

## MONITORAÇÃO DE SINAIS DE SONAR PASSIVO ATRAVÉS DE CLUSTERIZAÇÃO NÃO SUPERVISIONADA

RICARDO R. RAMOS\*, JOSÉ M. DE SEIXAS\*, LUIZ P. CALÔBA\*

\*Laboratório de Processamento de Sinais, Escola Politécnica, COPPE/UFRJ

Emails: ric3@lps.ufrj.br, seixas@lps.ufrj.br, caloba@lps.ufrj.br

**Abstract**— Passive sonar signals exhibit nonstationary characteristics, causing the need for its analysis to be performed in windows. The change in the statistics of the sonar signal must be detected in realtime, so that the interference separation techniques between contacts, often heavily based on signal statistics, have their performance maximized. This work aims to develop a monitoring system of passive sonar signals capable of indicating possible changes in sonar signal statistics. Unsupervised clustering using a modified ART network was evaluated in this study as monitoring technique. The results indicate that the proposed system can be used to help the interference separation techniques in the detection of mutual interference caused between contacts.

**Keywords**— Passive sonar, PCA, unsupervised clustering, ART network.

**Resumo**— 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, geralmente fortemente baseadas na estatística do sinal, tenham sua performance maximizada. Este trabalho tem por objetivo o desenvolvimento de um sistema de monitoração de sinais de sonar passivo que pretende acompanhar a estatística do sinal, de forma a indicar possíveis alterações. A clusterização não supervisionada, através da rede ART modificada, foi avaliada neste trabalho como técnica de acompanhamento. Os resultados indicam que o sistema aqui proposto pode vir a ser usado como auxílio às técnicas de separação de interferências, na detecção das interferências mútuas que podem ser causadas entre contatos.

**Palavras-chave**— Sonar passivo, PCA, clusterização não supervisionada, rede ART.

### 1 Introdução

Os sistemas de sonar passivo (Nielsen, 2000) escutam o som emitido por um alvo através de um array de hidrofones e realizam a detecção dos sinais contra o ruído de fundo, que é composto pelo ruído ambiente do mar e pelo ruído próprio do navio, conforme ilustra a Figura 1. Os sinais capturados são processados para estimação da “direção de chegada” (DOA, em inglês). Caso haja dois ou mais alvos provenientes de direções adjacentes, eles irão gerar interferência mútua, piorando a performance das técnicas de identificação do contato (Moura et al., 2007).

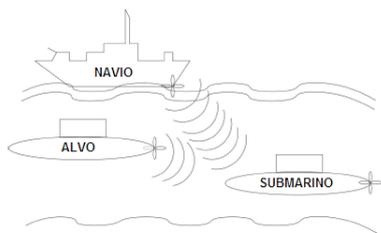


Figura 1: Detecção de Sinal de Sonar Passivo.

Com a finalidade de se detectar a energia em uma dada banda de frequência, é realizada uma análise de conformação de feixe (*beamforming*), cujo objetivo é detectar a energia em uma banda de frequência dada por uma determinada direção (Moura et al., 2007). O sistema, cujos dados experimentais

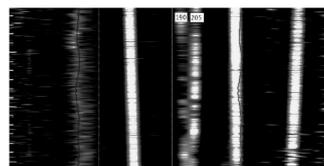


Figura 2: Tempo de Marcação.

foram usados neste trabalho, mantém uma vigilância omnidirecional com 96 bins de resolução, o que significa, em uma faixa que vai de  $0^\circ$  a  $360^\circ$ , uma resolução angular de  $3,75^\circ$ . A Figura 2 mostra o gráfico do tempo de marcação gerado na análise *beamforming* (Moura et al., 2007). O eixo horizontal representa a marcação, 0 a  $360^\circ$ , e o eixo vertical representa o tempo, onde o intervalo entre duas marcas maiores corresponde a um minuto. Neste trabalho, os ruídos irradiados por navios gravados nas direções  $190^\circ$  e  $205^\circ$  estão sendo analisados.

