais das marcações 190° e 205° foram divididos em conjuntos de treino, validação e teste. Inicialmente, do total de 6.880 espectros obtidos pela análise LOFAR, selecionou-se um trecho para treinamento (75% do total) e um trecho para teste (25% do total), ou seja, um conjunto de 5.160 espectros para treino e um conjunto de 1.720 espectros para teste, igualmente divididos para cada marcação. Esta seleção foi feita de forma intercalada, ou seja, a cada quatro padrões sequenciais, os três primeiros foram tomados para treino e o quarto, para teste, sucessivamente, até o final do conjunto. Dos 5.160 espectros de treino, 1.290 (o subconjunto inicial de 25% do conjunto de treino) são utilizados como conjunto de validação, divididos igualmente entre as classes. Desta forma, o treinamento da rede neural é feito com um conjunto de 3.870 espectros, a validação é feita com um conjunto de 1.290, para avaliação do critério de parada, e o teste é feito com um conjunto de 1.720, que são usados para analisar a generalização do classificador e calcular a eficiência de classificação, não sendo utilizados na etapa de atualização dos pesos da rede. Para cada espectro de entrada, foi associado o valor 1 ou -1 para a saída desejada, conforme a classe que se desejasse classificar. Ao final do treinamento, a taxa de acerto foi calculada considerando um limiar de decisão centrado em zero.

O classificador foi treinado inicialmente utilizando-se apenas a análise LOFAR no pré-processamento (sem a introdução do bloco ICA). Com esta configuração, foi feita a definição do número de neurônios na camada escondida. Os espectros aplicados na entrada do classificador são gerados diretamente a partir dos sinais de áudio das marcações 190° e 205° , proveniente do conformador de feixes, conforme o diagrama em blocos da Figura 5.13.




Figura 5.13: Diagrama em blocos do sistema de classificação com LOFAR no pré-processamento [17].

A dimensão do espaço de entrada da rede neural são os 1025 pontos dos espectros gerados pela análise LOFAR. No trabalho, não se buscou utilizar nenhuma técnica para redução de dimensionalidade, se fixando apenas em avaliar os efeitos da ICA no pré-processamento dos dados para classificação. Em [14], foram avaliadas diferentes técnicas de redução de dimensionalidade e seus efeitos no projeto de um classificador neural MLP. Um total de quatro neurônios na camada escondida foi utilizado, a partir da observação da taxa de acerto em uma média de cinco rodadas de treinamento. A Figura 5.14 mostra que 4 neurônios na camada escondida é uma escolha adequada, pois para 6 neurônios, apesar da taxa de acerto média ser 0,2% maior, isto representa muito pouco frente à menor complexidade do modelo com dois neurônios a menos na camada escondida. Para a camada de saída, utilizou-se apenas um neurônio, já que se tratou de uma discriminação de duas classes. Sendo assim, o classificador neural foi treinado em bateladas com uma estrutura 1025 x 4 x 1, com normalização dos padrões de entrada para conter variáveis padronizadas, tendo como critérios de parada, variações mínimas da eficiência de classificação, dos pesos sinápticos e, caso nenhum dos primeiros fossem atingidos, um número máximo de iterações.

Em [11], os autores obtiveram resultados promissores, mostrando que a aplicação de ICA no pré-processamento dos sinais do sonar passivo melhorou a eficiência da classificação neural, devido à diminuição do efeito da interferência mútua entre marcações próximas. O autor utilizou o algoritmo JADE e uma matriz de mistura sintética para avaliação, porém aplicados a marcações diferentes das que foram utilizadas no presente trabalho, e não sendo utilizado o ruído próprio.

No trabalho, além do algoritmo JADE, buscou-se avaliar também os algoritmos Akuzawa e FastICA como técnica de pré-processamento para atenuação do ruído de fundo e diminuição do efeito da interência entre contatos. Estes algoritmos foram aplicados nas amostras temporais do sinal do sonar passivo antes da análise LOFAR. Outro detalhe adicional deste trabalho foi a inclusão do ruído próprio na etapa de




Figura 5.14: Taxa de acerto média X Número de neurônios na camada escondida.

estimação da matriz de separação através de ICA. O ruído próprio, em conjunto com o ruído ambiente do fundo do mar, compõe o ruído de fundo que está presente como interferência entre marcações, o que será mostrado em detalhes na Seção 3.4.

