

CLASSIFICAÇÃO NEURAL DE SINAIS DE SONAR PASSIVO COM BASE EM COMPONENTES INDEPENDENTES

Natanael Nunes de Moura¹, J. M. Seixas¹, William Soares Filho²

Laboratório de Processamento de Sinais
¹ COPPE/Poli-UFRJ
CP 68504, 21945-970 Rio de Janeiro, RJ, Brasil
² IPqM - Instituto de Pesquisas da Marinha
Rua Ipiru, 2
Rio de Janeiro, RJ, Brasil

Emails: natmoura@lps.ufrj.br, seixas@lps.ufrj.br, wsoaresf@hotmail.com

Resumo – A estimação da direção de chegada (DOA – Direction Of Arrival) de um navio por um submarino envolve o seu sistema de sonar passivo. O ruído irradiado pelo navio (contato) é recebido pelos sensores do sonar, que realiza uma conformação de feixes (beamforming) para a determinação da direção deste ruído. Além da estimação da DOA, se faz necessária a análise do ruído proveniente da direção de interesse, para que possa ser feita uma identificação do navio. O objetivo do trabalho aqui apresentado é implementar um sistema de classificação, usando redes neurais, para identificar contatos após a estimação da direção de chegada ter sido realizada. O classificador opera sobre espectros obtidos com a análise LOFAR para obter as características principais dos sinais dos navios, sendo esta análise realizada sobre as componentes independentes extraídas de duas direções de interesse.

Palavras Chaves – Sonar Passivo, Direção de Chegada, Conformação de Feixes, Redes Neurais, Análise de Componentes Independentes.

Introdução

Um sistema que usa o som se propagando em um ambiente submarino é chamado de sistema sonar. A palavra **SONAR** é originária do inglês "**SO**und **NA**avigation and **R**anging" [1]. Existem dois tipos de sistemas sonar que são utilizados em várias aplicações em acústica submarina: o sistema ativo e o sistema passivo [1] [2]. No sistema ativo, uma onda acústica é transmitida pelo arranjo de sensores e, quando encontra um alvo, é refletida, sendo possível a estimação de parâmetros que levam à detecção e localização do alvo. O sistema passivo realiza a detecção e a estimação usando apenas o ruído irradiado pelo alvo, ruído este que é proveniente das vibrações das máquinas e da cavitação de seu hélice.

A Figura 1 mostra um ambiente em que estão presentes um submarino com um sistema de sonar passivo e vários contatos. O ruído gerado pelos contatos é captado pelos sensores do sonar (hidrofonos). O sonar usa um formador de feixes (beamformer) para obter os sinais provenientes de cada direção [1]. A detecção e a classificação são realizadas por um operador sonar (OS) de forma aural e visual. A detecção pode ser feita observando-se a energia que chega em cada direção (marcação) do sonar, sendo utilizado para isso um gráfico da variação temporal da energia em função da marcação, como mostrado na Figura 1. Para a classificação de um contato detectado em uma dada marcação, o OS utiliza o áudio proveniente desta marcação e análises espectrais realizadas neste sinal, como, por exemplo, a análise **LOFAR (LOw Frequency Analysis and Recording)** [2]. Uma dificuldade nesta classificação se deve ao fato de haver contaminação do ruído do contato com o ruído irradiado por contatos presentes em marcações próximas e também com o ruído do próprio submarino e com o ruído ambiente [3] [4]. Além disto, existe a fadiga do OS pelo fato de mesmo se encontrar durante muito tempo ouvindo neste ambiente ruidoso, sendo então necessário um sistema automático de classificação.

Este trabalho tem por objetivo desenvolver um pré-processamento baseado na análise de componentes independentes (ICA) [5]. Esta análise é aplicada para melhorar a relação sinal/interferência entre duas direções, visando um melhor desempenho na classificação dos contatos nestas direções. Como parte do pré-processamento, a análise LOFAR é realizada para obtenção de espectros na faixa de frequência de interesse. Após o pré-processamento, os espectros são submetidos a uma rede neural, para realizar a classificação, visando apoiar o operador sonar na identificação do contato. Neste trabalho, serão utilizados sinais gravados na saída do conformador de feixes de um sistema de sonar passivo pertencente a um submarino da Marinha do Brasil.