A observação da interferência mútua entre essas direções pode ser feita através da análise DEMON (*Detection Envelope Modulation On Noise*) (Nielsen, 2000). O diagrama em blocos da Figura 3 mostra como funciona a análise DEMON. O sinal adquirido é filtrado por um filtro passa-banda, tipicamente entre 1 e 10 kHz, que é a banda onde o sinal de interesse é mais frequente. Na sequência, o sinal é elevado ao quadrado, como em uma demodulação tradicional, e o algoritmo TPSW (*Two Pass Split Window*) é usado para estimar a média do ruído de fundo (Nielsen, 2000).

Para isso, calcula-se a média local para cada amostra com a finalidade de normalização do sinal. Através do TPSW, é possível enfatizar os picos de sinal dos alvos. O sinal é reamostrado para atingir a banda de 0 a 25 Hz. A Transformada Rápida de Fourier (FFT, em inglês) com base em janelas de Hanning (Diniz et al., 2002) é aplicada em todo trecho de sinal. O resultado é uma sequência janelas de espectros do sinal. A Figura 4 mostra os espectros médios obtidos para os sinais das direções 190° e 205°, respectivamente, a partir da análise DEMON. Percebe-se que o maior pico da direção 205° aparece também na direção 190° como o terceiro maior pico, indicando a interferência da direção 205° na direção 190°.



Figura 3: Diagrama em blocos da análise DEMON.

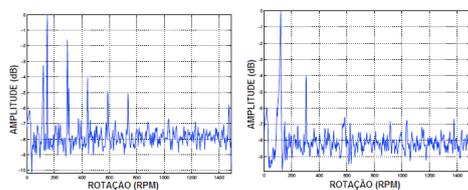


Figura 4: Análise DEMON para 190° (esquerda) e para 205° (direita).

Estudos recentes têm sido realizados para se melhorar a performance da separação da interferência dos sinais de interesse nas direções. Uma técnica promissora, mostrada em Moura et al. (2009), é a Análise de Componentes Independentes (ICA, em inglês) (Hyvärinen et al., 2001). Entretanto, a performance desta técnica é sensível a alterações nas densidades de probabilidade dos sinais utilizados na estimação do modelo de separação. Caso, de fato, tenha ocorrido a alteração na estatística do sinal, o modelo de separação estimado deixará de ser ótimo, demandando uma nova estimação dos componentes independentes, com base na nova densidade de probabilidade do sinal. Sendo assim, caso haja uma ferramenta capaz de monitorar a estatística do sinal do sonar passivo, esta será de grande valia para o Operador do Sonar, que passa a ter um indicador de quando o modelo ICA irá requerer uma nova atualização.

O objetivo deste trabalho é desenvolver um sistema baseado em clusterização neural que seja capaz de monitorar a estatística do sinal de sonar passivo,

provendo subsídios para os algoritmos de detecção e classificação dos sinais.

## 2 Desenvolvimento do Sistema

O modelo conceitual do sistema consiste em:

- Adquirir N janelas FFT do sinal do sonar passivo;
- Clusterizar o conjunto de N janelas;
- Avaliar as mudanças no número de clusters e possíveis deslocamentos dos centros destes clusters;
- Identificar as mudanças na estatística.

Uma gravação de pouco mais do que 200 segundos de duração da direção 190° foi utilizada neste desenvolvimento. Os dados de entrada utilizados para a clusterização correspondem aos espectros que são disponibilizados pela análise DEMON do sinal gravado. A Figura 5 (gráfico da esquerda) mostra uma janela típica, de um total de 410 que estão disponíveis, que corresponde a uma janela de tempo de aproximadamente 0,5 segundos. 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* na obtenção dos espectros do sinal temporal. Cada janela FFT possui 513 pontos.