O diagrama em blocos da Figura 5.15 mostra como funciona o sistema, incluindo a marcação 76°, que contém o áudio do ruído próprio, e a ICA para pré-processamento. A seleção da marcação após a aplicação de ICA é feita com base no valor da informação mútua [56] entre as marcações originais e as estimadas por ICA. A utilização de informação mútua (pelo método do histograma) para seleção correta da marcação estimada pela ICA se faz necessária devido ao fato de que as fontes estimadas por ICA não mantêm a ordenação em que são apresentadas ao algoritmo ICA. O coeficiente de correlação linear [57] chegou a ser avaliado como forma de seleção da marcação, porém não apresentou consistência nos resultados. Isto pode ser explicado pela existência de correlações de natureza não-lineares nos dados dos sinais de sonar passivo [14].




Figura 5.15: Diagrama em blocos do sistema de classificação com ICA + LOFAR no pré-processamento. A marcação 76° representa o ruído próprio.

5.4.2 Resultados

Conforme foi explicado na Seção 5.4.1, somente o conjunto de treino foi utilizado para estimação da matriz de separação do modelo ICA. No momento de operar o sistema, esta matriz de separação obtida para o conjunto de treino é aplicada ao conjunto de teste, de forma a garantir a generalização do pré-processamento ICA. Estratégia análoga foi utilizada na normalização dos padrões de entrada do classificador, onde a média e o desvio padrão de cada variável do conjunto de treino são armazenados para posterior normalização dos padrões do conjunto de teste. Essa normalização consiste na subtração da média e na divisão pelo desvio padrão de cada dimensão (coluna da matriz) dos padrões de teste, usando os valores armazenados obtidos a partir do conjunto de treino.

A primeira avaliação do desempenho da rede neural após o treinamento, considerando todas as configurações testadas, foi realizada a partir dos histogramas das saídas obtidas quando a rede é colocada em operação utilizando o conjunto de teste. As Figuras 5.16, 5.17, 5.18 e 5.19 mostram os histogramas das saídas das redes treinadas quando se utiliza o pré-processamento LOFAR, LOFAR + ICA (Akuzawa), LOFAR + ICA (JADE) e LOFAR + ICA (FastICA), respectivamente. Cada histograma mostra as saídas da rede para os dados de teste da classe 1 (esquerda) e da classe 2 (direita). As Tabelas 5.8, 5.9, 5.10 e 5.11 mostram as taxas de acerto e os erros de classificação para cada classe.

O desempenho das diferentes configurações testadas está resumido na Tabela 5.12, que faz uma comparação das taxas de acerto obtidas pela operação do classificador com um conjunto de teste selecionado. O classificador treinado com o pré-processamento ICA baseado no algoritmo FastICA apresentou desempenho superior.

O efeito da retirada do ruído próprio (marcação 76°) da etapa de pré-processamento foi testado observando-se a eficiência obtida pelo classificador com a configuração de melhor desempenho (LOFAR + ICA (FastICA)). Os resultados são mostrados pela Tabela 5.12. Neste caso, a taxa de acerto foi de 88,5%, considerando o mesmo número de neurônios na camada escondida. O mesmo teste foi feito para os algoritmos JADE e Akuzawa. Para o primeiro, a taxa de acerto foi de 87,6% e para o segundo, 80,9%.

Tabela 5.8: Tabela de confusão para a rede treinada com pré-processamento LOFAR.

Taxa (%)	rede (classe 1)	rede (classe 2)
classe 1	85,3	14,7
classe 2	18,2	81,8




Figura 5.16: Histogramas das saídas da rede treinada com pré-processamento LO-FAR: classe 1 (esquerda) e classe 2 (direita). Taxa de acerto de 83,6%.




Figura 5.17: Histogramas das saídas da rede treinada com pré-processamento LO-FAR + ICA (Akuzawa): classe 1 (esquerda) e classe 2 (direita). Taxa de acerto de 78,7%.




Figura 5.18: Histogramas das saídas da rede treinada com pré-processamento LO-FAR + ICA (JADE): classe 1 (esquerda) e classe 2 (direita). Taxa de acerto de 87,0%.

Tabela 5.9: Tabela de confusão para a rede treinada com pré-processamento LOFAR + ICA (Akuzawa).

