

CLASSIFICAÇÃO DE SINAIS 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 / EP / UFRJ, CP 68504, Rio de Janeiro 21945-970, Brasil

E-mails: {torres, seixas}@lps.ufrj.br

²IPqM - Instituto de Pesquisas da Marinha

Rua Ipiru, 2, Rio de Janeiro 21931-090, Brasil

E-mail: wsoaresf@hotmail.com

Resumo – A detecção e a classificação de um navio podem ser feitas através do ruído irradiado pelo mesmo. Este ruído é consequência 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 uma rede neural atuando sobre informação espectral. Como a dimensão do espaço de entrada de dados é bastante elevada (557 amostras), realizou-se a compactação deste espaço através de componentes principais não-lineares, a fim de reduzir a complexidade da rede neural de classificação. Utilizando apenas 20 componentes não-lineares, uma eficiência de 90.0% foi obtida, enquanto que, se utilizássemos componentes principais lineares, seriam necessárias 48 componentes para atingir um nível similar de eficiência de classificação. Projetando-se a informação espectral em 33 componentes não-lineares, a eficiência de classificação se eleva para 94.0%.

Palavras Chaves – Sonar Passivo, Redes Neurais, Classificadores, Componentes Principais Não-Lineares, Análises de Componentes Principais, Compactação de Sinais.

Introdução

Um dos problemas encontrados em diversas áreas de aplicação, e cada vez com maior frequência, nos projetos com sistemas classificadores, é a dimensão elevada do espaço dos sinais de entrada 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 de aplicações *online*, devido à necessidade de um *hardware* mais poderoso para a realização da tarefa. Neste aspecto, a análise de componentes principais [1] surge como uma poderosa ferramenta de compactação da informação a ser apresentada ao classificador. Descrevendo a informação de entrada em componentes estatisticamente ortogonais que podem ser extraídas ordenadamente, com base na energia que concentram, a dimensão do espaço original tipicamente é reduzida de forma significativa. Este é o caso do projeto de um classificador de contatos de sonar passivo, que usualmente 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 [2].

Para um submarino submerso, o som é a melhor forma de avaliar as ameaças ao 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 frequência e das características do meio [3].

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 ao sistema, captados por meio de 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 comparadas ao sinal original enviado [4]. Este sistema ativo, no entanto, revela a presença da embarcação que o utiliza, devido ao som emitido, sendo evitado seu uso quando se deseja permanecer oculto, como é o caso de um submarino.

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 demais, havendo maior semelhança quando os navios pertencem a uma mesma classe [5]. É possível, portanto, separar os sinais de ruído irradiado 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, devida às embarcações já detectadas, ao ruído do próprio submarino e ao ruído ambiente, conjugadas 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 e desgastante.

O uso de meios automáticos de apoio à detecção e à classificação destes contatos reduz a carga sobre o 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 meio de 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 [6]. Entretanto, devido à necessidade de funcionamento *online* do sistema e à grande complexidade deste problema de classificação, torna-se atraente a compactação dos dados de entrada para reduzir a complexidade computacional de um sistema deste tipo.

Este trabalho visa apresentar um método automático de detecção de classes de navios utilizando redes neurais. De forma a compactar significativamente a informação pré-processada que alimenta o classificador neural, propõe-se o uso de componentes principais não-lineares, que são extraídas também por meio de processamento neural. Uma comparação com a análise de componentes principais (lineares) clássica é também apresentada, em termos de eficiência de compactação. A classificação de contatos se dá para oito classes de navios, a partir da análise espectral de corridas experimentais que cobrem diferentes navios e condições operacionais diversas.

Este trabalho está dividido em cinco seções. A Seção 1 explica todo o processo de obtenção dos dados experimentais e o método de pré-processamento empregado. A Seção 2 faz uma rápida revisão da análise de componentes principais (PCA) e apresenta os detalhes relacionados ao conceito de componentes principais não-lineares (NLPCA) e sua extração neural. Já a Seção 3 se concentra nos resultados obtidos com o método proposto. A Seção 4 apresenta uma análise comparativa dos métodos de compactação PCA, NLPCA e a performance dos respectivos classificadores em relação a um classificador alimentado pela informação completa, sem qualquer compactação. Por fim, a Seção 5 apresenta as conclusões do trabalho.

1 Aquisição dos Sinais e Pré-Processamento

O conjunto de sinais utilizado neste trabalho corresponde ao ruído irradiado por oito classes de navios, ruído este adquirido através de diversas corridas realizadas numa raia acústica da Marinha do Brasil. Cada corrida corresponde à passagem do navio (sob uma dada condição operativa) sobre um hidrofone não direcional, posicionado próximo ao fundo, em um local com profundidade em torno de 45 metros. A Figura 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 em relação ao posicionamento do hidrofone e a encerrou a cerca de 500 metros após atingir o ponto de sua maior aproximação com respeito ao hidrofone. O sinal recebido pelo hidrofone foi gravado e posteriormente digitalizado, utilizando-se uma frequência de amostragem de 22050Hz, com 16 bits de resolução de amplitude.

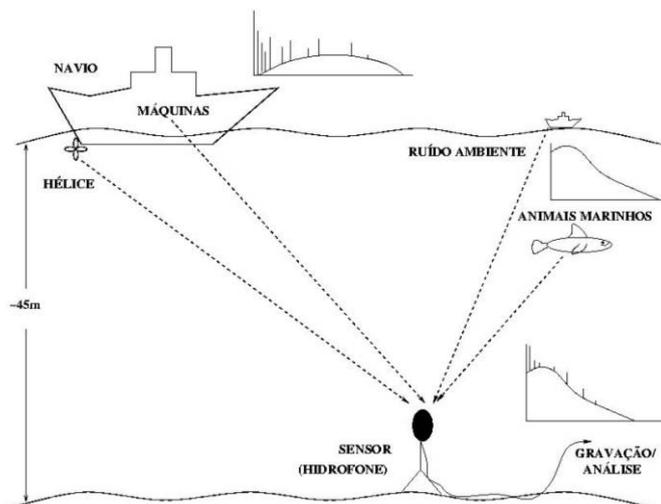


Figura 1 Diagrama esquemático de uma corrida de um navio na raia acústica.