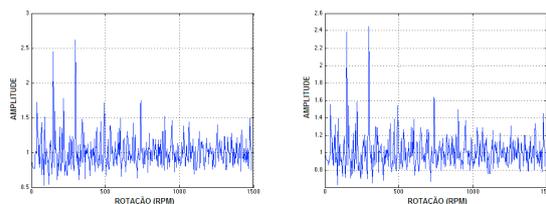


Figura 5: Janela FFT típica (esquerda) e média das 20 primeiras janelas (direita).

A informação obtida dos especialistas indica que o sinal do sonar passivo deva ser avaliado a cada 10 segundos, aproximadamente, para se verificar se houve uma mudança significativa na sua estatística. Sendo esta uma escolha empírica, futuramente pretende-se avaliar outros intervalos de parada para observação e seus efeitos na eficiência do sistema. Neste intervalo de 10 segundos, 20 janelas FFT são aplicadas ao sinal, disponibilizando 20 espectros correspondentes a cada uma das janelas. Estes 20 espectros foram considerados como ponto de partida para parametrizar a rede. Para o desenvolvimento, serão utilizados 10 grupos de 20 espectros. A Figura 5 (gráfico da direita) mostra o espectro médio destas 20 primeiras janelas FFT.

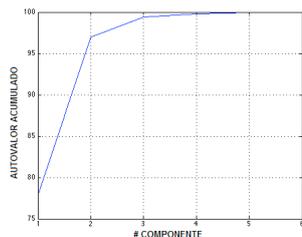


Figura 6: Curva de carga do primeiro conjunto de espectros.

### 2.1 Análise de Componentes Principais

Devido à elevada dimensão (513) do espaço original de entrada e sabendo que a clusterização tende a apresentar melhores resultados em dimensões reduzidas (Duda and Hart, 1973), foi adotada a técnica de Análise de Componentes Principais (PCA, em inglês) para redução de dimensionalidade dos dados. Filho et al. (2001) aplicou PCA em sinais de sonar e teve alto poder de compactação. Filho (2002) obteve bom desempenho na implementação de métodos neurais para extração de componentes principais de sinais de sonar passivo em tempo real. O detalhamento da análise PCA encontra-se em Haykin (2008).

A Figura 6 mostra a curva de carga obtida para o primeiro conjunto de 20 espectros de dimensão 513 para extração dos componentes principais. Pode-se observar que apenas os dois primeiros componentes retêm mais de 95% da variância do processo. Esta realidade se confirma para os 10 primeiros grupos de 20 espectros. Desta forma, optou-se por fazer a clusterização utilizando como entrada da rede as projeções dos dados nos dois primeiros componentes principais.

### 2.2 Clusterização

O modelo de rede escolhido para clusterização foi o da rede ART modificada (Vassali et al., 2002), que se baseia na camada de Kohonen (Haykin, 2008) com treinamento competitivo. A clusterização com esta rede consiste em atribuir um neurônio a cada cluster, sendo que a partir da similaridade entre cada padrão de entrada, que representa uma janela FFT, 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 cluster. Este neurônio será treinado de acordo com

a seguinte equação:

$$\mathbf{w}_{n+1} = (1 - \alpha)\mathbf{w}_n + \alpha\mathbf{x}_n, \quad (1)$$

onde  $\alpha$  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 cluster impõe uma região limitada de atuação do neurônio. Geometricamente, esta região equivale ao volume máximo de cada cluster. Caso o padrão de entrada recebido não seja similar a nenhum dos clusters, automaticamente a rede cria um novo cluster, atribuindo ao seu vetor de pesos o vetor de entrada recebido. Neste trabalho, todos os clusters possuem o mesmo raio de vigilância. É esperado que após um número de passos de treinamento, o vetor de pesos de cada neurônio convirja para o centróide do cluster correspondente. Esta rede é dotada também de processo de esquecimento, que consiste em eliminar da rede um neurônio que permaneça inativo por um determinado número de passos de treinamento.