Taxa (%)	rede (classe 1)	rede (classe 2)
classe 1	81,2	18,8
classe 2	23,8	76,2




Figura 5.19: Histogramas das saídas da rede treinada com pré-processamento LO-FAR + ICA (FastICA): classe 1 (esquerda) e classe 2 (direita). Taxa de acerto de 88,1%.

Tabela 5.10: Tabela de confusão para a rede treinada com pré-processamento LO-FAR + ICA (JADE).

Taxa (%)	rede (classe 1)	rede (classe 2)
classe 1	89,1	10,9
classe 2	15,0	85,0

Tabela 5.11: Tabela de confusão para a rede treinada com pré-processamento LO-FAR + ICA (FastICA).

Taxa (%)	rede (classe 1)	rede (classe 2)
classe 1	89,2	10,8
classe 2	13,0	87,0

Tabela 5.12: Comparação das eficiências das configurações testadas.

Pré-processamento	Eficiência (%) c/ ruído próprio	Eficiência (%) s/ ruído próprio
LOFAR	—	83,6
LOFAR + Akuzawa	78,7	80,9
LOFAR + JADE)	87,0	87,6
LOFAR + FastICA	88,1	88,5

Capítulo 6

Conclusões e Perspectivas

O sinal do sonar passivo apresenta característica não estacionária, ou seja, sua estatística varia de maneira tal, que o sinal somente poderia ser considerado estacionário, mesmo que de maneira aproximada, apenas em alguns trechos de sinal. Além disso, o sistema de sonar passivo gradativamente se torna mais sofisticado com a incorporação de técnicas de processamento de sinais que usam estatísticas de ordem superior. Devido a este fato, as técnicas de separação de interferências aplicadas ao sinal de sonar passivo, como ICA, e os classificadores neurais, que se baseiam fortemente na estatística do sinal para construção de seus modelos, necessitam de alguma indicação de que a estatística do sinal de sonar passivo possa ter sofrido qualquer alteração significativa.

Neste contexto, este trabalho procurou desenvolver um sistema de monitoração do sinal de sonar passivo através da técnica não supervisionada de clusterização com rede ART modificada. Foi feita uma descrição do contexto do ambiente do sonar passivo, onde foram apresentados os aspectos que impactam no desempenho dos sistemas de processamento de sinais aplicados neste ambiente. Na sequência, foram apresentadas descrições das formas de implementação das técnicas de pré-processamento aplicadas nos sistemas de sonar passivo, como a conformação de feixe, as análises espectrais DEMON e LOFAR, a redução de dimensionalidade através de PCA e a separação cega de fontes através de ICA. A base de dados utilizada neste trabalho é constituída de gravações em águas profundas, utilizando um sistema de sonar passivo instalado em um submarino em operação e navios de classe desconhecida.

A clusterização do sistema de monitoração proposto fez uso de uma rede neural ART modificada, tendo sido apresentado o seu algoritmo de treinamento. Esta rede se mostrou adequada para a finalidade deste trabalho, devido à facilidade de implementação, além da sua plasticidade e velocidade de treinamento. A forma de parametrização do sistema foi detalhada e buscou-se avaliar os efeitos da variação dos parâmetros de sintonia do sistema no seu funcionamento. Para validar o

sistema de monitoração, a resposta do sistema foi comparada com os valores da informação mútua e dos cumulantes cruzados, calculados a partir dos espectros do sinal das marcações. Os testes buscaram avaliar a eficiência do sistema de monitoração quanto ao acompanhamento das alterações na estatística dos sinais avaliados, periodicamente, com base no número de *clusters* criados e nas informações de dispersão e posição destes *clusters* e do conjunto de dados. As matrizes de espalhamento intra e extracusters, S_W e S_B , são calculadas pelo sistema para extrair as informações sobre posição e dispersão dos centros e dos dados. Os espectros do sinal provenientes da análise DEMON foram clusterizados em intervalos de aproximadamente 20 segundos. Os testes mostraram que o acompanhamento pode ser feito tanto pelo número de *clusters* quanto pelos valores dos traços das matrizes S_W ou S_B . Foi demonstrado ser possível a combinação dos vetores lógicos das marcações analisadas através de uma lógica “OU”. Nos melhores casos, uma eficiência de detecção de até 75% foi atingida, tendo a informação mútua como figura de mérito, e de 89%, tendo os cumulantes cruzados de quarta ordem como figura de mérito.