A Figura 2 mostra o diagrama em blocos do pré-processamento aplicado ao ruído irradiado pelos navios, para produzirem-se os espectros a serem usados na classificação. O sinal foi, inicialmente, decimado por 2, reduzindo-se a frequência de amostragem para 11025 Hz. O filtro usado para a decimação foi um filtro passa-baixas Chebyshev tipo I de oitava ordem, com banda de passagem indo até 5 kHz, e possuindo uma atenuação de cerca de 60 dB em 6 kHz, com o objetivo de assegurar a ausência de *aliasing* na banda de passagem. Após a decimação, o ruído foi separado em blocos de 2048 pontos, os quais foram transformados para o domínio da frequência usando-se a transformada rápida de Fourier (FFT), após

multiplicação por uma janela de Hanning [7]. O módulo do espectro obtido foi normalizado e usado ao longo do trabalho. A normalização foi feita estimando-se o ruído de fundo presente em cada espectro, usando-se o algoritmo TPSW (*Two-Pass Split-Window*) [6] e dividindo-se a janela espectral, amostra a amostra, por esta estimativa. Este procedimento, além de remover tendências de variação lenta no espectro, equaliza os tons presentes, de forma que suas amplitudes, em todo o espectro, tendem a se uniformizar. A Figura 3 mostra um espectro de ruído irradiado por um navio antes e após a normalização pelo algoritmo TPSW. Para cada espectro, foram retidas as 557 primeiras amostras, cobrindo a faixa de frequência de 0 a 2998.5 Hz, para serem usadas como informação de entrada do classificador neural. Nesta faixa de frequência se encontra a maioria dos tons gerados no interior do navio que são importantes na discriminação entre as diversas classes.

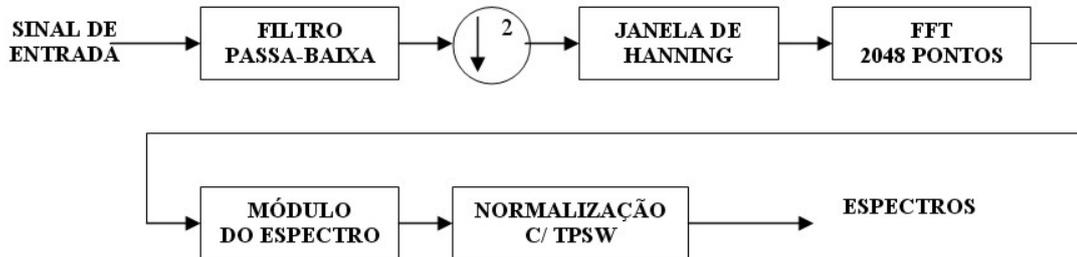


Figura 2 Diagrama em blocos do pré-processamento realizado para a obtenção dos espectros do ruído irradiado pelos navios.

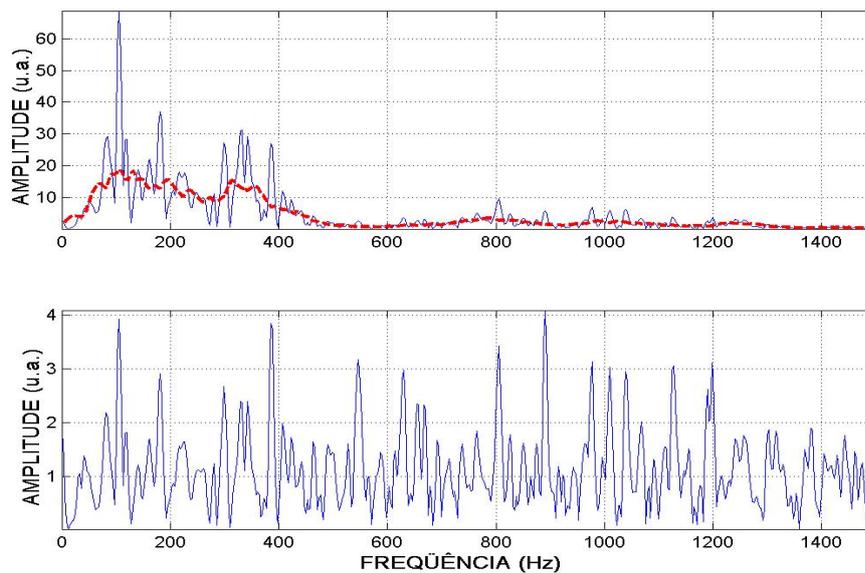


Figura 3 Um espectro típico do ruído irradiado por um navio, antes da normalização (em cima) e o resultado da sua normalização pelo algoritmo TPSW (em baixo). A linha tracejada sobre o espectro do gráfico superior corresponde ao ruído de fundo estimado pelo algoritmo para este mesmo espectro.

Um total de 16 navios pertencentes a 8 classes diferentes (dois navios por classe) fizeram as corridas na raia acústica. As classes foram identificadas por números (1 a 8), sem se utilizar qualquer informação prévia destas classes no projeto do classificador neural. A Figura 4 mostra o mapa espectral pré-processado de uma corrida de um dado navio. A escala horizontal corresponde ao eixo das frequências e cobre a faixa de 0 a 2998.5 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.

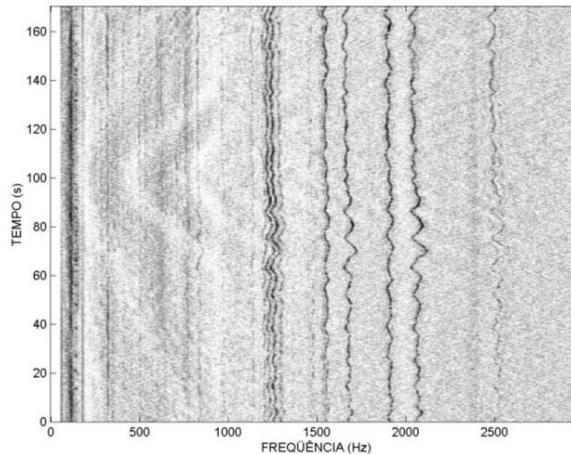


Figura 4 Mapa espectral de uma corrida.