A rede ART modificada foi escolhida por seu treinamento ser do tipo não supervisionado, o que se enquadra no problema do sonar e, principalmente, pela simplicidade e pela velocidade de treinamento e de operação, características essenciais para aplicações em tempo real, conforme requer o sistema de sonar passivo. Vassali et al. (2002) utilizou a rede ART modificada para discriminação neural de partículas, obtendo alta velocidade de processamento.

Antes de se iniciar a clusterização propriamente dita, foi necessário escolher um valor inicial do raio da classe, tendo sido esta uma etapa crítica do processo. Inicialmente, optou-se pelo raio inicial como 1,5 vezes o valor da menor moda do histograma das distâncias entre os padrões de entrada (Filho, 2007). A Figura 7 mostra o histograma das distâncias obtido para o primeiro conjunto de 20 espectros. A escolha do raio inicial como sendo 1,5 vezes a menor moda do histograma acarretou em uma situação na qual diversos clusters eram criados para mapear o espaço dos padrões de entrada, conforme mostra a Figura 8 (gráfico do lado esquerdo). Isto se repetia para os dez conjuntos de 20 espectros. O problema causado por esta escolha é que quando se passava da clusterização de um conjunto de 20 espectros para a clusterização do conjunto seguinte, muitos clusters eram esquecidos e, conseqüentemente, não participavam da monitoração desejada. Como o objetivo deste trabalho é fazer um acompanhamento da estatística do sinal de entrada, estes esquecimentos não são desejados, uma vez que os clusters observados deixam de existir após algumas poucas paradas para observação.

Estes esquecimentos de muitos clusters podem ser explicados pelo fato de que, a cada novo conjunto de 20 espectros clusterizados, a base ortogonal for-

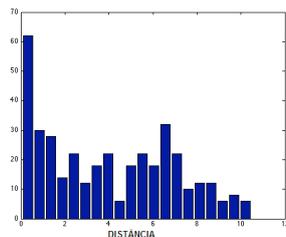


Figura 7: Histograma das distâncias entre os padrões de entrada do primeiro conjunto de 20 espectros.

mada pelas duas direções principais obtidas por PCA, que é usada para projeção dos dados de entrada, é diferente da base usada com o conjunto de espectros anteriores. Os clusters formados em uma etapa qualquer devem ser guardados para a etapa subsequente, para a manutenção de um acompanhamento contínuo do sinal do sonar. Estes clusters obtidos devem sofrer uma transformação de base antes do início da clusterização do novo trecho de sinal, gerando novas coordenadas para os clusters após a transformação de base. Devido a esta mudança de coordenadas, frequentemente, a área de cobertura destes clusters na nova base passa a não receber mais entradas do novo conjunto, como mostra a Figura 8 (gráfico do lado direito), sendo assim esquecidos durante a clusterização do novo trecho de sinal.

Assim, um novo critério teve que ser adotado para escolha do raio inicial. A nova escolha foi fazê-lo igual a segunda menor moda do histograma de distâncias. Com esta escolha, a área de cobertura dos clusters aumentou consideravelmente, em contrapartida, foi possível fazer o acompanhamento com mais facilidade, pois os clusters se mativeram ativos durante muito mais tempo, mesmo após a transformação de base, como será mostrado na Seção 3. A Figura 9 mostra os clusters formados em uma das etapas de clusterização (escolhida ao acaso) e as áreas de cobertura, quando é utilizado o critério da segunda menor moda.

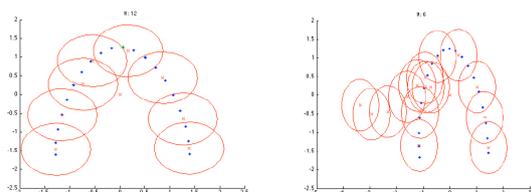


Figura 8: Clusters formados com o critério de 1,5 vezes a menor moda: final de uma clusterização (esquerda) e após a transformação para a clusterização seguinte (direita). Os padrões de entrada são os pontos dentro dos clusters dispostos de forma semielipsoidal.