Adicionalmente, foram mostrados os resultados de um trabalho que buscou avaliar os efeitos da utilização de três algoritmos de ICA no pré-processamento dos sinais na eficiência da classificação de contatos. Para isto, foi implementado um classificador neural MLP e sua eficiência de classificação foi obtida para cada um dos algoritmos aplicados ao pré-processamento para efeitos de comparação. Os resultados mostraram que o sistema de monitoração pode vir a ser desenvolvido para fins de classificação.

Os resultados obtidos neste trabalho mostraram que é possível realizar o acompanhamento da mudança da estatística através da observação do número de *clusters* criados a cada etapa de clusterização. Foi mostrado que acompanhar outros parâmetros, como, o traço das matrizes de espalhamento intra e extracusters, não acrescenta informação adicional, em relação ao acompanhamento do número de *clusters*. As perspectivas de trabalhos futuros apontam para a necessidade de avaliação de métodos alternativos para a escolha do tamanho do raio de vigilância do processo de clusterização, sendo um fator crítico para a clusterização pela rede ART modificada e, naturalmente, para o desempenho do sistema de monitoração. Propõe-se, também, novas avaliações do tamanho do conjunto de espectros a serem clusterizados. Outras formas de redução de dimensionalidade podem ser avaliadas, como PCA não linear e PCD (componentes principais de discriminação), já que a extração de características do sinal deve reter o máximo de informação sobre o comportamento estatístico do sinal. Estudos de técnicas alternativas para determinação da não estacionariedade estatística poderão ser conduzidos para que sejam disponibilizadas figuras de mérito alternativas e cada vez mais precisas para validação da eficiência do sistema de monitoração. O sistema deve ser avaliado com sinais de outras marcações,

em maior quantidade e de maior duração. O sistema poderá ser testado com sinais sintéticos para se determinar a sensibilidade de detecção de mudanças na estatística. O sistema proposto demonstrou ser aplicável como ferramenta de auxílio, podendo ser paralelizado para monitoração de mais marcações, devido à facilidade de implementação do algoritmo. Como próxima etapa, propõe-se a implementação do sistema de monitoração em um submarino para apoio à classificação de sinais de sonar passivo.

Referências Bibliográficas

- [1] NIELSEN, R. O. *Sonar Signal Processing*. Artech House Inc, Nortwood, MA, 2000.
- [2] KNIGHT, W., PRIDHAM, R., KAY, S. “Digital Signal Processing for Sonar”, *Proceedings of the IEEE*, v. 69, n. 11, pp. 1451 – 1506, 1981.
- [3] MOURA, N. N., DE SEIXAS, J. M., SOARES FILHO, W., et al. “Independent Component Analysis for Optimal Passive Sonar Signal Detection”. In: *Seventh International Conference on Intelligent Systems Design and Applications*, pp. 671–678, Rio de Janeiro, outubro 2007.
- [4] MOURA, N. N., DE SEIXAS, J. M., RAMOS, R. R. “Passive Sonar Signal Detection and Classification Based on Independent Component Analysis”. In: *Sonar Systems*, InTech, 2011.
- [5] VASSALI, M. R., DE SEIXAS, J. M., CALÔBA, L. P. “A Neural Particle Discriminator Based on a Modified ART Architecture”. In: *IEEE International Symposium on Circuits and Systems*, v. 2, pp. 121–124, Phoenix-Scottsdale, AZ, maio 2002.
- [6] SOARES FILHO, W. *Classificação do Ruído Irrradiado por Navios usando Redes Neurais*. Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, 2001.
- [7] HAYKIN, S. *Neural Networks and Learning Machines*. Bookman, 2008.
- [8] ERKMEN, B., YILDIRIM, T. “Improving Classification Performance of Sonar Targets by Applying General Regression Neural Network with PCA”, *Expert Systems with Applications*, v. 35, n. 1-2, pp. 472 – 475, 2008.
- [9] DE OLIVEIRA E SOUZA FILHO, J. B. *Análise de Componentes Principais em Sistemas de Sonar Passivo*. Tese de Mestrado, COPPE/UFRJ, Rio de Janeiro, 2002.
- [10] HYVÄRINEN, A., KARHUNEN, J., OJA, E. *Independent Component Analysis*. John Wiley & Sons, 2001.