2 Análise de Componentes Principais

2.1 Componentes Principais Lineares (PCA)

Um problema comum às tarefas de reconhecimento de padrões estatísticos é a seleção de características relevantes. Assim, o espaço original de dados é transformado em um espaço de características, as quais, pressupostamente, são capazes de descrever eficientemente o problema em questão. Eventualmente, esta transformação para o espaço de características pode ser desenvolvida de tal modo que haja uma compactação da informação, fazendo com que o espaço de características tenha uma dimensão reduzida em relação ao espaço original de dados. Ou seja, o conjunto original de dados passa por uma redução dimensional [1].

A análise de componentes principais lineares (PCA) oferece compactação eficiente e tem tido uma ampla aplicação em problemas práticos. Nesta análise, a transformação utiliza a matriz de auto-correlação do processo estocástico abordado [8]. Assim, esta técnica busca as direções ortogonais que representam o processo como um todo. Essas direções são os autovetores do processo, sendo que os respectivos autovalores correspondem à energia (variância) concentrada em cada direção. As componentes principais lineares são justamente esses autovetores, ordenados pela quantidade de energia que retêm, de forma que a primeira componente é a que contém a maior quantidade de energia do processo. Assim, com uma transformação linear que representa um processo em direções ortogonais ordenadas pela energia, torna-se possível a compactação eficiente de um sinal oriundo de uma realização do processo, através do descarte das componentes que retenham menor energia, o que minimiza a perda de informação devido a esta compactação.

As componentes principais lineares podem ser extraídas por métodos numéricos convencionais, ou através de modelos neurais, com possibilidade de extração seqüencial ou simultânea [9].

2.2 Componentes Principais Não-Lineares (NLPCA)

Como a análise de componentes principais (PCA) é um método linear [10], o uso de PCA pode não representar o melhor enfoque de projeto para a compactação de sinais, uma vez que a PCA observa apenas momentos de primeira e segunda ordem (média e variância). Entretanto, componentes principais não-lineares (NLPCA) generalizam a análise das PCAs, através da utilização de estatística de ordem superior, podendo, assim, conduzir a uma melhor eficiência de projeto.

A NLPCA, assim como a PCA, é usada para identificar e remover a correlação entre variáveis, auxiliando na redução da dimensão, visualização e análise exploratória dos dados. Enquanto a PCA identifica apenas as correlações lineares entre as variáveis, a NLPCA é capaz de lidar com a correlação não-linear, sem restrição prática quanto ao tipo de não-linearidade presente nos dados. Se houver correlação não-linear entre as variáveis, a NLPCA descreverá os dados com maior acuidade e/ou com menos componentes que a PCA, desde que haja dados estatisticamente suficientes para justificar a formulação de funções de mapeamento mais complexas [11].

Na PCA, $S = XU$ (onde X é o conjunto de entradas, U é a matriz com as componentes principais do processo e S é a projeção da entrada nas componentes principais) representa a transformação da entrada no espaço de características. Na NLPCA, o mapeamento no espaço de características é generalizado para permitir funções não-lineares.

$$S = G(X) \quad (1)$$

onde G é um vetor de funções não-lineares, de tal forma que:

$$S_i = G_i(X) \quad (2)$$

e G_i é a i -ésima componente não-linear.

A transformação inversa, restaurando a dimensão original do espaço de entrada, é implementada por um segundo vetor de funções não-lineares, $\mathbf{H} = H_1, H_2, \dots, H_M$, sendo que

$$X'_j = H_j(S) \quad (3)$$

e a perda de informação, ou erro, é medida por

$$E_t = E[(X - X')^2] \quad (4)$$

As funções G e H são selecionadas para minimizar E_t (erro médio quadrático), como na PCA.

2.2.1 Rede Autoassociativa de 5 Camadas

Como dito acima, G e H são vetores de funções não-lineares. Como sabemos [12], redes neurais artificiais podem implementar uma vasta gama de funções não-lineares, de forma que esta característica pode ser usada para propor uma rede para obtenção de componentes principais não-lineares [13]. Assim, as funções G e H foram modeladas, cada uma, por uma rede neural com uma camada escondida. A rede que obtém o mapeamento G opera nas linhas do vetor de entrada X e tem, assim, M entradas. A camada escondida de G , chamada de camada de codificação, contém N_1 nós com função de ativação sigmoideal. A saída da rede, S , é a projeção do vetor de entrada no espaço de características e, portanto, contém K nós. Os nós da camada de saída podem ter função de ativação linear ou sigmoideal. A função G_i , o i -ésimo fator não-linear, é definido pelos pesos e polarizações nas conexões da entrada à i -ésima saída.

A rede representando a função de decodificação (mapeamento inverso) H usa as linhas de S como entrada e, portanto, tem K entradas. A camada escondida, chamada de camada de decodificação, tem N_2 nós com função de ativação sigmoideal. A camada de saída produz o dado reconstruído X' e, portanto, contém M nós. Os nós da camada de saída podem ser lineares ou sigmoideais. Os pesos e polarizações conectando as entradas à saída i definem a função H_i .

As redes usadas para gerar os mapeamentos G e H requerem treinamento supervisionado. No entanto, ao treinar a rede representando G , a saída S desejada é desconhecida. Para a rede representando H , as saídas desejadas são conhecidas (correspondendo à entrada X da rede para G), mas as entradas correspondentes, S , não são. Como a saída da rede para G e a entrada da rede para H são as mesmas (S), as duas redes foram combinadas formando, agora, uma única rede de cinco camadas, com $N_1 = N_2$.

