Sistema de Sonar Passivo Utilizando Componentes Principais Não-Lineares

Rodrigo Coura Torres¹, José Manoel de Seixas¹, William Soares Filho²

¹Laboratório de Processamento de Sinais (LPS)
COPPE/EE/UFRJ, CP 68504, Rio de Janeiro 21945-970, Brasil
E-mails: {torres, seixas}@lps.ufrj.br

²IPqM - Instituto de Pesquisas da Marinha
R. Ipiru, 2, Rio de Janeiro 21931-090, Brasil

E-mail: wsoaresf@hotmail.com

Abstract

A detecção e a classificação de um navio podem ser feitas através do ruído irradiado pelo mesmo. Este ruído é conseqüência das vibrações das máquinas do seu interior e se propaga por longas distâncias na água. Neste trabalho, um sistema de classificação de navios foi implementado utilizando redes neurais. Como a dimensão do espaço de entrada de dados é bastante elevada (557 amostras), realizou-se a compactação dos mesmos utilizando componentes principais não-lineares, a fim de reduzir a complexidade da rede neural de classificação. Utilizando apenas 20 componentes não-lineares, uma eficiência de 90% foi obtida, enquanto que, se utilizássemos componentes principais lineares, seriam necessárias 50 componentes para atingir a mesma eficiência de classificação.

1 Introdução

Um dos problemas encontrados cada vez mais em projetos com classificadores é a dimensão elevada dos dados que devem ser classificados. Este problema tende a resultar em perda de eficiência por parte do sistema de detecção, cuja tarefa se mostra por demais complexa, além de produzir um aumento do custo do projeto, devido à necessidade de um hardware mais poderoso para a realização da tarefa. Neste aspecto, a análise de componentes principais surge como uma poderosa ferramenta que permite a compactação dos sinais a serem apresentados ao classificador. Este é o caso do projeto de um classificador de contatos de sonar passivo, que tipicamente utiliza um elevado número de amostras espectrais, adquiridas a partir da análise de Fourier em janelas temporais de duração pré-estabelecida, para alimentar o sistema classificador.

Para um submarino submerso, o som é a melhor forma de avaliar as ameaças a seu redor. Ondas eletromagnéticas, como as ondas de rádio e de luz, são atenuadas fortemente no meio oceânico, se propagando a poucas dezenas de metros. A onda sonora, por sua vez, se propaga por grandes distâncias, podendo viajar centenas de quilômetros, dependendo de sua freqüência e das ca-

racterísticas do meio.

O sistema de sonar (SOund NAvigation and Ranging) é o equipamento usado para analisar sons, captados no mar pelos seus sensores (hidrofones ou conjuntos de hidrofones). Navios anti-submarinos de superfície normalmente utilizam um sistema de sonar ativo para detectar um submarino. Neste sistema, o som é gerado propositadamente por um dos componentes do sistema, chamado projetor, que converte energia elétrica em energia sonora. As ondas sonoras do projetor viajam através do mar até um "alvo" e são refletidas, retornando como ecos até um hidrofone, que converte o som em um sinal elétrico. Sistemas de sonar ativo localizam e identificam seus alvos por meio do tempo de retorno do eco e da análise das modificações ocorridas neste eco, quando comparado ao sinal original enviado. Este sistema, no entanto, revela a presença da embarcação que o utiliza, devido ao som emitido, sendo evitado seu uso quando se deseja permanecer escondido.

Um submarino se vale de um sistema de sonar passivo, onde os seus sensores apenas "escutam" o ruído irradiado pelo alvo, ou "contato". Deste modo, apenas um caminho de transmissão pelo mar é envolvido e o sistema se centra no seu sensor, usado para captar os sons gerados pelo contato.

O ruído irradiado por um navio carrega consigo uma grande quantidade de informação a respeito dos equipamentos presentes no seu interior. Cada navio irradia um ruído diferente dos outros, sendo mais semelhantes quando os navios pertencem a uma mesma classe [1]. É possível, portanto, separar estes ruídos irradiados em classes, correspondendo às classes operacionais dos navios, e até mesmo identificar um navio dentro de sua classe, se houver informação suficiente. A detecção e a classificação em um sistema de sonar passivo são feitas pelo operador de sonar (OS). A complexa composição de diferentes fontes de ruído, devidas às embarcações já detectadas, ao ruído do próprio submarino e ao ruído ambiente, conjugada com a baixa probabilidade do surgimento de um sinal que possa ser associado a um contato de interesse, torna a tarefa do operador de sonar tremendamente cansativa.