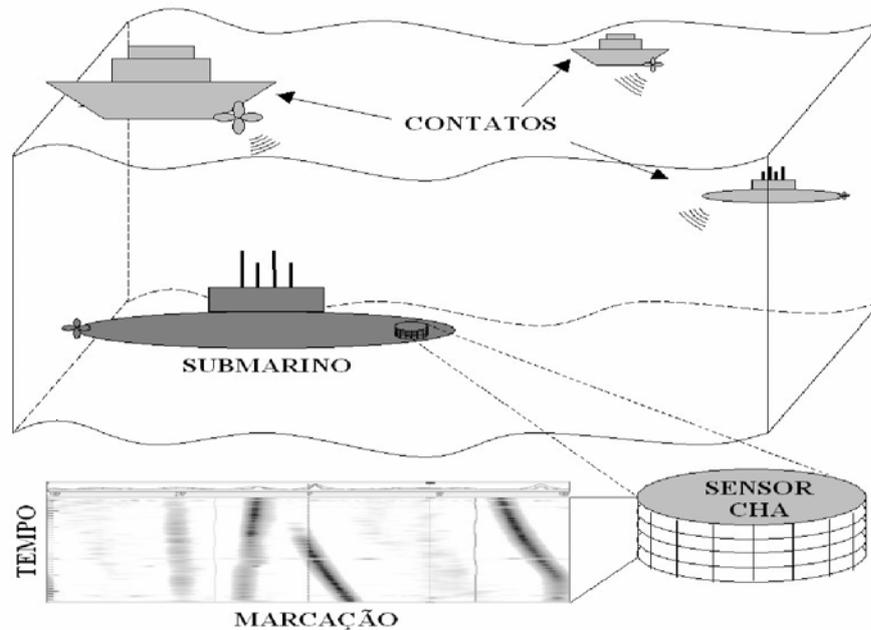


Figura 1 – Sistema de Sonar Passivo com um Arranjo de Sensores Cilíndrico (CHA – Cylindrical Hydrophone Array)

1 Descrição dos Sinais e Pré-processamento

Os sinais utilizados neste trabalho foram adquiridos por um sistema de sonar passivo instalado em submarinos da Marinha do Brasil. Os sinais são recebidos por um arranjo cilíndrico de sensores, sendo formados feixes empregando a técnica convencional de atraso e soma (Delay and Sum) [2] [6]. O conformador de feixes é um filtro espacial que combina os sinais de diferentes sensores com o objetivo de enfatizar os sinais provenientes de uma dada marcação, em detrimento dos sinais de outras marcações. No arranjo cilíndrico empregado neste trabalho, um feixe direcional é formado utilizando 32 sensores adjacentes, conforme mostrado na Figura 2. A Figura 43 apresenta a resposta angular do arranjo cilíndrico após a formação de feixes, para a frequência de 2 kHz. Este diagrama, em forma de sino, mostra para uma dada marcação, como os sinais provenientes de outras marcações contribuem para o sinal obtido no feixe para aquela marcação. O sinal de uma fonte posicionada na marcação do feixe 0° contribui com ganho relativo 1, enquanto que os sinais em outras marcações contribuem com ganhos menores, ou seja, são atenuados. A largura do lóbulo principal da resposta angular é dependente da frequência do sinal, ficando mais larga em frequências mais baixas e mais estreita em frequências mais altas. Isto ocorre devido a maior coerência entre os sensores e o comprimento de onda do sinal, conforme é mostrado na Figura 4. Dependendo da forma como os sensores são combinados para formar os feixes, podem aparecer lóbulos laterais que podem reforçar sinais indesejados em marcações distintas daquela referente ao feixe.

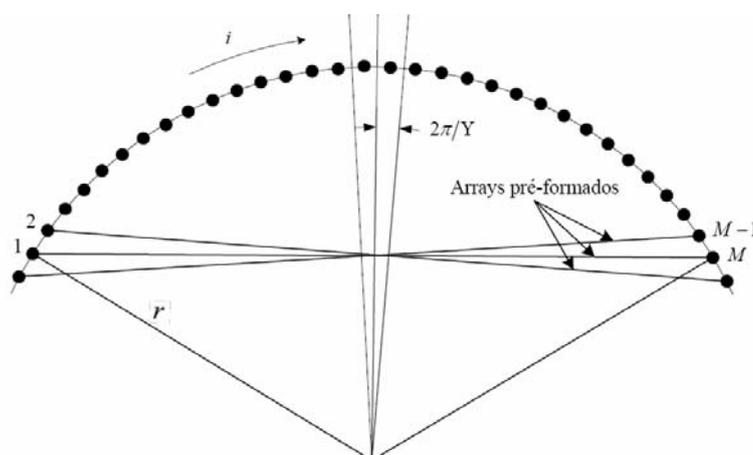


Figura 2 – Diagrama do arranjo cilíndrico mostrando sensores usados na conformação de feixes.