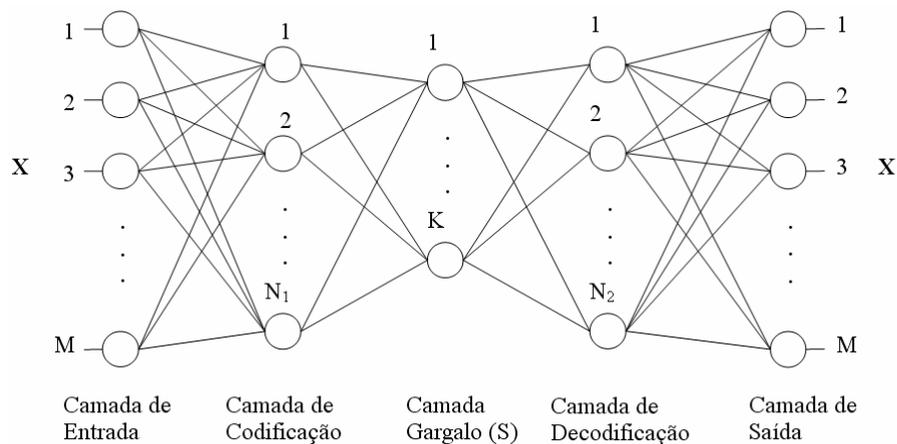


Figura 5 Rede para extração NLPCA.

A rede combinada, mostrada na Figura 5, contém três camadas escondidas: a camada de codificação, envolvida na representação do mapeamento G , a camada gargalo, cujas saídas representam S , e a camada de decodificação, requerida para modelar H . As camadas de entrada e saída representam X e X' , respectivamente. Os nós das camadas gargalo e de saída podem ser tanto lineares quanto não-lineares (desde que a função de ativação não-linear usada na saída abranja a faixa dinâmica do sinal da entrada). A rede é uma rede auto-associativa, treinada usando-se o algoritmo *backpropagation* [1] para reproduzir o

vetor de entrada na sua saída.

Após o treinamento, a rede combinada não tem mais utilidade e é desagregada em duas redes, cada uma com uma camada escondida, representando G e H . Na maioria das aplicações, G é a função de interesse, uma vez que é ela que realiza o mapeamento dos padrões de entrada no espaço de características, formando a entrada do classificador de padrões.

Duas formas diferentes têm sido usadas para treinar a rede NLPCA: simultânea e seqüencial. Na forma simultânea, cria-se a rede com o número de neurônios na camada gargalo igual ao número de componentes principais não-lineares que se deseja obter. A rede é, então, treinada para mapear a saída igual à entrada (mapeamento identidade). Já no modo seqüencial, apenas uma componente é extraída por vez. Primeiramente extraímos a primeira componente, e para a extração da segunda, calculamos o resíduo correspondente à saída da rede com a entrada anterior [13]. O processo então continua até a extração de todas as componentes desejadas ter terminado.

2.2.2 Extração das Componentes Principais Não-lineares

Neste trabalho, foi usado o método simultâneo de extração das NLPCAs. O número de padrões utilizados em cada classe, nas fases de treino e teste, está descrito na Tabela 1.

Classe	1	2	3	4	5	6	7	8	Total
Treino	1088	1244	1106	1063	1119	1065	1077	1120	8882
Teste	1076	1232	1097	1052	1110	1055	1066	1107	8795

Tabela 1 Apresentação do número de eventos de cada classe para as fases de treinamento e teste.

Como visto na Seção 1, cada corrida dá origem a vários eventos (padrões) de entrada do sistema classificador, devido a utilização de janelamento para análise espectral. Porém, os dados de treinamento e teste foram separados por corridas, e não pelos eventos oriundos das mesmas. Assim, se uma corrida qualquer é destinada ao conjunto de treinamento, todos os eventos que a mesma contém poderão ser utilizados somente no treinamento. Com isso, o sistema ganha em generalização, uma vez que será assegurado que existirão eventos de teste totalmente inéditos à rede, conforme se requer numa operação prática.

A rede neural utilizada para esta extração possui 557 nós na camada de entrada e, conseqüentemente, 557 neurônios na camada de saída. Além disso, há 60 neurônios na primeira e terceira camadas escondidas (camadas de codificação e decodificação, respectivamente), e a função de ativação utilizada na rede foi a tangente hiperbólica. Como dito antes, a segunda camada escondida (camada gargalo) é a que determina o número de componentes não-lineares que serão extraídas. Assim sendo, o algoritmo de extração das NLPCAs foi executado para diversos números de neurônios na camada gargalo, obtendo-se, assim, números diferentes de componentes principais extraídas. As Figuras 6 e 7 podem dar uma melhor visualização do processo de decomposição em componentes principais. Cada 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 (Figura 6). A Figura 7 apresenta a mesma análise, porém projetando o sinal de entrada nas componentes lineares do processo (extraídas por método numérico), para efeito de comparação. Pode-se, assim, observar que há uma melhor reconstrução a partir das NLPCAs.

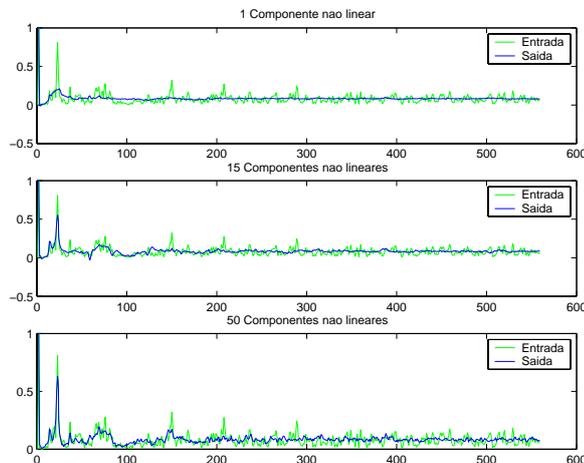


Figura 6 Exemplos de sinais reconstruídos após a projeção em 1, 15 e 50 componentes principais não-lineares.