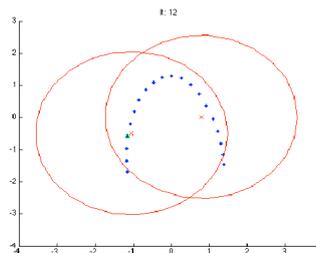


Figura 9: Clusters formados com o critério da segunda menor moda como raio de vigilância.

### 2.3 Sistemática do Acompanhamento

Após esta análise inicial do conjunto de dados e a parametrização da rede, a seguinte sistemática foi adotada para o acompanhamento do sinal do sonar usando clusterização não supervisionada com a rede ART modificada:

1. Seleção da primeira metade do sinal do sonar, no caso, 200 espectros provenientes da aplicação de FFT em janelas (aproximadamente 100 segundos no tempo);
2. Seleção do primeiro grupo de 20 espectros;
3. Aplicação de PCA no grupo de 20 espectros selecionados;
  - Se não atingir o mínimo de 90 % na curva de carga, refaz PCA incluindo mais 1 componente;
4. Projeção dos dados (espectros) brutos nos primeiros componentes principais considerados;
5. Normalização das projeções (subtração da média e multiplicação pelo inverso do desvio padrão);
6. Clusterização com a rede ART com esquecimento;
  - Registro da dispersão intra-cluster;
  - Registro da distância percorrida por cada cluster;
  - Registro da matriz de distâncias entre clusters;
  - Registro do número de clusters ao final da clusterização;
7. Observação e avaliação;
8. Volta para 2, seleciona o grupo seguinte de 20 espectros, iniciando a clusterização com os clusters da etapa anterior com coordenadas transformadas para a nova base ortogonal, e executa de 3 a 6.

No passo 3, é feito um controle do valor acumulado da curva de carga. Caso este valor caia abaixo de um determinado limiar de carga acumulada, o controle determina o aumento do número de projeções (de 1 em 1) até atingir um valor mínimo para o

limiar. Caso haja indicação de que este valor não tenha sido atingido, esta é mais uma indicação da mudança da estatística do sinal do sonar. Para os resultados obtidos na Seção 3 foi escolhido um limiar de 90%, começando com dois componentes.

### 3 Resultados

O procedimento descrito na Seção 2 foi então aplicado ao sinal do sonar da marcação 190° e os resultados são mostrados ao longo desta seção.

A Figura 10 mostra a evolução do número de clusters ao final da clusterização. O registro desta informação, ou seja, a percepção de que houve a criação de um novo cluster ou mais de um e, até mesmo, que houve o esquecimento de um ou mais clusters, é bastante relevante para indicar se houve uma mudança na estatística. Por exemplo, nota-se que houve um aumento brusco da observação 7 para a 8, já que o número de clusters salta de 3 para 5. Esta é uma forte indicação de que a estatística do sinal mudou de forma significativa.

Para fins de observação do acompanhamento, serão mostrados os valores dos registros de distância e de dispersão descritos na sistemática de acompanhamento, considerando apenas 1 cluster, no caso, o primeiro cluster formado, que será chamado de cluster 1. O acompanhamento de um determinado cluster é realizado conforme o procedimento detalhado na Seção 2.2.

A Figura 11 mostra como evolui a distância do cluster 1 a cada parada para observação. A distância na observação  $i$  é dada pela distância euclidiana entre a posição do cluster ao final da clusterização  $i+1$  e a sua posição ao final da clusterização  $i$ , já considerando a transformação de coordenadas da posição final anterior para a mesma base da posição final seguinte. Sendo assim, quando se observa no gráfico da Figura 11 o valor da distância na observação 3 (eixo das ordenadas), por exemplo, significa a distância do cluster 1 na sua posição na observação 4, em relação à observação 3.