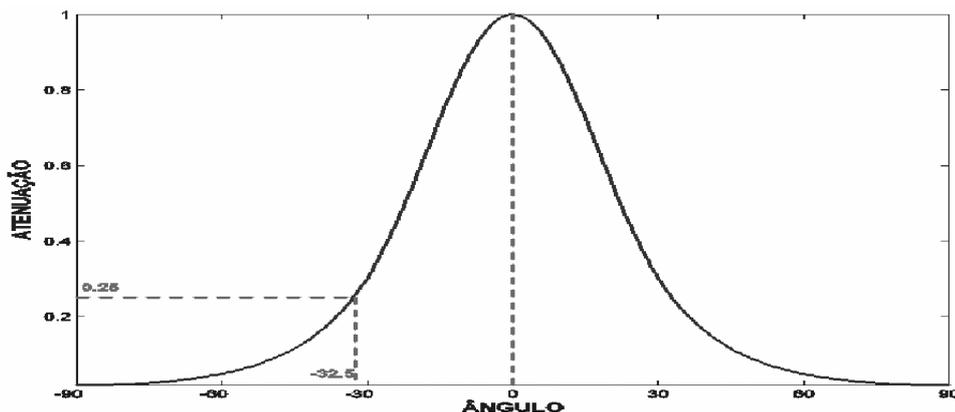


Figura 3 – Resposta angular do arranjo cilíndrico para a frequência de 2kHz. A linha tracejada horizontal indica a atenuação para a matriz de mistura usada no trabalho.

Esta conformação de feixes tem a finalidade de estimar os sinais provenientes de cada direção, tornando possível o cálculo da energia na direção e banda de frequência de interesse, como mostrado na Figura 5. O eixo horizontal representa a marcação, 0° a 360°, formando 96 feixes, com uma separação de 3,75° entre feixes. O eixo vertical representa o tempo, onde o intervalo entre duas marcas maiores corresponde a um minuto. Em determinadas situações, devido à proximidade dos feixes, pode ocorrer uma interferência entre os mesmos, o que acaba impactando negativamente na etapa de classificação dos contatos. Por isso, faz-se necessário o uso de um pré-processamento para realizar a separação dos sinais, facilitando a classificação dos contatos em cada uma das marcações. Neste trabalho, esta tarefa é realizada pela análise de componentes independentes. Após a realização da ICA, é implementada uma análise LOFAR, que tem por objetivo obter os tons presentes no sinal, através dos espectros que irão ser usados efetivamente na classificação.

Foram escolhidos sinais provenientes das marcações de 31° e 146°, com a duração de aproximadamente 180 segundos cada um, onde os contatos estão bem separados, para o treinamento da rede. Considerando a resposta angular mostrada na Figura 3, existe muito pouca interferência entre os sinais destes dois contatos, para a frequência usada no cálculo da resposta angular. Estes mesmos sinais foram, então, combinados com o objetivo de simular a aproximação em marcação dos contatos, ficando os mesmos separados de 32,5°. Esta combinação corresponde a se usar uma matriz de mistura **A**, dada por:

$$\mathbf{A} = \begin{bmatrix} 0,2 & 0,8 \\ 0,8 & 0,2 \end{bmatrix}$$

Após a mistura, foi somado um ruído gaussiano em cada sinal, correspondendo a uma relação sinal/ruído (SNR) de aproximadamente 10dB [2]. A rede neural foi testada com estes dados misturados de modo a verificar a eficiência do classificador.

