

Identificação de Navios em Sinais de Sonar Passivo por Curvas Principais

Tamara Silva Passos Fernandes*, João Baptista de Oliveira e Souza Filho*^{†‡}, Errison dos Santos Alves*[‡]

Departamento de Engenharia Elétrica (DEPEL)*,
Programa de Pós-Graduação em Engenharia Elétrica (PPEEL)[‡],
Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET-RJ), Brasil*

Departamento de Engenharia Eletrônica e Computação (DEL/POLI)[†],
Universidade Federal do Rio de Janeiro, RJ, Brasil[†]

Email: *tamara.spf@gmail.com, [†]jbfilho@poli.ufrj.br, [‡]errison_alves@yahoo.com.br

Resumo—A identificação automática de classes e embarcações entre possíveis ameaças (contatos) é de extrema valia para facilitar a tomada de decisão pelos operadores de sonar. Neste trabalho é desenvolvido um classificador baseado em curvas principais para a identificação de diferentes classes e tipos de navios com um alto grau de eficiência. O classificador proposto identifica a classe através da distância mínima à curva principal representativa de cada classe e, posteriormente, o navio através do valor do índice de projeção nesta curva, sendo este último critério pioneiro neste tipo de classificador. A metodologia é avaliada utilizando uma base de dados real, formada por corridas de 28 navios de 8 classes em raia acústica. São avaliadas as seguintes propostas para identificação dos navios, respectivamente, Limites Heurísticos, Limiares Ótimos e Classificação *Fuzzy*, sendo possível obter uma eficiência média de 91,4%.

I. INTRODUÇÃO

Sonares desempenham um papel fundamental na vigilância promovida pela Marinha do Brasil, pois através da análise dos sinais captados é possível detectar ameaças. No caso dos submarinos, as possíveis ameaças são denominadas como *contatos*. Os sonares passivos são utilizados nestas embarcações, principalmente, para a tarefa de vigilância, pois operam de forma silenciosa, apenas captando e analisando o ruído aquático, visto que a emissão de sinais, tais como realizada pelos sonares ativos, poderia denunciar a sua presença. Como os sinais sonoros emitidos por cada contato possuem uma assinatura acústica característica, é possível sua discriminação.

A captação dos sinais de sonar é uma aplicação que, conhecidamente, gera dados de grande complexidade e dimensionalidade. Assim, faz-se necessária uma cadeia de pré-processamento para a extração de informação útil à solução do problema. Uma técnica atrativa neste contexto é a técnica de curvas principais, em especial o algoritmo de *K-segmentos*, que foi desenvolvido por Verbeek [1].

A técnica de Curvas Principais já foi utilizada para a classificação de sinais de sonar em trabalhos anteriores, utilizando a mesma base de dados, tais como em [3], onde foi realizado um estudo da eficácia do uso de Curvas Principais para a discriminação de 4 classes de navios, bem como em [2], onde foram consideradas 8 classes e realizada uma análise do efeito do quantitativo de segmentos por curva de classe na acurácia do classificador. Ambos trabalhos utilizaram como critério de classificação a distância dos dados à curva representativa de cada classe.

Nos trabalhos anteriores, não foi avaliada a eficácia da curva para a identificação de navios. A proposta deste trabalho é a implementação de um classificador hierárquico, baseado em Curvas Principais, onde a classificação de navios é realizada em duas etapas; primeiramente, é identificada a classe à qual o navio pertence, utilizando o mesmo critério de classificação aplicado em [2] e [3], e posteriormente, avaliação do índice de projeção na curva representativa da classe identificada na primeira etapa, onde é identificado cada navio correspondente. Desta maneira, o complexo processo de classificação em um número expressivo de navios tem um baixo custo computacional associado.