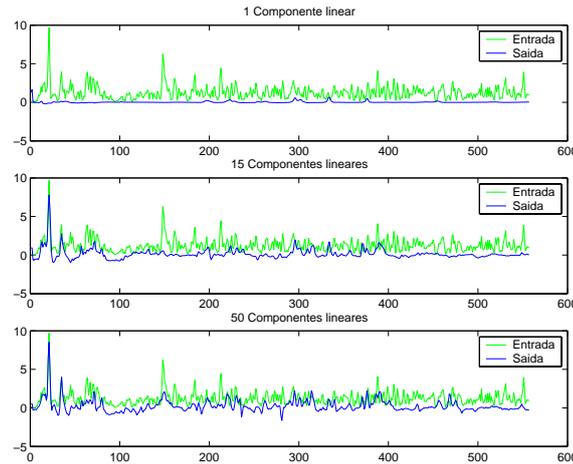


Figura 7 Exemplos de sinais reconstruídos após a projeção em 1, 15 e 50 componentes principais lineares.

3 Resultados

No contexto de classificação de sinais de sonar passivo, há uma natural restrição para a aquisição de dados experimentais, considerando-se a complexidade logística requerida para moverem-se navios em direção à raia acústica, a variedade de classes de contactos existentes e as diferentes condições operativas que são típicas para cada classe que se deseja detectar. Assim, durante a aquisição de sinais, algumas classes acabam sendo representadas por várias corridas, devido às diferentes condições operativas. Outras classes, entretanto, podem ter tido um número menor de corridas adquiridas, o que pode significar que uma dada classe possa estar mal representada do ponto de vista estatístico. Por outro lado, apesar de ser representada por um número reduzido de corridas, uma dada classe pode possuir interesse tático significativo, de tal forma que a eficiência de classificação para esta classe não deve ser menosprezada.

Desta maneira, uma avaliação de desempenho de um classificador de sinais de sonar passivo pode levar em conta tais aspectos de projeto que se referem à importância diferenciada das classes de contactos e a representação estatística de cada classe. Assim, neste trabalho, foram utilizadas duas figuras de mérito para o cálculo da eficiência de classificação de contactos.

A primeira figura de mérito, aqui referida como eficiência absoluta, é obtida através da relação:

$$E_a = \frac{1}{8} \sum_{i=1}^8 \frac{N_{ci}}{N_{ti}} \quad (5)$$

onde N_{ci} é o número de eventos (janelas espectrais) da i -ésima classe classificados corretamente pela rede neural classificadora, e N_{ti} representa o número total de eventos da i -ésima classe apresentados ao classificador. Nesta abordagem, a eficiência nada mais é do que a média aritmética das eficiências de cada classe.

A segunda figura de mérito, referida como eficiência ponderada, é obtida pela seguinte relação:

$$E_p = \sum_{i=1}^8 \frac{N_{ci}}{N_{ev}} \quad (6)$$

onde N_{ci} representa o número de eventos corretamente classificados da i -ésima classe, e N_{ev} representa o número total de eventos apresentados ao classificador, considerando todas as classes de padrões. A eficiência ponderada, como visto pela sua expressão, pondera a eficiência do sistema classificador para cada classe pelo número de eventos avaliados de cada classe. Com isso, classes que estejam representadas por um pequeno número de corridas não contribuirão de maneira significativa para o cálculo da eficiência. Uma maior importância é, então, dada às classes com maior diversidade de condições operativas, por serem representadas com um maior número de corridas.

O classificador de sinais de sonar passivo utilizado é uma rede neural com apenas uma única 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. A entrada da rede é formada pela projeção da informação espectral pré-processada nas suas componentes principais não-lineares. No treinamento, apenas uma saída é feita ativa, de acordo com a classe de contato usada para alimentar a rede neural.

A Figura 8 apresenta as eficiências ponderadas obtidas para diferentes números de componentes principais lineares e não-lineares. Observa-se que as eficiências de classificação, quando se utilizam componentes principais não-lineares, são sempre superiores quando comparadas àquelas obtidas utilizando a análise de componentes principais lineares. Em [11], observou-se que, com 33 componentes principais lineares, o sistema neural atingiu uma boa eficiência de classificação para apenas quatro classes de navios, sendo este resultado tomado como medida de desempenho neste trabalho. Observando a Figura 8, nota-se que com 33 componentes principais lineares, a eficiência ponderada de classificação fica em torno de 85.0%. Com 33 componentes não-lineares, a eficiência ponderada de classificação sobe para 94.0%. A taxa de compactação obtida pela NLPCA é, portanto, bastante atraente para o objetivo de classificação. Por outro lado, nove pontos percentuais é uma diferença bastante significativa para a aplicação em discussão, considerando-se que o sistema atuará como apoio à decisão do operador de sonar, o que exige um elevado nível de confiabilidade. Adicionalmente, modelos parcimoniosos, que produzem redes neurais mais compactas, no caso dos classificadores com NLPCA, são preferíveis, do ponto de vista da estatística disponível para o problema [14]. Assim, visando obter um melhor compromisso entre a compactação de sinais (velocidade de processamento) e a eficiência de classificação, decidiu-se utilizar 20 componentes principais não-lineares, visto que este número atende aos dois requisitos. Como critério de parada do treinamento, utilizou-se o erro médio quadrático obtido para o conjunto de teste, ao longo do treinamento.

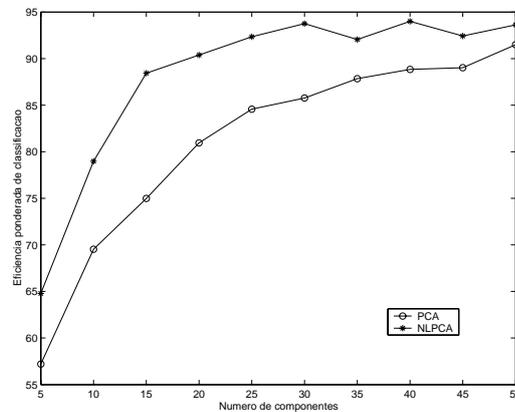


Figura 8 Eficiências ponderadas de classificação para diferentes números de componentes principais.

