

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

NATANAEL NUNES DE MOURA*, WILLIAM SOARES FILHO†, J. M. SEIXAS*

*COPPE/Poli-UFRJ

Laboratório de Processamento de Sinais
CP 68504, 21945-970 Rio de Janeiro, RJ, Brasil

†IPqM - Instituto de Pesquisas da Marinha
Rua Ipiru, 2
Rio de Janeiro, RJ, Brasil

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

Abstract— The estimation of the direction of arrival (DOA) of a ship by a submarine relies very much in its passive sonar system. The noise radiated by a contact is received by the sonar sensors, using a beamformer to determine the direction of the noise. Besides the DOA estimation it is also necessary to identify the contact's class in a given direction of interest, performing the classification of ships. The objective of the work presented here is to implement a classification system, using neural networks, to identify contacts after the estimation of the direction of arrival has been performed. The classifier operates over independent component extracted from a LOFAR analysis, which is realized in each direction to obtain the main features of the ship signals.

Keywords— Passive Sonar, Direction of Arrival, LOFAR, Beamforming, Neural Networks, Independent Component Analysis.

Resumo— A estimação da direção de chegada (DOA) de um navio por um submarino envolve o seu sistema de sonar passivo. O ruído irradiado pelo 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 necessário também a identificação do ruído proveniente da direção de interesse, para que possa ser feita uma classificação dos navios. O objetivo do trabalho apresentado aqui 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 componentes independentes extraída de uma análise LOFAR, que é realizada em cada direção de interesse para obter as características principais dos sinais dos navios.

Keywords— Sonar Passivo, Direção de chegada, Conformação de Feixes, Redes Neurais, Análise de Componentes Independentes.

1 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 "SOund NAvigation and Ranging" (Waite, 2003). Existem dois tipos de sistemas sonar que são utilizados em várias aplicações em acústica submarina, o sistema ativo e o sistema passivo (Nielsen, 1991), (Waite, 2003). No sistema ativo, uma onda acústica é transmitida pelo arranjo de sensores e quando encontra um alvo é refletida sendo possível a estimação dos parâmetros que levam à detecção e localização do alvo. O sistema passivo realiza a detecção e a estimação usando o ruído irradiado pelo alvo, ruído este que é proveniente das vibrações das máquinas e da cavitação de seu hélice.

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. 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 (hidrofones). A confor-

mação de feixes empregou a técnica convencional de atraso e soma (Delay and Sum) (Nielsen, 1991).




Figura 1: Sistema de Sonar Passivo com um Arranjo de Sensores Cilíndrico.

A detecção e a classificação em um sistema de sonar passivo são realizadas por um operador sonar (OS) de forma aurál 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** (**LO**w **F**requency **A**nalysis and **R**ecording) (Nielsen, 1991). A dificuldade nesta classificação se deve ao fato de haver contaminação do ruído do contato com o ruído irradiado por contatos presentes em outras marcações e também com o ruído do próprio submarino e com o ruído ambiente (Urlick, 1983).

Este trabalho tem por objetivo desenvolver um pré-processamento baseado na análise de componentes independentes (ICA) (Yan and J.Peach, 2000) para melhorar a relação sinal interferência entre duas direções, visando um melhor desempenho na classificação dos contatos nestas direções. É realizada uma análise LOFAR para obtenção de espectros na faixa de frequência de interesse para uma posterior classificação. Após este pré-processamento, os espectros são submetidos a uma rede neural, para realizar a classificação, possibilitando a identificação do contato.

2 Descrição dos Sinais e Pré-processamento

Os dados adquiridos foram gravados em um sistema de sonar passivo que está instalado em submarinos da Marinha do Brasil. Os sinais que foram gravados são recebidos por um arranjo cilíndrico de sensores e a conformação de feixes (Waite, 2003) 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 2. O eixo horizontal representa a marcação, 0° a 360° , formando 96 feixes, cada feixe representando uma marcação, com uma resolução de $3,4^\circ$. Desta forma, o sistema faz a estimação da direção de chegada em todas as direções. O eixo vertical representa o tempo, onde o intervalo entre duas marcas corresponde a dez segundos.