- [11] MOURA, N. N., DE SEIXAS, J. M., SOARES FILHO, W. “Classificação de Sinais de Sonar Passivo com Base em Componentes Independentes”. In: *Learning and Nonlinear Models - Revista da Sociedade Brasileira de Redes Neurais*, pp. 10–19, 2007.
- [12] PFLUG, L., IOUP, G., IOUP, J., et al. “Variability in Higher Order Statistics of Measured Shallow-Water Shipping Noise”. In: *Higher-Order Statistics, 1997. Proceedings of the IEEE Signal Processing Workshop on*, pp. 400–404, Banff, Canada, 1997.
- [13] MOURA, N. N., SIMAS FILHO, E. F., DE SEIXAS, J. M. “Independent Component Analysis for Passive Sonar Signal Processing”. In: *Advances in Sonar Technology*, Viena: IN-TECH, cap. 5, pp. 91–110, 2009.
- [14] SOARES FILHO, W., DE SEIXAS, J. M., CALÔBA, L. P. “Principal Component Analysis for Classifying Passive Sonar Signals”. In: *International Conference on Circuits and Systems*, v. 2, pp. 592–595, Sydney, 2001.
- [15] DE OLIVEIRA E SOUZA FILHO, J. B. *Classificação Neural de Sinais de Sonar Passivo*. Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, 2007.
- [16] RAMOS, R. R., DE SEIXAS, J. M., CALÔBA, L. P. “Monitoração de Sinais de Sonar Passivo Através de Clusterização Não Supervisionada”. In: *Anais do IX Congresso Brasileiro de Redes Neurais/Inteligência Computacional*, v. 1, pp. 1–7, Ouro Preto, MG, 2009.
- [17] RAMOS, R. R., CALÔBA, L. P., DE SEIXAS, J. M., et al. “Classificação Neural de Sinais de Sonar Passivo com Base nas Análises LOFAR e ICA”. In: *Anais do VIII Encontro de Tecnologia em Acústica Submarina*, v. 1, pp. 1–10, Rio de Janeiro, 2009.
- [18] SEIXAS, J. M., SOARES-FILHO, W., SOUZA-FILHO, J. B. O., et al. “A Compact Online Neural System for Classifying Passive Sonar Signals”. In: *Proceedings of the International Conference on Signal Processing Applications and Technology (ICSPA 1999)*, v. 1, pp. 1–4, Orlando, USA, 1999.
- [19] GORMAN, R., SEJNOWSKI, T. “Learned Classification of Sonar Targets using a Massively Parallel Network”. In: *IEEE Transactions on Acoustics, Speech, and Signal Processing*, v. 36, pp. 1135–1140, 1988.
- [20] GORMAN, R. “Neural Networks and the Classification of Complex Sonar Signals”. In: *IEEE Conference on Neural Networks for Ocean Engineering*, pp. 283–290, Washington, DC, 1991.

- [21] VAN-HOUTTE, P., DEEGAN, K., KHORASANI, K. “Passive Sonar Processing using Neural Networks”. In: *IEEE International Joint Conference on Neural Networks*, v. 2, pp. 1154–1159, 1991.
- [22] TORRES-MORENO, J.-M., GORDON, M. B. “Characterization of the Sonar Signals Benchmark”, *NEURAL PROCESSING LETTERS*, v. 7, n. 1, pp. 1–4, 1998.
- [23] HASENJÄGER, M., RITTER, H. “Perceptron Learning Revisited: The Sonar Targets Problem”. In: *Neural Processing Letters*, pp. 10–1, 1999.
- [24] WARD, M., STEVENSON, M. “Sonar Signal Detection and Classification using Artificial Neural Networks”. In: *Canadian Conference on Electrical and Computer Engineering*, v. 2, pp. 717–721, Halifax, Canada, 2000.
- [25] HOWELL, B., WOOD, S. “Passive Sonar Recognition and Analysis using Hybrid Neural Networks”. In: *OCEANS 2003. Proceedings*, v. 4, pp. 1917–1924, San Diego, CA, 2003.
- [26] TORRES, R., SEIXAS, J., SOARES-FILHO, W. “Classificação de Sinais de Sonar Passivo utilizando Componentes Principais Não-Lineares”. In: *Learning and Nonlinear Models - Revista da Sociedade Brasileira de Redes Neurais*, v. 2, pp. 60–72, 2004.
- [27] PERSSON, L., LEVONEN, M. “Statistical Tests for Sonar Data Conditioning”. In: *OCEANS 2002 MTS/IEEE Conference*, v. 4, pp. 2234–2238, 2002.
- [28] MASSEY JUNIOR, F. J. “The Kolmogorov-Smirnov Test for Goodness of Fit”. In: *Journal of the American Statistical Association*, v. 46, pp. 68–78, 1951.
- [29] SHANMUGAN, K. S., BREIPOHL, A. M. *Random Signals - Detection, Estimation and Data Analysis*. John Wiley & Sons, 1988.
- [30] DINIZ, P. S. R., DA SILVA, E. A. B., NETTO, S. L. *Digital Signal Processing: System Analysis and Design*. Cambridge University Press, 2002.
- [31] KRAMER, M. A. “Nonlinear Principal Component Analysis Using Autoassociative Neural Networks”, *AICHE*, v. 37, n. 2, fevereiro 1991.
- [32] CALÔBA, L. P., SEIXAS, J. M., PEREIRA, F. S. “Neural Discriminating Analysis For A Second Level Trigger System”. In: *Computing in High Energy Physics*, pp. 870–874, Rio de Janeiro, 1995.
- [33] OPPENHEIM, A. V., SCHAFER, R. W. *Discrete-Time Signal Processing*. Prentice Hall, 1989.