Assim, as entradas da rede classificadora correspondem às projeções das informações espectrais, janela a janela, nas 20 primeiras componentes não-lineares. Configurando-se a rede com apenas 19 neurônios na camada escondida, reduzimos a rede para apenas 559 pesos². Mesmo com tamanha redução na complexidade, este modelo alcançou uma eficiência ponderada de 90.4% para o conjunto de teste. Se projetássemos os sinais de entrada nas componentes principais lineares, seriam necessárias, aproximadamente, 48 componentes para se obter eficiência semelhante, o que prova mais uma vez o poder de concentração de energia que as componentes principais não-lineares possuem.

	D ₁	D ₂	D ₃	D ₄	D ₅	D ₆	D ₇	D ₈
C ₁	90.4	0.1	7.2	0.4	0.2	0.7	0.3	0.7
C ₂	0.1	90.0	1.1	1.2	0.7	0.1	3.2	3.7
C ₃	9.3	0.7	84.3	1.2	0.3	1.5	0.5	2.2
C ₄	0.2	1.3	1.0	91.8	0.1	1.2	1.7	2.6
C ₅	1.0	0.4	0.5	0.3	95.2	1.4	0.4	0.9
C ₆	1.2	0.2	1.5	0.2	0.6	93.6	0.3	2.4

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

2 Uma redução de 98%, se compararmos com um classificador utilizando informação não compactada e composto por 557 nós de entrada, 50 neurônios na camada escondida e 8 na camada de saída.

C_7	0.3	3.1	0.8	3.5	0.8	0.4	89.3	1.9
C_8	0.3	2.1	1.9	0.7	0.2	2.5	3.8	88.5

Tabela 2 Tabela de confusão para a rede NLPCA, usando 20 componentes.

A Tabela 2 apresenta a matriz de confusão gerada para o conjunto de teste após a validação da rede, onde C_i representa o conjunto de dados de teste pertencentes a i -ésima classe e que são apresentados ao classificador. D_j representa o número percentual de vezes que a j -ésima classe é detectada para um conjunto de dados de entrada C_i . Idealmente, deveríamos ter a diagonal principal da matriz com valores iguais a 100%. Os valores percentuais nas colunas D_j , para $j \neq i$, representam o erro de detecção pra um dado conjunto C_i . A última coluna apresenta o total de padrões aplicados à rede, para cada classe.

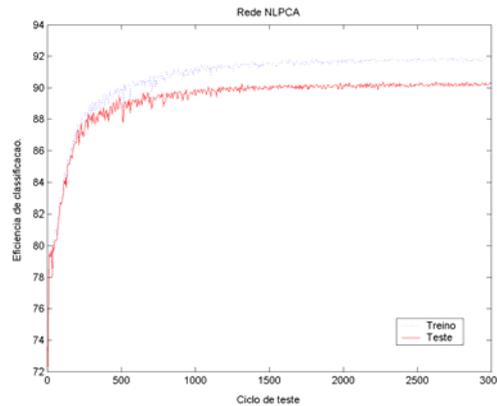


Figura 9 Variação da eficiência absoluta ao longo do treinamento da rede utilizando a projeção nas 20 primeiras componentes não-lineares.

A Figura 9 apresenta as curvas de aprendizado médio deste modelo baseado nas projeções nas componentes não-lineares, mostrando que a rede conseguiu uma boa generalização. A eficiência absoluta, ao final, também alcançou 90.4%, mostrando que as eficiências obtidas pelo classificador e o número de eventos em cada classe equilibram-se de tal maneira que o resultado encontrado foi igual ao obtido com a figura de mérito da eficiência ponderada.

Para melhor observação dos resultados obtidos com o classificador neural, a Figura 10 apresenta os histogramas gerados com as saídas obtidas em cada nó da camada de saída da rede para padrões pertencentes à classe que o respectivo nó procura representar. Observa-se que as distribuições concentram-se em torno do valor “1” ideal, indicando uma boa performance de classificação.

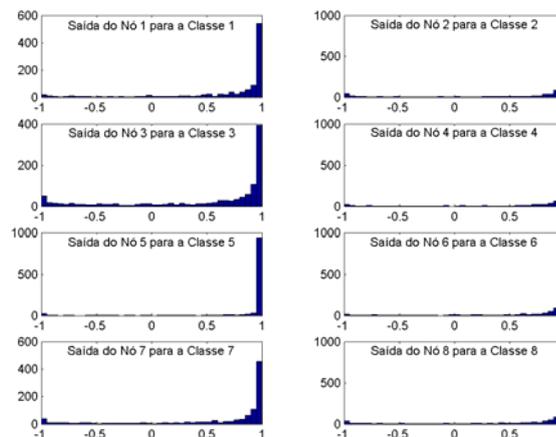


Figura 10 Saída da rede classificadora, mostrando a resposta de cada nó de saída para os padrões de teste da classe que ele está associada.

4 Comparação Entre Modelos

Nesta sessão, são apresentados os resultados comparativos com a projeção NLPCA de dois outros enfoques de projeto de classificador neural:

- **Sem compactação** → No qual os dados pré-processados de entrada são aplicados diretamente à rede, sem nenhum tipo de compactação.
- **PCA** → Onde os dados pré-processados de entrada são projetados nas componentes principais lineares do processo. Em ambos os modelos, a função de ativação dos neurônios foi a tangente hiperbólica.

4.1 Sem Compactação

Para este modelo, utilizamos todas as amostras espectrais que são produzidas pelo sistema de pré-processamento. Assim sendo, a rede classificadora possui 557 nós na camada de entrada. Optou-se por utilizar 50 neurônios na camada escondida. Assim, após o treinamento, a eficiência ponderada da rede ficou em 94.5%, para o conjunto de teste. A Tabela 3 apresenta a tabela de confusão gerada para o conjunto de teste neste modo. Como podemos perceber, com a exceção da classe 3, que foi confundida um número maior de vezes com a classe 1, todas as classes tiveram índices de acerto superiores a 90%.