A estrutura do artigo é a seguinte: na Seção II são expostos os conceitos de Curvas Principais e do algoritmo de *k*-segmentos, bem como abordados conceitos básicos sobre lógica *Fuzzy*; na Seção III são expostos os métodos de classificação quanto ao índice de projeção, respectivamente: Limites Heurísticos, Limiares Ótimos e Classificação *Fuzzy*; são apresentadas as eficiências de classificação associadas a cada método, bem como é realizada uma análise dos resultados obtidos. Por fim, na Seção V tem-se as conclusões e os trabalhos futuros.

II. MATERIAIS E MÉTODOS

A. Curvas Principais

As *Curvas Principais* são uma generalização não-linear do método de *Análise de Componentes Principais* (PCA). Estas curvas fornecem uma sumarização dos dados em termos de curvas não-lineares inseridas no espaço dos dados. As Curvas Principais foram propostas por Hastie e Stuetzle [4], e consistem numa curva suave que passa no *meio* de uma nuvem de dados. Nesta definição se destaca o conceito da *auto-consistência*, que intuitivamente significa que cada ponto da curva consiste na média de todos os pontos que nela projetam.

Nas curvas principais dois parâmetros são de grande relevância: o índice de projeção e a distância dos dados à curva.

Seja f uma curva suave de velocidade unitária em \mathbb{R}^d , parametrizada no intervalo fechado $t \subseteq \mathbb{R}^1$, que não intercepta a si própria (ou seja, $t_1 \neq t_2 \rightarrow f(t_1) \neq f(t_2)$), e de comprimento finito dentro de uma esfera de dimensões finitas em \mathbb{R}^d .

Define-se o índice de projeção $t_f : \mathbb{R}^d \rightarrow \mathbb{R}^1$ como:

$$t_f(x) = \sup_t \{ \|x - f(t)\| = \inf_{\mu} \|x - f(\mu)\| \} \quad (\text{II.1})$$

O quadrado da distância euclidiana de \mathbf{x} a \mathbf{F} é definido como a distância quadrática de \mathbf{F} a partir do ponto de projeção de \mathbf{x} até o próprio \mathbf{x} , ou seja,

$$\delta(\mathbf{x}, \mathbf{f}) = \inf_{a \leq t \leq b} \|\mathbf{x} - \mathbf{f}(t)\|^2 = \|\mathbf{x} - \mathbf{f}(t_f(\mathbf{x}))\|^2. \quad (\text{II.2})$$

Na Figura 1 tem-se uma representação de uma curva arbitrária e de vários índices de projeção associados.




Figura 1: Índices de projeção em uma curva principal. Extraído de [5].

B. Algoritmo de k -segmentos não-suave

O algoritmo de k -segmentos não-suave (*k-segment hard*) foi desenvolvido por Verbeek, Vlassis e Kröse [1], e seu objetivo é gerar uma Curva Principal através de sua aproximação por um conjunto de segmentos conectados.

A sequência lógica do método de k -segmentos não-suave consiste em, primeiramente, separar os dados em grupos de

modelos locais, ou regiões, produzidos com base na análise de componentes principais (PCA). A idéia básica é encontrar k -segmentos s_1, \dots, s_k que minimizem a distância quadrática total de todos os pontos à linha mais próxima.

$$\sum_{i=1}^k \sum_{\mathbf{x} \in V_i} d(\mathbf{x}, s_i)^2 \quad (\text{II.3})$$

Na Figura 2 tem-se um exemplo de separação de regiões e de segmentos a ela ajustados.




Figura 2: Os dados são particionados em três regiões para dois segmentos (V_1 e V_2) e um segmento adimensional (V_0). Extraído de [1].

Após o ajuste, estes modelos são conectados por uma linha poligonal (PL). A Figura 3 ilustra o processo de construção da curva principal para um número crescente de segmentos, segundo o algoritmo k -segmentos. Nesta Figura, segmentos grossos são aqueles ajustados; e os segmentos finos, os inseridos pela construção da linha poligonal (PL). Percebe-se uma boa aproximação de curvas complexas, tal como a ilustrada.