Em determinadas situações, devido à proximidade dos feixes, pode ocorrer uma interferência entre os mesmos, o que acaba impactando negativamente também 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 (ICA). Após a realização da ICA, é implementada uma análise LOFAR para a obtenção dos espectros que irão ser usados efetivamente na classificação.

Foram escolhidos trechos nas marcações de 31° e 146° , onde os sinais dos contatos estão bem separados de forma que o treinamento da rede

possa ser realizado.

Estes mesmos sinais foram, então, combinados com o objetivo de simular a aproximação em marcação dos contatos. Considerando o diagrama de recepção do arranjo utilizado no sistema de sonar passivo do submarino (Burdic, 1984), mostrado na Figura 3, quando os contatos estão afastado em marcação de $32,5^\circ$, a combinação dos sinais corresponde a se usar uma matriz de mistura M , dada por:

$$\begin{bmatrix} 0.2 & 0.8 \\ 0.8 & 0.2 \end{bmatrix} \quad (1)$$

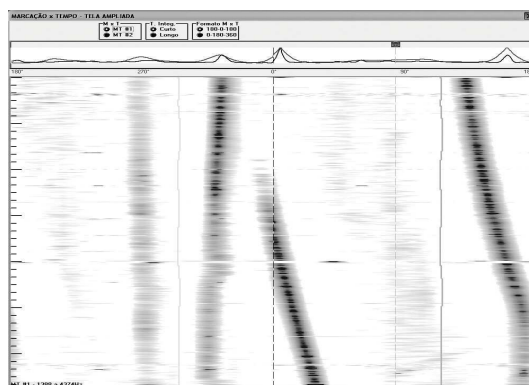


Figura 2: Gráfico Marcação x Tempo apresentando a variação temporal da energia em função da marcação.

Após a mistura, foi somado um ruído gaussiano em cada sinal, correspondendo a uma relação sinal/ruído (SNR) de aproximadamente 10dB, o que é realístico. A rede foi testada com estes dados misturados de modo a verificar a eficiência do classificador. A seguir, será feita uma




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.

abordagem do pré-processamento usando ICA e a análise LOFAR.

2.1 Análise de Componentes Independentes

A análise de componentes independentes tem por objetivo realizar a separação de sinais de uma fonte que compõe uma mistura (Oja, 2000). O objetivo nesta análise é achar uma representação linear da não gaussianidade dos dados de forma que as componentes sejam estatisticamente independentes, ou tão independentes quanto possível (E. O. Aapo Hyrinen, 2001). 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 uma grande atenção. 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 misturas, $x_1(t), \dots, x_n(t)$, onde estas misturas são lineares e instantâneas. Isto pode ser representado de forma compacta como mostrado na Eq. 2:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) \quad (2)$$

onde $\mathbf{s}(t) = [s_1(t), \dots, s_n(t)]^T$ é um vetor coluna $n \times 1$, dos sinais das fontes. Os sinais $x(t)$ são adquiridos das n observações. \mathbf{A} é uma matriz 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 $x(t)$, 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 Eq. 3:

$$\mathbf{y}(t) = \mathbf{B}\mathbf{x}(t) \quad (3)$$

onde $\mathbf{y}(t)$ 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 têm sido usados hoje em dia (Cardoso, 1998), entre eles o algoritmo JADE, que usa a teoria de matrizes cumulantes para a separação de sinais.

2.1.1 Algoritmo Jade

O algoritmo JADE (Joint Approximate Diagonalization of Eigenmatrices) (E. O. Aapo Hyrinen, 2001) tem como princípio a solução do problema de iguais autovalores do tensor cumulante realizando uma diagonalização do tensor através da decomposição dos autovalores. Métodos tensoriais são usados na análise de componentes independentes. Tensores podem ser considerados como uma generalização linear de matrizes ou operadores. O tensor cumulante é um operador linear definido por cumulantes de quarta ordem