	D ₁	D ₂	D ₃	D ₄	D ₅	D ₆	D ₇	D ₈
C ₁	94.2	0.1	4.3	0.5	0.1	0.7	0.1	0.1
C ₂	0.2	96.1	0.6	0.7	0.2	0.0	1.2	0.9
C ₃	7.1	1.1	86.5	0.9	0.6	0.8	0.5	2.4
C ₄	0.1	0.2	0.6	95.8	0.3	0.8	1.2	1.0
C ₅	0.5	0.4	0.5	0.8	96.5	0.3	0.0	1.1
C ₆	0.9	0.1	1.3	0.2	1.1	95.4	0.1	0.9
C ₇	0.1	1.0	1.2	0.6	0.6	0.1	96.1	0.4
C ₈	0.2	0.6	1.4	0.4	0.5	0.8	0.5	95.8

Tabela 3 Tabela de confusão para a rede classificadora alimentada com a informação completa.

A Figura 11 apresenta a curva de aprendizado da rede sem compactação. Observando as curvas de treinamento e teste, podemos concluir que a rede, embora tenha obtido um percentual de acerto bastante elevado, apresentou uma considerável diferença entre as eficiências médias de treinamento e teste, quando comparada com os demais modelos. Este problema pode ser relacionado ao grande número de neurônios que esta rede apresenta, exigindo um elevado grau de liberdade, que não é compatível com as restrições estatísticas resultantes da aquisição de sinais. Este problema, e o alto custo computacional que uma rede deste tamanho possui (28308 pesos), são os principais motivos para considerarmos formas de compactação do sinal de entrada, visando reduzir a complexidade da rede. Desta forma, o resultado obtido com NLPCA passa a ser bastante atraente, pois atinge um bom nível de eficiência de classificação, com elevada capacidade de compactação, favorecendo a generalização do treinamento e a operação *online* requerida para a classificação de contatos. Os histogramas com os valores dos neurônios de saída para a rede operando sem compactação estão na Figura 12, confirmando a qualidade de sua classificação.

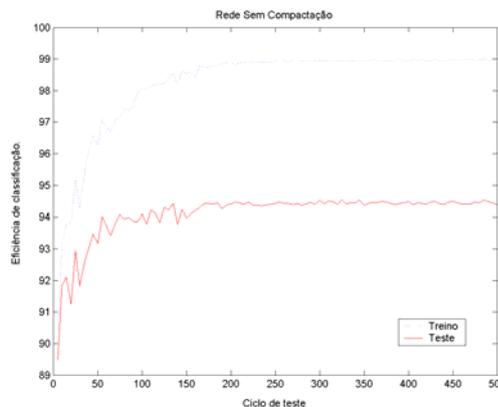


Figura 11 Variação da eficiência absoluta ao longo do treinamento da rede alimentada com a informação não compactada.

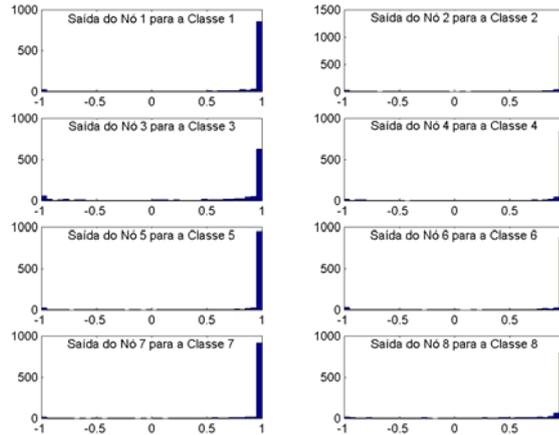


Figura 12 Saída da rede para dados não compactados, mostrando a resposta de cada nó de saída para a classe a ele associada, considerando-se o conjunto de teste.

4.2 Rede PCA

Levando em consideração a Figura 8, e desejando-se manter a eficiência de classificação elevada, uma rede neural foi treinada com dados obtidos através da projeção nas 50 primeiras componentes principais lineares do processo. Considerando, nesta implementação, apenas 25 neurônios na camada escondida, a rede classificadora possui apenas 1483 pesos, o que representa uma redução de quase 95% no número de pesos, em relação ao classificador que opera sobre a informação não compactada. Após o treinamento, a rede obteve uma média de eficiência ponderada de 91.4%, para o conjunto de teste, o que é um valor bastante satisfatório, considerando-se o ganho com a redução da complexidade da rede e o conseqüente aumento na velocidade de classificação. A Tabela 4 apresenta a tabela de confusão obtida para o conjunto de teste, após o treinamento da rede.

	D ₁	D ₂	D ₃	D ₄	D ₅	D ₆	D ₇	D ₈
C ₁	91.1	0.2	6.0	0.2	0.5	1.1	0.3	0.7
C ₂	0.2	90.5	0.9	1.3	0.6	0.2	4.1	2.3
C ₃	9.2	0.8	83.9	1.3	0.4	1.5	0.8	2.2
C ₄	0.2	1.6	0.7	93.8	0.1	1.2	1.1	1.2
C ₅	0.3	0.7	0.6	0.3	96.6	0.5	0.1	1.0
C ₆	1.4	0.0	1.9	0.3	0.9	93.5	0.4	1.6
C ₇	0.0	3.8	1.5	2.4	0.5	0.0	90.7	1.1
C ₈	0.8	2.3	1.2	0.7	0.7	1.2	1.8	91.3

Tabela 4 Tabela de confusão para a rede utilizando componentes principais lineares.

Novamente, somente a classe 3 ficou abaixo de 90% de eficiência, por ter sido confundida um número considerável de vezes com a classe 1. A Figura 13 apresenta a evolução do treinamento para este modo. Desta vez, a extração das componentes principais permitiu uma melhor generalização da rede, tornando o sistema mais robusto, de maneira análoga ao ocorrido quando se utilizaram as componentes principais não-lineares. Deve-se destacar que a eficiência alcançada quando se projeta o espaço original nas componentes lineares se baseou no uso de 50 componentes, enquanto que o uso de componentes não-lineares atinge um resultado relativamente próximo com apenas 20 componentes.