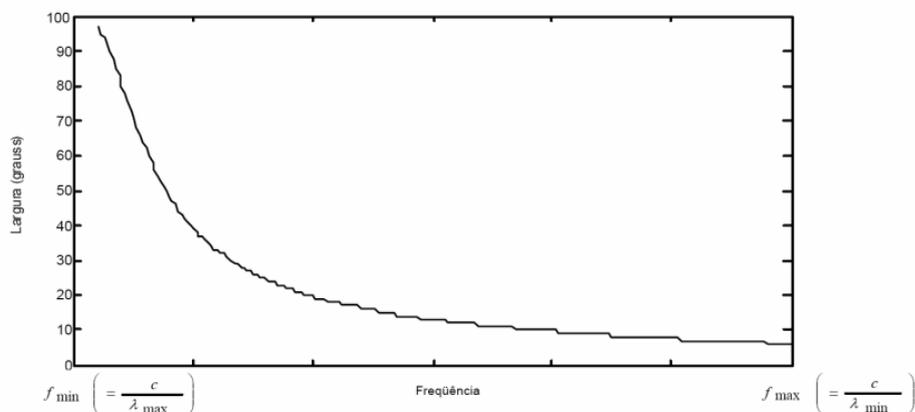


Figura 4 – Gráfico da largura do lóbulo principal versus frequência

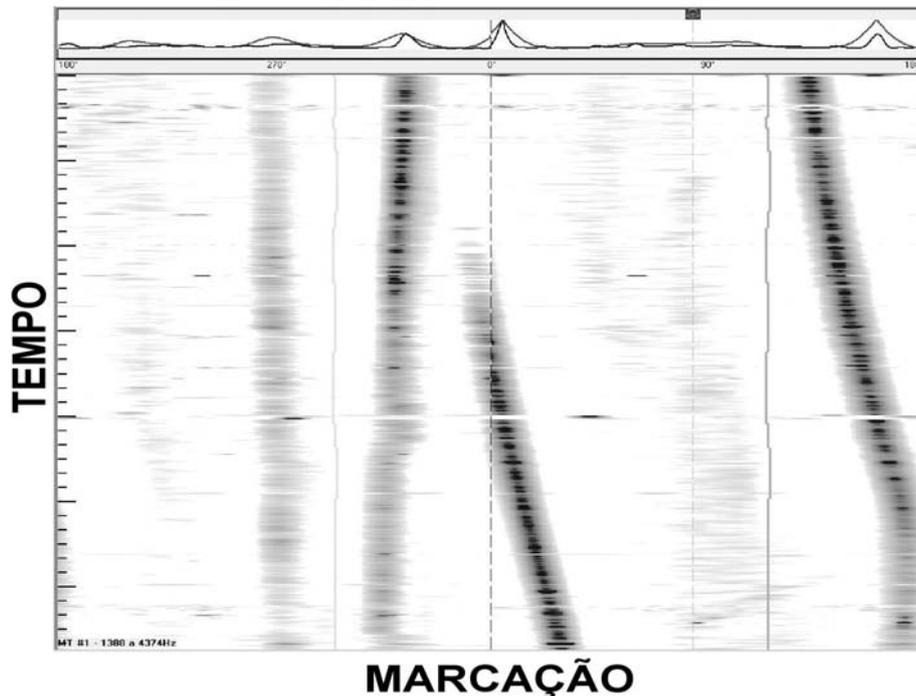


Figura 5 – Gráfico Marcação x Tempo apresentando a variação temporal da energia em função da marcação.

A seguir, será feita uma abordagem do pré-processamento usando as análises LOFAR e a ICA.

1.1 Análise Espectral

Os sinais adquiridos nas marcações de interesse foram processados para obter os espectros que alimentam o classificador neural. A frequência de amostragem dos sinais é de 31.250 Hz, cobrindo uma faixa de observação de 0 a 15.625 Hz. Cada espectro contém 1024 pontos (bins), porém, como a faixa de frequência usada é de 0 a 4 kHz, faixa que contém a grande maioria dos tons gerados pela maquinaria dos navios, foram usados apenas os primeiros 256 bins. O diagrama em blocos da Figura 6 mostra como a análise LOFAR [2] [6] é implementada. O sinal na direção de interesse é multiplicado por uma janela de Hanning [7]. Após esta multiplicação, o sinal é separado em blocos de 1024 pontos, os quais são transformados para o domínio da frequência usando-se a transformada rápida de Fourier (FFT). O módulo do espectro obtido foi normalizado usando o algoritmo TPSW (Two-Pass Split Window), como mostrado na Figura 7 [2]. A normalização foi implementada estimando-se o ruído de fundo presente em cada espectro e realizando a divisão do espectro ponto a ponto por esta estimativa. 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.



Figura 6 – Diagrama em blocos da análise LOFAR.

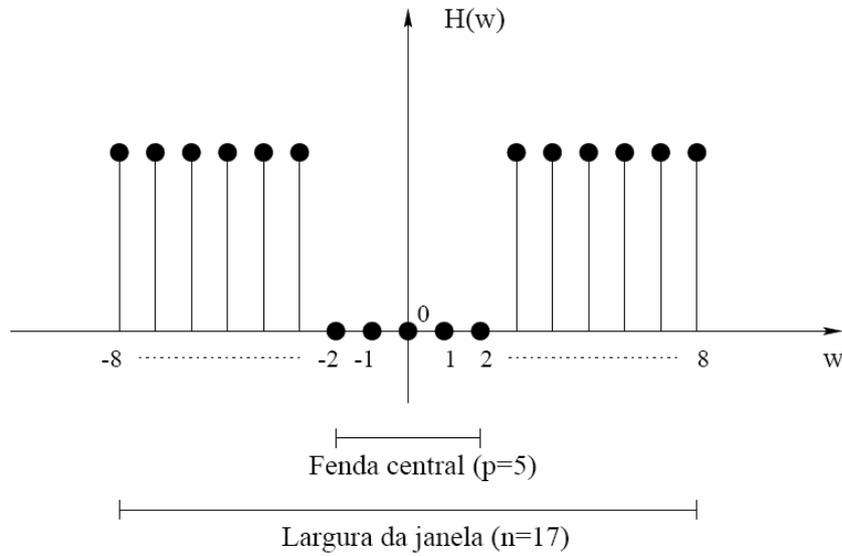


Figura 7 - Janela usada para cálculo da média local com o algoritmo TPSW.