O uso de meios automáticos de apoio à detecção e à classificação destes contatos reduz a carga sobre o

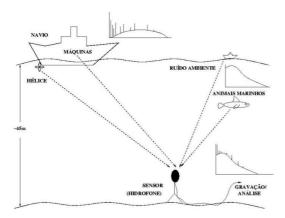


Figura 1: Diagrama esquemático de uma corrida de um navio na raia acústica.

OS, permitindo que ele se dedique à análise dos contatos que sejam realmente importantes e à confirmação das decisões tomadas pelos sistemas automáticos. As informações obtidas por um sistema automático podem ser usadas para dar início a diferentes atividades, como iniciar um acompanhamento automático ou alertar o operador, quando o contato detectado tiver algum interesse tático maior [2].

Este trabalho visa apresentar um método automático de detecção de classes de navios utilizando redes neurais. Este trabalho está dividido da seguinte forma: a sessão 2 explicará todo o processo de obtenção dos dados experimentais e o método de pré-processamento aplicado aos mesmos. A sessão 3 apresentará os detalhes relacionados ao conceito de componentes principais não-lineares. Já a sessão 4 apresentará os resultados obtidos com o método proposto e, por fim, o capítulo 5 apresentará as conclusões desta contribuição.

2 Aquisição dos Sinais

O conjunto de sinais selecionado para uso neste trabalho corresponde ao ruído irradiado por navios, adquirido em diversas corridas realizadas na raia acústica da Marinha do Brasil, em Arraial do Cabo, RJ. Cada corrida corresponde à passagem do navio sobre um hidrofone não direcional, posicionado próximo ao fundo, em um local com profundidade em torno de 45 metros. A fig. 1 mostra o diagrama de uma corrida na raia. Para cada corrida, o navio manteve rumo, velocidade e configuração de máquinas constantes. O navio iniciou sua corrida a cerca de 1000 metros antes do hidrofone e a encerrou a cerca de 500 metros após passar pelo ponto de maior aproximação do navio ao hidrofone. O sinal recebido pelo hidrofone foi gravado e posteriormente digitalizado, utilizando-se uma freqüência de amostragem de 22050Hz, com 16 bits de resolução de amplitude. Para cada corrida, foram selecionados trechos compostos de 557 amostras espectrais, que apresentassem características significativas dos navios e que pudessem ser importantes para a discriminação entre as classes. Um sistema de pré-processamento no

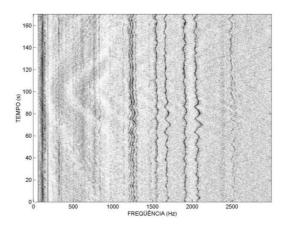


Figura 2: Mapa espectral de uma corrida.

domínio da frequência [3] permitiu a compactação inicial das amostras espectrais e a eliminação de ruído de fundo, utilizando-se o algoritmo TPSW (*Two Pass Splitted Window* [4]).

Foram escolhidos um total de 16 navios pertencentes a 8 classes diferentes (mínimo de 2 navios por classe). As classes foram identificadas por números (1 a 8). A fig. 2 mostra um mapa espectral de uma corrida de um dado navio. A escala horizontal corresponde ao eixo das freqüências e cobre a faixa de 0 a 2889,3 Hz. Pode-se notar no mapa a presença de linhas verticais que podem ser associadas às máquinas no interior do navio, sendo úteis na identificação.

3 Componentes Principais Não-Lineares

Como a análise de componentes principais (PCA) é um método linear [5] e muitos dos problemas reais são não-lineares, o uso de PCA linear em problemas não-lineares pode não representar o melhor enfoque de projeto para a compactação de sinais. Componentes principais não-lineares (NLPCA) generalizam a análise das PCAs, através da utilização de estatística de ordem superior, e podem conduzir a uma melhor eficiência de projeto.

Sabe-se que as últimas componentes principais (minoritárias) podem conter informações importantes. Se as componentes minoritárias forem descartadas, estas informações serão perdidas. Se, ao contrário, tais componentes forem mantidas, o conjunto de componentes pode tornar-se demasiado grande para a solução de um problema prático. Assim, o uso de um método PCA não-linear pode ajudar neste problema.