Os histogramas com os valores dos neurônios de saída da rede classificadora baseada em componentes lineares estão na Figura 14.

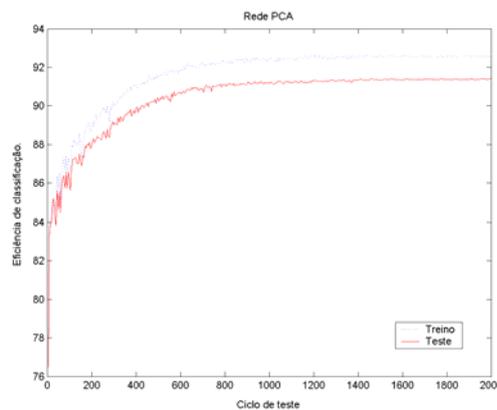


Figura 13 Variação da eficiência absoluta ao longo do treinamento da rede utilizando componentes principais lineares.

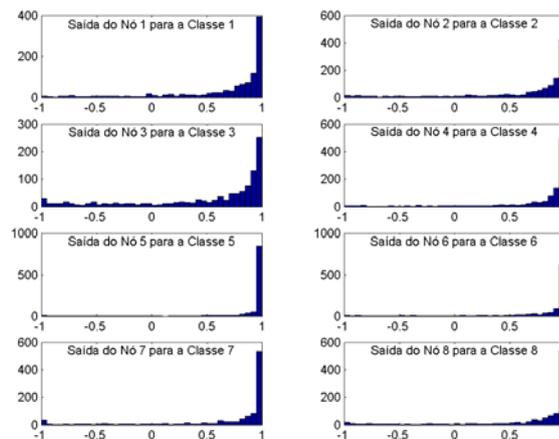


Figura 14 Saída da rede usando componentes principais lineares, mostrando a resposta de cada nó de saída para a classe a ele associada, considerando-se o conjunto de teste.

5 Conclusão

Foi desenvolvido um classificador neural para identificar classes de navios a partir do sinal adquirido por um sistema de sonar passivo. O classificador utiliza a projeção espectral em componentes principais não-lineares, que, por utilizarem estatística de ordem superior, conseguem reter uma fração significativa da energia da informação de entrada num número relativamente reduzido de componentes, quando se compara com a capacidade de compactação da análise de componentes principais lineares. Assim, usando-se apenas vinte componentes não-lineares, obtém-se uma eficiência ponderada de classificação melhor do que 90%, quando se consideram corridas experimentais de oito classes de navios.

Apresentaram-se, também, sistemas classificadores sem compactação dos dados de entrada e com compactação através das componentes principais lineares, mostrando, através dos resultados obtidos, que o sistema baseado em componentes principais não-lineares apresenta uma boa eficiência de classificação, aliada a uma taxa de compactação bastante significativa.

O próximo passo neste trabalho será a implementação, na tecnologia dos processadores digitais de sinais (DSPs), deste sistema de classificação de navios, possibilitando a classificação *online* 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 que utiliza componentes principais de discriminação (PCD) [15]. A análise com PCD encontra-se, atualmente, em fase de desenvolvimento.

6 Agradecimentos

Gostaríamos de agradecer ao CNPq, CAPES, FAPERJ e ao Instituto de Pesquisas da Marinha (IPqM) pelo apoio dado a este trabalho.

7 Referências Bibliográficas

- [1] S. Haykin, *Neural Networks, A Comprehensive Foundation*, Prentice Hall, Segunda Edição, 1999.
- [2] W. S. Filho, Uso de Componentes Principais para Classificação em Sonar Passivo, *II Workshop em Acústica Submarina*, Rio de Janeiro, Brasil, 2002.
- [3] J. Horvat, *Handbook of Ocean and Underwater Engineering*, McGraw-Hill, 1969.
- [4] W. Knight, R. Pridham, S. Kay, Digital Signal Processing for Sonar, *IEEE Proceedings*, V. 69, N. 11, PP. 1451-1507, 1981.
- [5] A. Rogoyski, F. Dawe, M. Robinson, *Passive Sonar Data Processing*, capítulo *Underwater Defense Technology*, páginas 310-313, 1994.
- [6] R. O. Nielsen, *Sonar Signal Processing*, Artech, 1991.
- [7] P. S. R. Diniz, E. A. B. da Silva, S. L. Netto, *Digital Signal Processing: System Analysis and Design*, Cambridge University Press, 2002.
- [8] A. Papoulis, S. U. Pillai, *Probability, Random Variables and Stochastic Processes*, McGraw-Hill, Quarta Edição, 2002.
- [9] A. Cichocki, S. Amari, *Adaptive Blind Signal and Image Processing – Learning Algorithms and Applications*, John Wiley Sons, 2002.
- [10] W. W. Hsieh, Nonlinear Multivariate and Time Series Analysis by Neural Network Methods, *Review of Geophysics*, June, 2003.
- [11] W. S. Filho, J. M. de Seixas, and L. P. Caloba, Principal Component Analysis for Classifying Passive Sonar Signals, *IEEE International Symposium on Circuits and Systems*, Sidney, Austrália, 2001.
- [12] G. Cybenko, Approximation by Superpositions of a Sigmoidal Function, *Mathematics of Control, Signal and Systems*, 2, 1989.
- [13] M. A. Kramer, Nonlinear Principal Component Analysis Using Auto Associative Neural Networks, *AIChE*, 37(2), Fevereiro 1991.
- [14] G. Rech, Forecasting with Artificial Neural Network Models, *Working Papers Series in Economics and Finance*, Stockholm School of Economics, N.491, Fevereiro, 2002.
- [15] L. P. Caloba, J. M. de Seixas, and F. S. Pereira, Neural Discriminating Analysis for a Second Level Trigger System, *Computing in High Energy Physics*, Rio de Janeiro, Brasil, 1995.