As Figuras 8 e 9 mostram os mapas espectrais pré-processados dos dados nas marcações de interesse das classes dos contatos. A escala horizontal corresponde ao eixo das frequências que vai de 0 a 4 kHz. A escala vertical representa o tempo. No mapa, observam-se linhas verticais que podem ser associadas aos tons das máquinas dos navios nas respectivas marcações. Estas linhas são de grande importância para a identificação dos navios. É importante também observar, na Figura 9, que após a separação dos sinais, os tons característicos de cada navio ficaram mais evidenciados e as interferências foram atenuadas, contribuindo de forma significativa na identificação do contato, principalmente de forma aural, por parte do operador sonar.

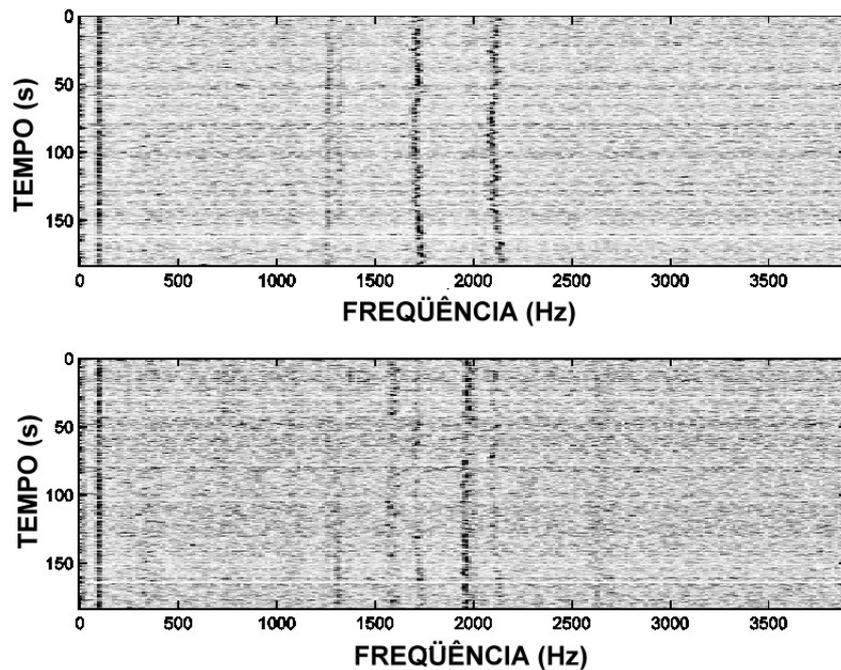


Figura 8 – Espectrograma das marcações 31° (acima) e 146° (abaixo) com as misturas.

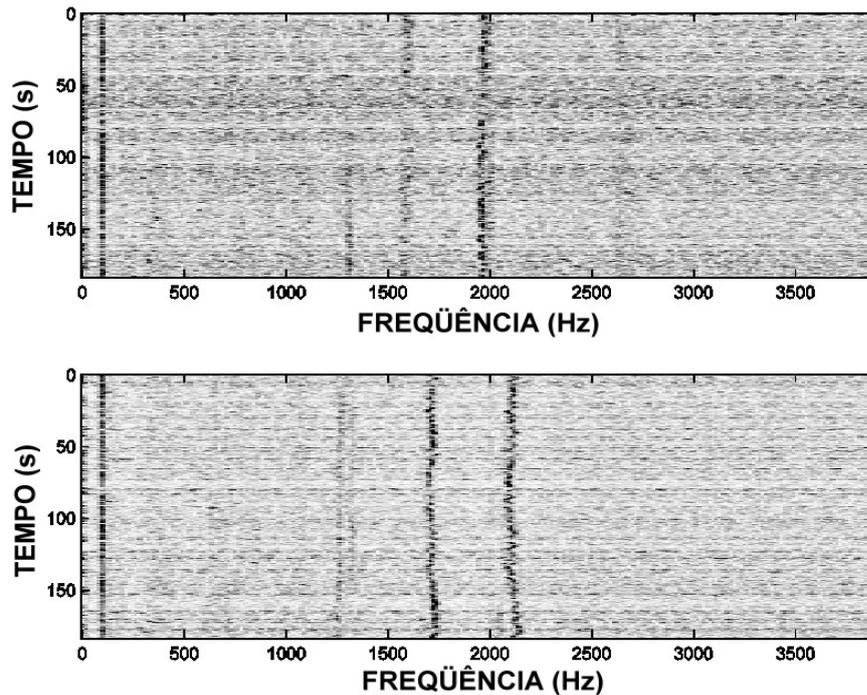


Figura 9 – Espectrograma dos sinais separados pela ICA.