$cum(x_i, x_j, x_k, x_l)$. Esta operação linear gera uma matriz que tem a forma da Eq. 4. Neste algoritmo, a decomposição do autovalor é considerada como um pré-processamento.

$$\mathbf{F}_{ij}(\mathbf{M}) = \sum_{kl} m_{kl} cum(x_i, x_j, x_k, x_l) \quad (4)$$

Nesta equação, m_{kl} é um elemento da matriz, \mathbf{M} . O algoritmo JADE usa as cumulantes de segunda e quarta ordens. A cumulante de segunda ordem é usada para assegurar o branqueamento do dado (descorrelação). Um conjunto de matrizes cumulantes é estimada dos dados branqueados, como é mostrado na Eq. 5. Desta forma, a matriz $\mathbf{F}(\mathbf{M})$ é diagonalizada através da matriz \mathbf{W} para alguma matriz \mathbf{M}_i .

$$\mathbf{Q} = \mathbf{W}\mathbf{F}(\mathbf{M}_i)\mathbf{W}^T \quad (5)$$

A minimização da soma dos quadrados dos elementos fora da diagonal da Eq. 5 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 Eq. 6:

$$\mathbf{J}_{JADE}(\mathbf{W}) = \sum_i \|\text{diag}(\mathbf{W}\mathbf{F}(\mathbf{M}_i)\mathbf{W})\|^2 \quad (6)$$

onde $\|\text{diag}(\cdot)\|$ 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. Após alguma manipulação algébrica, a função contraste (E. O. Aapo Hyrinen, 2001), (Y. J. Zhen W., 2005) é calculada como mostrado na eq. 7.

$$\mathbf{J}_{JADE}(\mathbf{W}) = \sum_{ijkl \neq iikl} cum(y_i, y_j, y_k, y_l)^2 \quad (7)$$

2.2 Análise Espectral

Os sinais adquiridos nas marcações de interesse foram processados para obter espectros a serem utilizados no classificador neural. A frequência de amostragem dos sinais é de 31250 Hz, cobrindo uma faixa de observação de 0 a 15625 Hz. Cada espectro contém 1024 pontos (bins), porém, como a faixa de frequência usada é de 0 a 4 kHz, faixa esta que contém a grande maioria dos tons gerados pela maquinária dos navios, foram usados apenas os primeiros 256 bins. O diagrama em

blocos da Figura 4 mostra como a análise LO-FAR (Nielsen, 1991), (W. Knight, 1981) é implementada. O sinal na direção de interesse é multiplicado por uma janela de Hanning (P. S. R. Diniz, 2002). 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) (Nielsen, 1991). 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 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 4: Diagrama em blocos da análise Lofar.

As Figuras 5 e 6 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. Pode ser observado no mapa, 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.

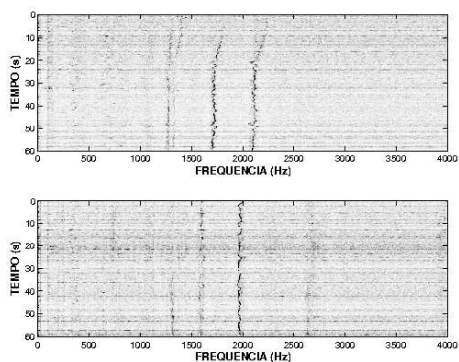


Figura 5: Espectrograma das marcações 31° e 146°.

3 Classificador Neural

O classificador neural usado para a discriminação entre as classes é uma rede neural que contém multicamadas de neurônios, sem realimentação (MLP - Multi-Layer Perceptron) (Haykin, 1999). Esta rede foi projetada com uma camada de entrada com 256 nós, uma camada escondida com 4

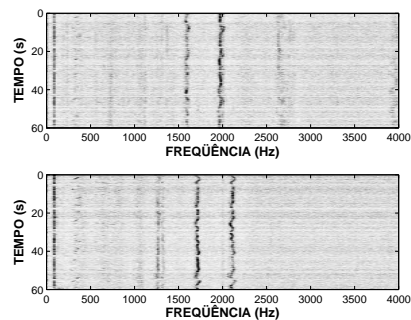


Figura 6: Espectrograma dos sinais separados pela ICA.

neurônios e uma 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.