Figura 3: Exemplos de diferentes grupos de PLs encontradas aplicando o algoritmo de k -segmentos, considerando-se 4, 6 e 12 segmentos, respectivamente. Extraído de [1].

Em seguida, se necessário, um novo modelo local é adicionado, segundo um processo de busca global no conjunto de dados, até um limite estabelecido.

C. Lógica Fuzzy

A lógica *Fuzzy* foi introduzida por Lotfi Zadeh em 1965 [6] e objetiva facilitar a modelagem de informação imprecisa. Sua principal diferença em relação à lógica booleana diz respeito às relações de pertinência, que para um conjunto de operadores *fuzzy* pode assumir valores que variam entre zero e um (diferentes gradações).

O Sistema de Inferência *Fuzzy* (FIS) de Mamdani é a metodologia *Fuzzy* mais comumente utilizada. Esta foi proposta por Ebrahim Mamdani em 1975, como uma alternativa para o controle de uma máquina a vapor, realizada através da síntese de regras de controle linguísticas, obtidas de experientes operadores humanos destas máquinas. Mamdani se baseou no artigo publicado por Zadeh sobre algoritmos *Fuzzy* para sistemas complexos e processos decisórios [7].

Um *Sistema Lógico de Inferência Fuzzy* ou *Fuzzy Logic Inference System* (FLIS) é um mapeamento não-linear do vetor de dados, o qual é relacionado a uma saída escalar, sendo normalmente definido através de regras que podem ser fornecidas por especialistas (heurísticamente), bem como extraídas dos dados por algoritmos numéricos. A arquitetura *Fuzzy* pode ser resumida conforme o diagrama de blocos da Figura 4.




Figura 4: Arquitetura de um Sistema Lógico de Inferência *Fuzzy* ou Controlador *Fuzzy*.

Entre os processos apresentados na Figura 4, a "fuzzificação" é um mapeamento do domínio de entrada para o domínio *fuzzy*, e pode ser entendida como um *pré-processamento* de categorias ou de classes dos sinais de entrada. A fuzzificação se efetua através de curvas que relacionam os valores do universo de discurso e os valores da função de pertinência para cada variável de entrada. A "defuzzificação", por outro lado, converte a saída do sistema de inferência *fuzzy* em uma saída no domínio das variáveis a serem aproximadas pelo FLIS [8].

III. CLASSIFICADOR HIERÁRQUICO POR CURVAS PRINCIPAIS

O classificador proposto opera em duas etapas: a primeira, cujo objetivo é classificar os dados entre classes; e a segunda, que consiste em realizar uma subsequente classificação destes dados em navios. A sequência descrita é representada na Figura 5, considerando três possibilidades quanto à atribuição dos navios, a serem discutidas e avaliadas neste trabalho.




Figura 5: Sequência de classificação.

A. Primeira etapa - classificação em classes

Nesta etapa, as curvas principais de cada classe foram extraídas aplicando o algoritmo de *k*-segmentos no conjunto de treino. O procedimento é similar ao utilizado em [9], e ilustrado de forma sucinta na Figura 6. As curvas de cada classe foram dimensionadas conforme o critério interno do próprio algoritmo *k*-segmentos.