A NLPCA, assim como a PCA, é usada para identificar e remover correlação entre as variáveis de um problema, com auxílio na redução da dimensão, visualização e análise exploratória dos dados. Enquanto a PCA identifica apenas as correlações lineares entre as variáveis, a NLPCA descobre tanto a correlação linear quanto nãolinear, sem restrição quanto ao tipo de não-linearidade presente nos dados. Se houver correlação não-linear

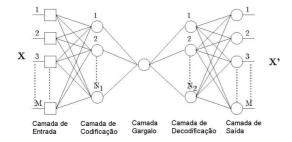


Figura 3: Rede para extração NLPCA.

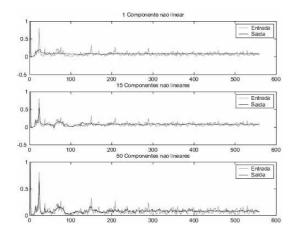


Figura 4: Exemplos de sinais reconstruídos após a projeção em 1, 15 e 50 componentes principais não-lineares.

entre as variáveis, a NLPCA descreverá os dados com maior acuidade e/ou com menos componentes que a PCA, desde que haja dados suficientes para justificar a formulação de funções de mapeamento mais complexas [6].

A fig. 3 apresenta a rede utilizada para a extração das componentes principais não-lineares. A rede é composta por três camadas escondidas, onde a primeira e a terceira devem ter a mesma quantidade de neurônios, uma vez que são as camadas de mapeamento dos dados. A segunda camada escondida é chamada de camada "gargalo", por ser a camada com o menor número de neurônios [7].

A fig. 4 pode dar uma melhor visualização do processo de decomposição em componentes principais nãolineares. O gráfico apresenta o sinal que é aplicado à rede de extração das NLPCAs e a saída gerada por esta rede, que é a reconstrução do sinal de entrada após a projeção em 1, 15 e 50 componentes.

4 Resultados

A fig. 5 apresenta as eficiências obtidas para diferentes números de componentes principais lineares e nãolineares. Observa-se que as eficiências de classificação, quando se utiliza componentes principais não-lineares, são sempre superior quando comparadas àquelas obti-

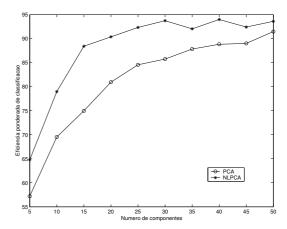


Figura 5: Eficiências de classificação para diferentes números de componentes principais.

das utilizando componentes principais lineares. Em [6], observou-se que com 33 componentes principais lineares, o sistema atingiu uma boa eficiência de classificação para apenas quatro classes de navios, sendo este resultado tomado como medida de desempenho. Observando a figura 5, nota-se que com 33 componentes principais lineares, a eficiência de classificação fica em torno de 85%. Assim, visando obter melhoras tanto na compactação de sinais, bem como na eficiência de classificação, decidiu-se utilizar 20 componentes principais não-lineares.

O classificador é uma rede neural com apenas uma camada escondida e treinamento supervisionado do tipo *backpropagation*, tendo oito neurônios na camada de saída. Nesta camada, cada neurônio é responsável por identificar uma classe¹.

Assim, as entradas da rede correspondem às projeções das informações espectrais, janela a janela, nas 20 primeiras componentes não-lineares. Configurando a rede com apenas 18 neurônios na camada escondida, reduzimos a rede para apenas 674 neurônios². Mesmo com tamanha redução na complexidade, este modo alcançou uma eficiência ponderada³ de 90,38%. Se projetássemos sinais de entrada nas componentes principais lineares, seriam necessárias 50 componentes para obter a mesma eficiência, o que prova mais uma vez o poder de concentração de energia que as componentes principais não-lineares possuem.

A tab. 1 apresenta a tabela de confusão gerada após a validação da rede, onde C_i representa o conjunto de sinais pertencentes a i-ésima classe que é aplicado à rede, e D_j representa o número de saídas (em valores percentuais) para a j-ésima classe. A última coluna apresenta o

¹A classe vencedora é a que apresenta o seu respectivo neurônio de saída com o valor mais alto (idealmente 1) para uma dada janela espectral.

²Uma redução de 98%, se compararmos com um classificador sem projeção em componentes principais composto de 557 neurônios na camada de entrada, 50 na camada escondida e 8 na camada de saída.

³A Eficiência ponderada é calculada pela média das eficiências das oito classes, sendo que cada eficiência é ponderada pelo total de eventos da classe a que pertence.