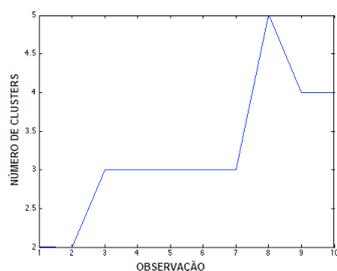


Figura 10: Número de clusters após a clusterização em cada observação.

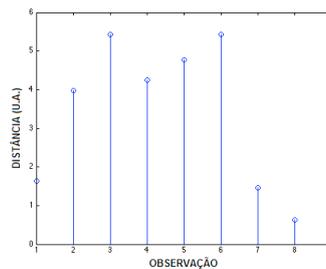


Figura 11: Distância percorrida pelo cluster 1 entre observações.

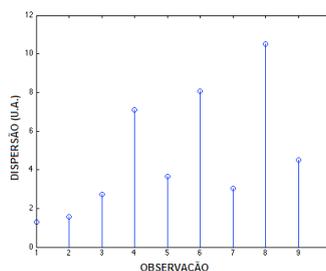


Figura 12: Dispersão do cluster 1 em cada observação.

A Figura 12 mostra a dispersão intra-cluster do cluster 1 em cada parada para observação. O cálculo da dispersão intra-cluster é calculado como o valor esperado da diferença ao quadrado entre os padrões de entrada pertencentes ao cluster e o centro deste. Tanto o valor da distância percorrida pelo cluster quanto a dispersão intra-cluster podem ser usados para a indicação da mudança da estatística do sinal. Porém, para isto, deve ser definido um limiar de decisão que considere cada medida individualmente ou uma combinação de ambas. A definição deste limiar deve ficar a cargo da opinião do especialista.

A Tabela 1 mostra as matrizes de distâncias entre clusters escolhidas nas observações 6, 7 e 8. Elas mostram dinamicamente como os clusters se deslocam com relação aos outros clusters em cada parada para observação. A diagonal será sempre igual a zero, pois representa a distância de um dado cluster para ele próprio. Caso os clusters estejam se afastando ou se aproximando rapidamente a cada observação, esta informação também pode ser usada para determinar uma mudança na estatística do sinal do sonar. Assim como as medidas de distância percorrida pelo cluster e de dispersão intra-cluster, o limiar aqui dependerá da opinião do especialista.

Para as dez observações consideradas, em nenhum momento o limiar mínimo para a curva de carga foi atingido, desta forma sempre foram usadas apenas duas componentes para projeção dos padrões de en-

trada. Caso o limiar escolhido fosse atingido, este seria mais um indicativo de mudança da estatística do sinal do sonar, uma vez que a PCA é feita em cima da matriz de covariância dos 20 espectros analisada em cada etapa de observação.

Tabela 1: Matriz de distâncias entre clusters nas observações 6, 7 e 8 (superior, central e inferior, respectivamente).

Núm. Cluster	1	2	3
1	0	4,53	5,70
2	4,53	0	4,25
3	5,70	4,25	0

Núm. Cluster	1	2	3
1	0	5,80	4,22
2	5,80	0	4,45
3	4,22	4,45	0

Núm. Cluster	1	2	3	4	5
1	0	2,80	1,09	1,72	6,05
2	2,80	0	0,50	7,34	6,37
3	1,09	0,50	0	5,03	6,82
4	1,72	7,34	5,03	0	4,28
5	6,05	6,37	6,82	4,28	0

#### 4 Conclusões

O sinal do sonar passivo apresenta característica não estacionária, ou seja, sua estatística varia de maneira tal que este somente poderia ser considerado estacionário, mesmo que de maneira aproximada, apenas em trechos de sinal bastante reduzidos. Devido a este fato, as técnicas de separação de interferências que vêm sendo aplicadas ao sinal do sonar, como ICA, que se baseiam fortemente na estatística do sinal para construção do modelo de separação, necessitam de alguma indicação de que a estatística do sinal do sonar possa ter sofrido qualquer alteração significativa.