1.2 Análise de Componentes Independentes

A análise de componentes independentes tem por objetivo realizar a separação de sinais de uma fonte que compõe uma mistura [8]. É achada uma representação linear da não gaussianidade dos dados de forma que as componentes sejam estatisticamente independentes, ou tão independentes quanto possível [9]. Devido ao grande número de aplicações em várias áreas de interesse, tais como comunicações, processamento de voz, processamento de sinais na área médica, aplicações na área militar, etc., a análise de componentes independentes tem recebido grande atenção [5]. Muitas abordagens diferentes têm sido tentadas por um grande número de trabalhos usando estatísticas de ordem superior. O modelo mais simples considera a existência de n sinais independentes $s_1(t), \dots, s_n(t)$ e as observações são obtidas por estas fontes de misturas, $x_1(t), \dots, x_n(t)$. Estas misturas são lineares e instantâneas. Isto pode ser representado de forma compacta como mostrado na equação:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) \quad (1)$$

onde $\mathbf{s}(t) = [s_1(t), \dots, s_n(t)]^T$ é um vetor coluna $n \times 1$, representando os sinais das fontes. Os sinais $\mathbf{x}(t)$ são adquiridos das n observações. \mathbf{A} é uma matriz $n \times n$ de misturas que contém os coeficientes da mistura. O problema da análise de componentes independentes consiste na recuperação do vetor fonte $\mathbf{s}(t)$ usando somente as observações dos dados $\mathbf{x}(t)$, considerando a independência entre as entradas do vetor $\mathbf{s}(t)$. Isto pode ser realizado fazendo o cálculo da matriz de separação \mathbf{B} , de tamanho $n \times n$, onde a saída tem a forma da equação:

$$\mathbf{y}(t) = \mathbf{B}\mathbf{x}(t) \quad (2)$$

Assim $\mathbf{y}(t)$ é uma estimativa do vetor $\mathbf{s}(t)$.

A separação de sinais usando ICA pode ser formulada como a determinação da direção onde a não gaussianidade seja máxima. Vários algoritmos eficientes vêm sendo usados hoje em dia [10], entre eles o algoritmo JADE, que se baseia na teoria de matrizes cumulantes para a separação de sinais.

1.2.1 Algoritmo JADE

O algoritmo JADE (Joint Approximate Diagonalization of Eigenmatrices) [9] [11] tem como princípio a solução do problema de autovalores do tensor cumulante, realizando uma diagonalização do tensor através da decomposição dos autovalores. O tensor cumulante é um operador linear definido por cumulantes de quarta ordem. Os tensores podem ser considerados como uma generalização linear de matrizes [8]. Esta operação linear gera uma matriz que tem a forma da

Equação (3), onde m_{kl} são os elementos da matriz \mathbf{M} que vai ser transformada. Neste algoritmo, a decomposição do autovalor é considerada como um pré-processamento.

$$\mathbf{F}_{ij}(\mathbf{M}) = \sum_{kl} m_{kl} cum(\mathbf{x}_i, \mathbf{x}_j, \mathbf{x}_k, \mathbf{x}_l) \quad (3)$$

O algoritmo JADE usa os cumulantes de segunda e quarta ordens. O cumulante de segunda ordem é usado para assegurar o branqueamento dos dados (descorrelação). Isto produz uma matriz de branqueamento \mathbf{W} que diagonaliza a matriz $\mathbf{F}(\mathbf{M}_i)$ como pode ser visto na Equação (4). Assim são criadas matrizes de dados branqueadas. A matriz de separação pode ser estimada a partir do produto $\mathbf{V} \cdot \mathbf{W}$, onde \mathbf{V} é uma matriz de rotação que faz as matrizes cumulantes tão diagonais quanto possível.

$$\mathbf{Q} = \mathbf{W}\mathbf{F}(\mathbf{M}_i)\mathbf{W}^T \quad (4)$$

A minimização da soma dos quadrados dos elementos fora da diagonal da Equação (4) é equivalente à maximização da soma dos quadrados dos elementos da diagonal. Isto se deve ao fato da matriz \mathbf{W} ser uma matriz ortogonal o que não muda a soma total dos quadrados de uma matriz. A maximização do algoritmo JADE é um método que fornece uma diagonal conjunta aproximada de $\mathbf{F}(\mathbf{M}_i)$ como é mostrado na Equação (5):

$$\mathbf{J}_{\text{JADE}}(\mathbf{W}) = \sum_i \left\| \text{diag}(\mathbf{W}\mathbf{F}(\mathbf{M}_i)\mathbf{W}^2) \right\| \quad (5)$$

onde $\|\text{diag}(\bullet)\|$ significa a soma dos quadrados da diagonal. A maximização da função contraste \mathbf{J}_{JADE} é uma maneira de realizar uma diagonalização conjunta aproximada da matriz $\mathbf{F}(\mathbf{M}_i)$. As matrizes \mathbf{M}_i são escolhidas das automatrizes dos tensores cumulantes. Este é o princípio básico do algoritmo de JADE [9] [11].