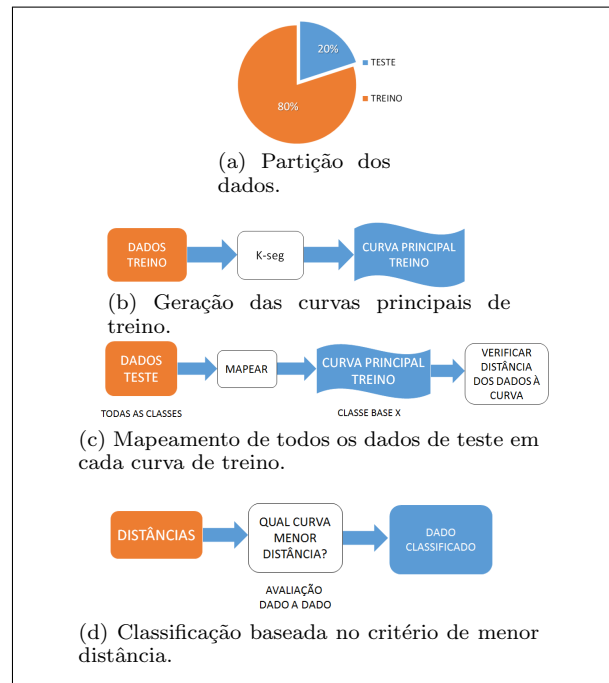


Figura 6: Sequência lógica da primeira etapa do classificador.

B. Segunda etapa - classificação em tipos de navio

Através da análise dos índices de projeção dos dados nas diferentes curvas de cada classe, verificou-se que uma classificação eficaz dos diferentes tipos de navios poderia ser realizada. Deste modo, foi proposta a sistemática ilustrada na Figura 7. Em síntese, diferentes faixas de valores de índices de projeção são associadas a cada um dos navios de cada classe utilizando o conjunto de treino. Na Figura 8, estas faixas estão ilustradas para os navios da classe A. Em fase de operação, tal procedimento é ilustrado na Figura 7b, e basicamente consiste em realizar a projeção

do dado na curva, identificando-se o índice de projeção correspondente, e, por consequência, o navio associado, de acordo com os limites atribuídos na fase de projeto (Figura 7a). Visando definir os limites do índice de projeção de cada classe, três critérios foram considerados:

1) *Limites Heurísticos*: Neste caso, os limites foram definidos por uma cuidadosa inspeção visual das curvas classe-a-classe.

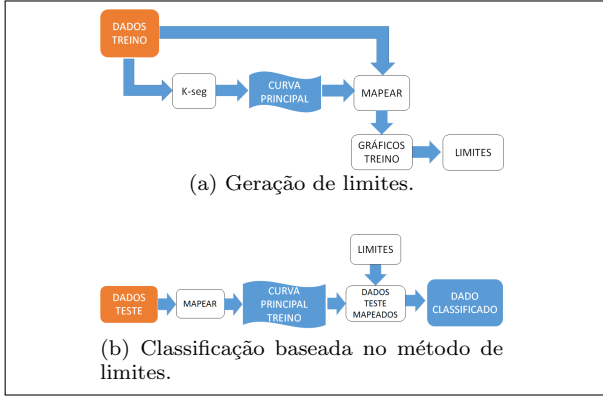


Figura 7: Sequência lógica do método proposto para a identificação de navios.




Figura 8: Faixas dos índices de projeção associados aos diferentes navios da classe A (conjunto de treino).

2) *Limiares Ótimos*: Neste método, os limites são inseridos visualmente e, posteriormente, otimizados através de um cálculo de probabilidade. Segundo este critério, os limiares são ajustados de forma a definir uma fronteira ótima entre cada tipo de navio, supondo que os índices de projeção de cada navio que pertençam a regiões de fronteira entre dois navios sejam descritos, apropriadamente, por distribuições gaussianas, cujos parâmetros (média e desvio padrão) são estimados dos próprios dados.

3) *Classificação Fuzzy*: O método de classificação *Fuzzy* foi construído utilizando-se a GUI de *Fuzzy Inference System* (FIS) do Matlab, considerando-se o modelo de

Classes	Navio	Nº Corridas	Nº Espectros	Total Espectros
Classe A	A1	11	1191	2432
	A2	4	504	
	A4	7	737	
Classe B	B1	8	914	3432
	B2	4	700	
	B3	9	1224	
	B5	5	594	
Classe C	C1	5	512	4797
	C2	10	1081	
	C3	6	799	
	C4	6	705	
	C5	16	1700	
Classe D	D1	13	1401	3072
	D3	4	406	
	D4	12	1265	
Classe E	E1	21	2462	7075
	E2	7	717	
	E3	31	3505	
	E4	7	391	
Classe F	F1	6	636	2934
	F2	8	857	
	F3	6	628	
	F4	7	813	
Classe G	G1	8	867	2143
	G2	11	1276	
Classe H	H1	16	1680	3392
	H2	9	975	
	H5	6	737	

Tabela I: Distribuição das corridas por classes e navios. Extraído de [11].