A rede 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 realizado um cálculo da eficiência de classificação visando a avaliar a generalização do classificador neural. A eficiência na classificação foi calculada com base no critério de máxima probabilidade.

4 Resultado


Os dados foram obtidos das marcações 31° e 146°. Para cada classe foram calculados 3400 espectros que foram separados em dados de treino (espectros ímpares), e dados 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 são mostrados nas figuras 7(a) e 7(b).

Após o treinamento, a rede foi usada para classificar os sinais originais e também os sinais misturados, representando uma aproximação em marcação dos contatos. A seguir, foi aplicado o pré-processamento com a ICA para a separação dos sinais e a rede foi aplicada também nestes sinais. O diagrama em blocos da figura 8 mostra como os sinais que foram pré-processados com a ICA para a realização da classificação.

A tabela 1 mostra a eficiência do classificador para as diversas condições de sinais, considerando os dados de teste. Para os sinais originais, o valor obtido foi de 94,3%. Quando se considera os sinais originais acrescido com o mesmo nível de ruído usado na mistura, obteve-se uma eficiência de 89%. Considerando os sinais misturados para a classificação, a rede teve seu desempenho reduzido para 82,7%. Quando se utilizou a ICA nos sinais mis-



(a)



(b)

Figura 7: Distribuições das classes: (a) Classe A (b) Classe B.



Figura 8: Diagrama em blocos da classificação utilizando pré-processamento com ICA

turados, a eficiência da rede para os dados separados subiu para 88%, próximo ao valor obtido para a situação antes da mistura, mas com a mesma SNR.

5 Conclusão

Neste trabalho, foram utilizados sinais obtidos em um sistema de sonar passivo para duas classes, 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. A rede foi testada com os sinais originais, com os sinais misturados e também com os sinais separados usando-se a análise de componentes independentes (ICA).

A mistura do sinal confundiu o classificador, reduzindo a eficiência obtida. O uso da ICA para

| Condição dos Sinais | Eficiência (%) |
|------------------------|----------------|
| Sinal de Teste | 94,3 |
| Com Mistura | 82,7 |
| Sem Mistura, com ruído | 89,0 |
| Com ICA | 88,0 |

Tabela 1: Tabela de Eficiência do Classificador Neural

separar os sinais se mostrou eficiente, melhorando o desempenho na classificação.

Para trabalhos futuros poderão ser utilizados um conjunto de dados reais que contenha a situação de mistura apresentada em forma de simulação neste trabalho. Além disso, deve-se considerar a realização do treinamento com as mesmas classes, porém, em condições de vibração diferentes, fazendo com que o classificador neural tenha uma capacidade de generalização ainda mais eficiente.

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.

Referências

- Burdic, W. S. (1984). *Underwater Acoustic System Analysis*, Prentice-Hall.
- Cardoso, J. F. (1998). *Blind signal separation: Statistical and principles*.
- E. O. Aapo Hyrinen, Juha Karhunen, O. (2001). *Independent Component Analysis*, John Wiley and Sons, New York.
- Haykin, S. (1999). *Neural Networks, A Comprehensive Foundation*, Prentice Hall, segunda edição.
- Nielsen, R. O. (1991). *Sonar Signal Processing*, Artech House Inc, Nortwood.
- Oja, A. H. E. (2000). *Independent component analysis: Algorithms and applications*. 13.
- P. S. R. Diniz, E. A. B. da Silva, S. L. N. (2002). *Digital Signal Processing: System Analysis an Design*, Cambridge University Press.
- Urick, R. (1983). *Principles of Underwater Sound for Engineers*, McGraw-Hill.
- W. Knight, R. Pridhan, S. K. (1981). *Digital signal processing for sonar*.
- Waite, A. D. (2003). *Sonar for practicing Engineers*, John Wiley and Sons, New York.
- Y. J. Zhen W., L. J. (2005). *Independent component analysis*.
- Yan, D. P. and J.Peach (2000). *Comparison of blind souce separation algorithms*.