2 Classificador Neural

O classificador neural usado para a discriminação entre as classes, é uma rede neural (MLP – Multi-Layer Perceptron) [12] que contém multicamadas de neurônios, sem realimentação. Esta rede foi projetada com uma camada de entrada com 256 nós, uma camada escondida com 4 neurônios e uma única camada de saída com apenas um neurônio. Os neurônios da camada escondida e da camada de saída possuem uma função de ativação do tipo tangente hiperbólica. Cada neurônio da entrada é alimentado por um ponto do espectro obtido pelos mapas espectrais da análise LOFAR. O treinamento foi do tipo batelada, utilizando um conjunto de 3.400 espectros, sendo a metade deste conjunto espectros do navio de uma marcação e a outra metade do conjunto é composta por espectros da outra marcação.

A rede neural foi treinada usando o algoritmo de aprendizado supervisionado "backpropagation". Para cada espectro apresentado na entrada da rede, a saída desejada foi definida como sendo um vetor com os valores 1 e -1 correspondendo às classes que se quer classificar. Após o treinamento, foi calculado a eficiência de classificação visando avaliar a generalização do classificador neural. A eficiência na classificação foi calculada com base no critério de máxima probabilidade.

3 Resultados

A rede neural usa a análise LOFAR como pré-processamento antes da classificação. Os dados foram obtidos das marcações 31° e 146°. Para cada classe foram calculados 3.400 espectros que foram separados em um conjunto de treino (espectros ímpares), e um conjunto de teste (espectros pares). Estes dados foram usados no treinamento e teste da rede. Os histogramas com os valores do neurônio de saída da rede para os dados de teste, com o pré-processamento usando ICA e com os sinais misturados, são mostrados nas Figura 10.

Após o treinamento, a rede foi usada para classificar os sinais originais e também os sinais misturados, representando uma aproximação em marcação dos contatos. Depois disto, foi aplicado o pré-processamento nos sinais misturados usando a ICA para a separação dos sinais, e os sinais separados também foram testados na rede. O diagrama em blocos da Figura 11 mostra como os sinais foram pré-processados com a ICA para a realização da classificação.

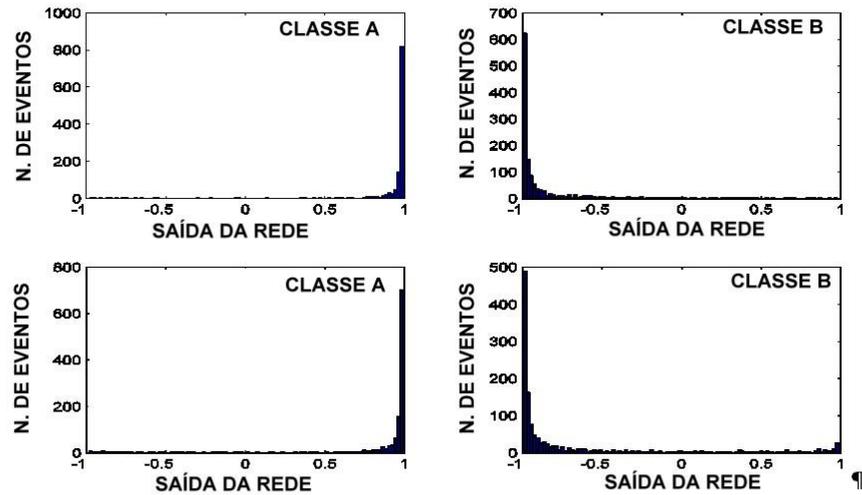


Figura 10 – Distribuições das classes: A e B. Parte superior, saída do classificador com o pré-processamento usando ICA. Parte inferior, saída do classificador com os sinais misturados.



Figura 11 – Diagrama em blocos da classificação utilizando pré-processamento com ICA.

A Tabela 1 mostra a eficiência do classificador para as diversas condições de sinais, considerando os dados de teste. Para os sinais originais, sem a adição do ruído branco, o valor obtido foi de 94,3%. Os sinais misturados, isto é, multiplicados pela matriz de mistura **A** tiveram o seu desempenho reduzido para 82,7%. Quando se utilizou o pré-processamento com a ICA nos sinais misturados, a eficiência da rede neural para os dados separados subiu para 88%, próximo ao valor obtido para a situação antes da mistura e com a SNR de 10 dB que é de 89,0%.

Tabela 1 –Eficiência. De classificação

Sinal de Teste	94,3
Com Mistura	82,7
Sem Mistura, com ruído	89,0
Com ICA	88,0

A seguir, são apresentadas curva de eficiência de classificação dos contatos, com os sinais de teste e com o pré-processamento usando a ICA e com os sinais misturados.