Mamdani, onde foram elaboradas funções de pertinência, em maior parte, trapezoidais, baseadas nos valores de limites encontrados através do método de limites heurísticos.

IV. RESULTADOS

O sistema classificador proposto foi avaliado utilizando uma base de dados fornecida pelo Instituto de Pesquisas da Marinha do Brasil (IPqM), que é composta pelos ruídos irradiados por 28 navios, pertencentes a 8 classes, em 263 corridas de prova, realizadas em uma raia acústica. Os sinais foram pré-processados segundo a cadeia discutida em [10] e [11], de forma a se obter janelas espectrais dos sinais que possuíssem informação útil à classificação. Após o pré-processamento, cada janela espectral possui 557 dimensões, havendo um mínimo de 2143 e um máximo de 7075 janelas por classe; um mínimo de 391 (navio E4) e um máximo de 3505 (navio E3) janelas por navio. Os quantitativos de corridas, navios e espectros associados a cada classe são descritos na Tabela I.

Para a avaliação do sistema, foi utilizada a técnica de Holdout [12], e um percentual de 80% e 20% do total de eventos foram destinados para os conjuntos de treino e teste, respectivamente, como listado na Tabela II.

Foram extraídas as curvas principais dos conjuntos de treino de cada classe, utilizando o algoritmo de *k*-segmentos, cujo quantitativo de segmentos sugeridos pelo algoritmo se encontram descritos na Tabela III.

Em sequência, os dados de teste de cada classe foram mapeados nas curvas principais de treino de cada classe e atribuídos à curva da classe mais próxima. As eficiências

Classes	Conjunto Treino	Conjunto Teste	Total Espectros
Classe A	1952	480	2432
Classe B	2756	676	3432
Classe C	3856	941	4797
Classe D	2470	602	3072
Classe E	5685	1390	7075
Classe F	2358	576	2934
Classe G	1722	421	2143
Classe H	2726	666	3392

Tabela II: Distribuição dos dados em grupos de treino e teste.

Classes	Número segmentos
Classe A	10
Classe B	30
Classe C	30
Classe D	6
Classe E	30
Classe F	24
Classe G	9
Classe H	21

Tabela III: Número de segmentos sugeridos para as curvas principais geradas a partir dos conjuntos de treino de cada classe.

correspondentes a esta primeira etapa de classificação para cada classe podem ser observadas na Figura 9. Pode-se perceber que o sistema é eficaz, com uma eficácia superior a 90%.




Figura 9: Eficiências médias de classificação da primeira etapa (valores percentuais).

A partir dos resultados de classificação da primeira etapa, foram avaliadas as três propostas de classificação de navios descritas na Seção II.

Nas Figuras 10, 11 e 12 tem-se a comparação dos percentuais de eficiências de classificação por navio nos três métodos, onde percebe-se que todos têm desempenho de classificação elevado, distinguindo-se apenas em determinados navios. Verifica-se, também, uma concordância quanto aos navios mais críticos, nesta ordem: B5, D3, E4 e G2, com pior eficiência superior a 75%. Observa-se, ainda, um desempenho bastante equilibrado dos três, com destaque ao método de limites heurísticos, que possui como atrativo sua simplicidade.