- [34] TREES, H. L. V. *Detection, Estimation and Modulation Theory. Part I*. John Wiley & Sons Inc., 2001.
- [35] DUDA, R. O., HART, P. E. *Pattern Classification and Scene Analysis*. John Wiley & Sons Inc, 1973.
- [36] HAYKIN, S. *Adaptive Filter Theory*. Information and System Sciences. Prentice Hall, 2002.
- [37] HYVÄRINEN, A., OJA, E. “A Fast Fixed-Point Algorithm For Independent Component Analysis”. In: *Neural Computation*, v. 9, pp. 1483–1492, 1997.
- [38] CARDOSO, J.-F., SOULOUMIAC, A. “Blind Beamforming for Non Gaussian Signals”. In: *IEE Proceedings-F*, v. 140, pp. 362–370, 1993.
- [39] AKUZAWA, T. “Extended Quasi-Newton Method for the ICA”. In: *Proceedings of the International Workshop on Independent Component Analysis and Blind Signal Separation*, pp. 521–525, Helsinki, Finland, 2000.
- [40] ECKART, C., YOUNG, G. “The Approximation of One Matrix by Another of Lower Rank”, *Psychometrika*, v. 1, pp. 211–218, 1936.
- [41] THEODORIDIS, S., KOUTROUMBAS, K. *Pattern Recognition*. Academic Press. Elsevier, 2006.
- [42] BARTO, A. G., SUTTON, R. S., ANDERSON, C. W. “Neuronlike Adaptive Elements that can solve Difficult Learning Control Problems”, *IEEE Transaction on Systems, Man, and Cybernetics*, v. SMC-13, pp. 834–846, 1983.
- [43] RUMELHART, D. E., ZIPSER, D. “Feature Discovery by Competitive Learning”, *Cognitive Science*, v. 9, n. 1, pp. 75–112, 1985.
- [44] CARPENTER, G. A., GROSSBERG, S., REYNOLDS, J. H. “ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network”, *Neural Networks*, v. 4, n. 5, pp. 565 – 588, 1991.
- [45] CARPENTER, G., GROSSBERG, S., MARKUZON, N., et al. “Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps”, *IEEE Transactions on Neural Networks*, v. 3, n. 5, pp. 698 – 713, 1992.
- [46] DUDA, R. O., HART, P. E., STORK, D. G. *Pattern Classification*. John Wiley & Sons Inc., 2001.