Neste contexto, este trabalho procurou desenvolver um sistema de monitoração do sinal do sonar passivo através da técnica não supervisionada de clusterização com rede ART modificada. Esta rede foi escolhida pela simplicidade, plasticidade e velocidade de treinamento, sendo adequada para o problema do sonar passivo. A técnica de PCA foi utilizada para redução de dimensionalidade. Os resultados obtidos neste trabalho mostraram que é possível realizar o acompanhamento da mudança da estatística através da observação da distância percorrida pelos clusters, do valor da dispersão intra-cluster, da matriz de distâncias entre clusters, do número de clusters e também do limiar mínimo da curva de carga, para realizar a compactação do espaço de entrada original.

Como trabalhos futuros pretende-se estender a

análise para os sinais de outras marcações e diferentes classes de sinais de sonar passivo. Outros métodos de clusterização serão avaliados para efeitos de comparação com o método apresentado. A extração de componentes principais através de métodos neurais será avaliada para a implementação do sistema em tempo real. Além disso, a clusterização será testada utilizando componentes NLPCA (*Nonlinear PCA*) e PCD (*Principal Component Discriminant*), com a vantagem destas técnicas acessarem estatísticas de ordem superior, que são utilizadas em ICA. Novos intervalos de tempo de parada para observação serão testados para se avaliar o efeito na obtenção dos componentes principais e na clusterização.

#### Agradecimentos

Os autores gostariam de agradecer ao CNPq e à FAPERJ pelo apoio ao projeto, à Marinha do Brasil por disponibilizar os dados experimentais, e aos colegas Natanael Nunes Moura (UFRJ) e João Batista de Oliveira e Souza Filho (CEFET-RJ), pesquisadores entusiastas de processamento de sinais de sonar passivo, pela colaboração.

#### Referências

- Diniz, P. S. R., da Silva, E. A. B. and Neto, S. L. (2002). *Digital Signal Processing: System Analysis and Design*, Cambridge University Press.
- Duda, R. O. and Hart, P. E. (1973). *Pattern Classification and Scene Analysis*, John Wiley & Sons Inc.
- Filho, J. B. O. S. (2002). *Análise de componentes principais em sistemas de sonar passivo*, Master's thesis, COPPE/UFRJ, Rio de Janeiro.
- Filho, J. B. O. S. (2007). *Classificação Neural de Sinais de Sonar Passivo*, PhD thesis, COPPE/UFRJ, Rio de Janeiro.
- Filho, W. S., Seixas, J. M. and Calôba, L. P. (2001). Principal component analysis for classifying passive sonar signals, *International Conference on Circuits and Systems*.
- Haykin, S. (2008). *Neural Networks and Learning Machines*, Bookman.
- Hyvärinen, A., Karhunen, J. and Oja, E. (2001). *Independent Component Analysis*, Wiley-Interscience.
- Moura, N. N., Filho, E. F. S. and Seixas, J. M. (2009). Independent component analysis for

passive sonar signal processing, in S. R. Silva (ed.), *Advances in Sonar Technology*, Viena: IN-TECH, pp. 1–20.

Moura, N., Seixas, J. M., Filho, W. S. and Greco, A. (2007). Independent component analysis for optimal passive sonar signal detection, *Seventh International Conference on Intelligent Systems Design and Applications*, pp. 671–678.

Nielsen, R. O. (2000). *Sonar Signal Processing*, Artech House Inc, Nortwood, MA.

Vassali, M. R., Seixas, J. M. and Calôba, L. P. (2002). A neural particle discriminator based on a modified art architecture, *IEEE International Symposium on Circuits and Systems*, pp. II–121–II–124.