As eficiências médias de classificação de navios obtidas para cada abordagem estão resumidas na Tabela IV. Observa-se que não há diferença significativa no desempenho dos três métodos, e que os valores obtidos são




Figura 10: Eficiências de classificação de tipos de navio do método de limites heurísticos.




Figura 11: Eficiências de classificação de tipos de navio do método de limiares determinados.




Figura 12: Eficiências de classificação de tipos de navio do método de classificação fuzzy.

Técnica	Eficiências (%)
Limites Heurísticos	91,4
Limiares Ótimos	90,7
Inferência Fuzzy	91,1

Tabela IV: Eficiências finais de classificação para cada técnica de separação de navios.

expressivos, em especial quando considerado o grande número de navios envolvido no problema.

V. CONCLUSÃO

Este trabalho discutiu a construção de um sistema eficaz para a identificação automática de navios baseado em janelas espectrais extraídas de sinais de sonar passivo. Para tal tarefa, é proposta a utilização da técnica de Curvas Principais como mecanismo extrator de características; e de um esquema de classificação de dois estágios, onde, primeiramente, há a identificação da classe mais provável, que é sucedida pela identificação do navio correspondente.

O sistema proposto se mostrou robusto à escolha da técnica utilizada para a atribuição dos navios. Dentre aquelas consideradas neste trabalho, foi possível atingir uma eficiência média de 91,4%, resultado que é expressivo ao problema em questão.

Como trabalhos futuros, estão em investigação algoritmos automáticos para a identificação dos limiares. Entre possibilidades sob avaliação, tem-se a adoção de redes *Neuro-Fuzzy*.

REFERÊNCIAS

- [1] VERBEEK, J. J., VLASSIS, N., KRÖSE, B., "A k-segments Algorithm for Finding Principal Curves", *Pattern Recognition Letters*, v. 23, n. 8, pp. 1009–1017, 2002.
- [2] ROCHA, G. G. M. ; SOUZA FILHO, J. B. O. E. ; GESUALDI, A. R. ; SEIXAS, J. M. . Otimização Genética de Curvas Principais para a Classificação de Contatos. In: X Congresso Brasileiro de Inteligência Computacional, 2011, Fortaleza. Anais do X CBIC, 2011.
- [3] SOUZA FILHO, J. B. O. ; GUEDES, R. M. ; GESUALDI, A. R. . Classificadores Multi-classe de Contatos por Curvas Principais. In: X Simpósio Brasileiro de Automação Inteligente - SBAI 2011, 2011, São João Del Rei. Anais do X Simpósio Brasileiro de Automação Inteligente, 2011.
- [4] HASTIE, T. J., STUETZLE, W., "Principal curves", *Journal of the American Statistical Association*, v. 84, n. 406, pp. 502-516, 1989.
- [5] KEGL, B., "Principal curves: learning, design and applications", Phd thesis, Concordia University, 1999.
- [6] ZADEH, Lotfi A., "Fuzzy Sets, Information and Control", 8, 338-353, 1965.
- [7] ZADEH, Lotfi A., "Outline of a New Approach to the Analysis of Complex Systems and Descision Processes", *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. SMC-3, n^o 1, 1973.
- [8] SIMÕES, M. G., SHAW, I., "Controle e Modelagem Fuzzy", Edgard Blücher, 1999.

- [9] FERNANDEZ, HELENA L., "Classificação de navios baseada em curvas principais", M.Sc dissertation, UFRJ, 2005.
- [10] SOARES FILHO, W., "Classificação do Ruído Irradiado por Navios usando Redes Neurais" Ph.D. dissertation, UFRJ, 2001.
- [11] OLIVEIRA E SOUZA, J. B. F., "Classificação Neural de Sinais de Sonar Passivo", Ph.D dissertation, UFRJ, 2007.
- [12] KOHAVI, R., "A Study of Cross-validation and Bootstrap for Accuracy Estimation and Model Selection". In: *International Joint Conference on Artificial Intelligence (IJCAI)*, pp. 1137–1145, 1995.