	D_1	D_2	D_3	D_4	D 5	D 6	D_7	D_8	Tot
C_1	91.51	0.00	5.98	0.39	0.00	1.54	0.00	0.58	518
C_2	0.00	84.74	3.73	0.16	0.81	1.46	3.41	5.68	616
C_3	9.48	0.89	84.62	0.72	0.18	1.07	1.07	1.97	559
C_4	0.91	0.73	0.73	92.32	0.00	1.65	2.74	0.91	547
C_5	0.00	0.87	0.35	0.00	98.08	0.17	0.17	0.35	572
C_6	1.50	0.37	1.50	0.19	0.00	93.27	0.56	2.62	535
C_7	0.19	3.08	0.77	1.73	0.77	0.77	90.00	2.69	520
$C \circ$	1.19	0.34	3.58	0.17	0.51	2.39	2.56	89.25	586

Tabela 1: Tabela de confusão para a rede NLPCA.

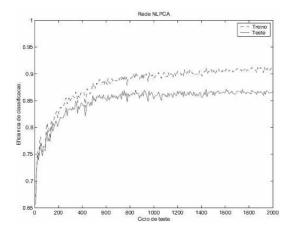


Figura 6: Variação da eficiência média ao longo do treinamento da rede NLPCA.

total de padrões de cada classe aplicados a rede.

A figura 6 apresenta as curvas de aprendizado médio deste modo, mostrando que a rede conseguiu uma boa generalização. Para melhor observação dos resultados obtidos com o classificador, a fig. 7 apresenta os histogramas gerados com as saídas obtidas em cada nó da camada de saída da rede para padrões pertencentes à classe representada por esta saída. Observa-se que todas as saídas concentram-se em torno do valor "1" ideal, indicando uma boa performance de classificação.

5 Conclusão

Foi desenvolvido um classificador neural para identificar classes de navios a partir do sinal de sonar passivo. O classificador utiliza a projeção espectral em componentes principais não-lineares, que, por utilizarem estatística de ordem superior, conseguem reter muito mais energia com menos componentes, quando comparadas com as componentes principais lineares. Assim, usando-se vinte componentes não-lineares, obtém-se uma eficiência de classificação melhor do que 90%, quando se consideram corridas experimentais de oito classes de navios.

O próximo passo para este trabalho seria a implementação em DSP deste sistema de classificação de navios, possibilitando a classificação *on-line* a um custo bastante reduzido.

Vale lembrar que componentes principais não apontam na direção de melhor discriminação dos dados, e sim na direção de maior energia, fazendo com que outras técnicas de compactação possam atingir resultados ainda melhores, como a compactação utilizando componentes principais de discriminação (PCD) [8, 9]. A

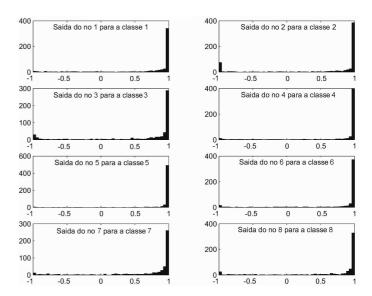


Figura 7: Saída da rede, mostrando a resposta do nó para cada classe a ele associada.

análise com PCD encontra-se atualmente em fase de desenvolvimento.

Agradecimentos

Gostaríamos de agradecer à CAPES, FAPERJ, CNPq e IPqM por todo apoio oferecido para a realização deste trabalho.

Referências

- [1] A. Rogoyski, F. Dawe, and M. Robinson. *Passive Sonar Data Processing*, chapter Underwater Defense Technology, pages 310–313. 1994.
- [2] IPQM. Ii workshop em acústica submarina. Conference report, Marinha do Brasil, Novembro 2002.
- [3] W. S. Filho. Uso de componentes principais para classificação em sonar passivo. II Workshop em Acústica Submarina, 2002.
- [4] R. O. Nielsen. Sonar Signal Processing. Artech, 1991.
- [5] S. Haykin. Neural Networks. A Comprehensive Foundation. Prentice Hall, 2nd edition, 1999.
- [6] W. S. Filho, J. M. de Seixas, and L. P. Calôba. Principal component analysis for classifying passive sonar signals. *IEEE International Symposium on Circuits and Systems*, 2001
- [7] M. A. Kramer. Nonlinear principal component analysis using autoassociative neural networks. *AIChE*, 37(2), February 1991.
- [8] W. S. Filho. Classificação do Ruído Irradiado por Navios Usando Redes Neurais. PhD thesis, UFRJ, 2001.
- [9] L. P. Calôba, J. M. de Seixas, and F. S. Pereira. Neural discriminating analysis for a second level trigger system. *Computing in High Energy Physics*, 1995.