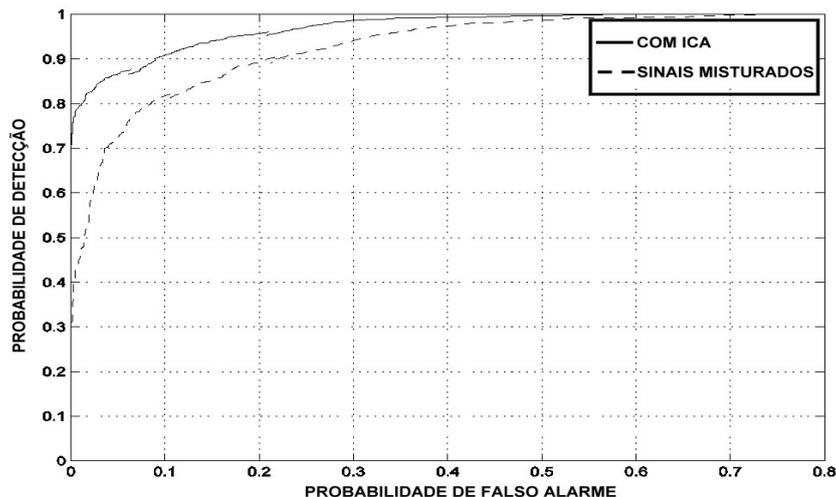


Figura 12 – Curva ROC dos sinais com ICA e os sinais misturados.

4 Conclusões

Neste trabalho, foram utilizados sinais obtidos de um sistema de sonar passivo para duas classes de navios, em diferentes marcações, para treinar e testar um classificador neural. Os dados de entrada do classificador foram obtidos usando-se a análise LOFAR, cobrindo a faixa de frequência de 0 a 4kHz. Estes sinais foram misturados para simular a aproximação dos contatos em marcação usando a resposta angular de um arranjo cilíndrico para a frequência de 2 kHz. A rede neural foi testada com os sinais originais, com os sinais misturados e também com os sinais separados usando a análise de componentes independentes (ICA) sendo obtida uma boa eficiência de classificação dos sinais. Então, pode ser concluído que a ICA realizou a boa separação dos sinais.

Trabalhos futuros, poderão ser utilizados com dados reais que apresentem a situação de mistura, que é freqüente em condições práticas. A mistura de sinais em marcações vizinhas dificulta sobre maneira a ação do operador sonar na identificação das classes de navios de interesse. Além disso, deve-se considerar a realização do treinamento com as mesmas classes, porém, em condições variadas de operação, fazendo com que o classificador neural tenha uma capacidade de generalização ainda mais eficiente.

5 Agradecimentos

Gostaríamos de agradecer ao CNPq, CAPES, FAPERJ pelo apoio dado a este projeto e ao Instituto de Pesquisas da Marinha (IPqM), pelas frutíferas discussões realizadas com os seus especialistas e por disponibilizar os dados experimentais utilizados neste trabalho.

6 Referências Bibliográficas

- [1] Waite, A. D. *Sonar for practicing Engineers*, John Wiley and Sons, New York, 2003.
- [2] Nielsen, R. O. *Sonar Signal Processing*, Artech House Inc, Nortwood, 1991.
- [3] Urick, R. *Principles of Underwater Sound for Engineers*, McGraw-Hill, 1983.
- [4] Burdic, W. S. *Underwater Acoustic System Analysis*, Prentice-Hall, 1984.
- [5] Yan, D. P. and J.Peach. Comparison of blind source separation algorithms, *Advances in Neural Networks and Applications*, WSES, pp. 18-21.
- [6] W. Knight, R. Pridhan, S. K, Digital signal processing for sonar, *IEEE proceedings*, v. 69, number 11, pp. 1451-1507, 1981.

- [7] P. S. R. Diniz, E. A. B. da Silva, S. L. N., *Digital Signal Processing: System Analysis and Design*, Cambridge University Press, 2002.
- [8] Oja, A. H. E. Independent component analysis: Algorithms and applications. www.cs.helsinki.fi/u/ahyvarin/papers/NN00new.pdf, 2000.
- [9] E. O. Aapo Hyrinen, Juha Karhunen, O. *Independent Component Analysis*, John Wiley and Sons, New York, 2001.
- [10] Y. J. Zhen W., L. J, Independent component analysis. www.stanford.edu/~zhenwei/Presentation/icafinal.pdf, 2005.
- [11] Cardoso, J. F. Blind signal separation: Statistical and principles, IEEE proceedings, v. 86, pp. 2009-2025, 1998.
- [12] Haykin, S. *Neural Networks, A Comprehensive Foundation*, Prentice Hall, second edition, 1999.