- [47] BISHOP, C. M. *Neural Networks for Pattern Recognition*. Oxford University Press, 1995.
- [48] STATSOFT. “Distance Measures”. Agosto 2011. Disponível em: <http://www.statsoft.com/textbook/cluster-analysis/>.
- [49] GROSSBERG, S. “Adaptive Pattern Classification and Universal Recoding: II. Feedback, Expectation, Olfaction, Illusions”, *Biological Cybernetics*, v. 23, pp. 187–202, 1976.
- [50] CARPENTER, G. A., GROSSBERG, S. “A massively parallel architecture for a self-organizing neural pattern recognition machine”, *Computer Vision, Graphics, and Image Processing*, v. 37, n. 1, pp. 54 – 115, 1987.
- [51] CARPENTER, G. A., GROSSBERG, S. “ART 2: self-organization of stable category recognition codes for analog input patterns”, *Appl. Opt.*, v. 26, n. 23, pp. 4919–4930, 1987.
- [52] CARPENTER, G. A., GROSSBERG, S., ROSEN, D. B. “ART 2-A: An adaptive resonance algorithm for rapid category learning and recognition”, *Neural Networks*, v. 4, n. 4, pp. 493 – 504, 1991.
- [53] CARPENTER, G. A., GROSSBERG, S. “ART 3: Hierarchical Search Using Chemical Transmitters in Self-Organizing Pattern Recognition Architectures”, *Neural Networks*, v. 3, pp. 129–152, 1989.
- [54] CARPENTER, G. A., GROSSBERG, S., ROSEN, D. B. “Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system”, *Neural Networks*, v. 4, n. 6, pp. 759 – 771, 1991.
- [55] KOHONEN, T. “Clustering, Taxonomy, and Topological Maps of Patterns”, *International Conference on Pattern Recognition*, pp. 114–128, 1982.
- [56] HAYKIN, S. *Communication Systems*. John Wiley & Sons, 1994.
- [57] PAPOULIS, A. *Probability, Random Variables, and Stochastic Processes*. McGraw-Hill, 2001.
- [58] GEORGIEV, P., RALESCU, A., RALESCU, D. “Cross-cumulants measure for independence”, *Journal of Statistical Planning and Inference*, v. 137, n. 3, pp. 1085 – 1098, 2007. ISSN: 0378-3758.
- [59] HOPPE, E., ROAN, M. “Non-linear, Adaptive Array Processing for Underwater Source Localization and Sonar Interference Suppression”. In: *OCEANS 2009 - EUROPE*, pp. 1 –5, 2009.

- [60] RIEDMILLER, M., BRAUN, H. “A Direct Adaptive Method for Faster Back-propagation Learning: The RPROP Algorithm”. In: *Proceedings of the IEEE International Conference on Neural Networks*, pp. 586–591, San Francisco, CA, 1993.

Apêndice A

Publicações

Segue uma descrição dos trabalhos aceitos ou em fase de aceitação para publicação.

A.1 Capítulo de Livro

1. **Título:** Passive Sonar Signal Detection and Classification Based on Independent Component Analysis

Autores: Natanael Nunes Moura, José Manoel de Seixas, Ricardo Rezende Ramos

Livro: Sonar Systems

Editora: InTech

Descrição: As análises espectrais DEMON e LOFAR são apresentadas. São abordados o problema da interferência entre marcações e como é tratada sua remoção no domínio da frequência. A técnica de separação cega de fontes baseada em ICA é apresentada. São mostrados alguns resultados de trabalhos de detecção e classificação a partir de dados experimentais.

A.2 Artigos em Congressos

1. **Título:** Monitoração de Sinais de Sonar Passivo através de Clusterização Não-Supervisionada

Autores: Ricardo Rezende Ramos, José Manoel de Seixas, Luiz Pereira Calôba

Congresso: IX Congresso Brasileiro de Redes Neurais, Ouro Preto, Brasil, 2009

Descrição: Este trabalho apresentou o projeto de um classificador neural de sinais de sonar passivo com base nas análises LOFAR e ICA. A técnica de

ICA foi utilizada na etapa de pré-processamento como forma de minimizar a interferência mútua entre marcações. Três diferentes algoritmos de ICA foram avaliados.

2. **Título:** Classificação Neural de Sinais de Sonar Passivo com Base nas Análises LOFAR e ICA

Autores Ricardo Rezende Ramos, Luiz Pereira Calôba, José Manoel de Seixas, Natanael Nunes Moura

Congresso: VIII Encontro de Tecnologia em Acústica Submarina, Rio de Janeiro, Brasil, 2009

Descrição: Este trabalho mostrou o desenvolvimento de um sistema de monitoração de sinais de sonar passivo visando acompanhar a estatística do sinal, de forma a indicar possíveis alterações. A clusterização não supervisionada, através de uma rede ART modificada, foi avaliada neste trabalho como técnica de acompanhamento. Os resultados indicaram que o sistema proposto poderia vir a ser usado como auxílio às técnicas de separação de interferências, na detecção das interferências mútuas que podem ser causadas entre contatos.