

# Aplicação de Máquina de Vetor de Suporte na Classificação de Sinais Acústicos de Navios Utilizando Dados de Frequência e RPM.

Mikey da Silva Neto, Moacyr Machado Cardoso Júnior, Rodrigo Arnaldo Scarpel<sup>1</sup>  
Praça Marechal Eduardo Gomes, 50 - Vila das Acácias São José dos Campos – SP – Brasil CEP: 12228-900

**Resumo** — Este artigo apresenta um estudo para identificação de sinais acústicos utilizando Máquina de Vetor de Suporte (MVS). Os dados utilizados foram obtidos através da análise de frequências principais, mais especificamente, lofograma e demograma, cujo objetivo é prover a um submarino a capacidade de reconhecer classe de navios necessários tanto à segurança da navegação assim como identificação de alvos em cenários de beligerância.

Os dados de frequência principal contêm os atributos de frequência sonora provenientes das máquinas e RPM do eixo-propulsor dos navios. Técnicas MVS foram usadas com o algoritmo *Grid Search* para extração dos parâmetros ótimos da função Kernel. Os resultados mostraram uma boa performance na classificação de navios usando os atributos selecionados, bem como um baixo custo computacional relativo.

**Palavras-chave:** Mineração de Dados, Aprendizado de Máquina, Pesquisa Operacional Militar.

## I. INTRODUÇÃO

Identificação de um navio em uma área próxima não é uma tarefa fácil. No caso de um submarino esta pode apresentar como uma difícil tarefa, pois em muitas ocasiões há somente uma fonte de informação que é o seu equipamento sonar. Uma das funções de um Sistema Sonar (*Sound navigation and ranging*) é a classificação de sinais acústicos submarinos. Esta classificação é usada para identificar a fonte de sinais acústicos percebida nos receptores sonar. No passado o sonar teve grande relevância e ainda hoje com a invenção do esnorquel e construção de submarinos nucleares, o tempo imerso dispendido cresceu substancialmente tornando ainda mais importante a qualidade da informação obtida com o mesmo.

O trabalho de um operador sonar é perceber a presença de navios e mais características que permitam suas identificações. Para tanto, ele utiliza-se de suas habilidades e/ou habilidade de escutar, que foi apurada após anos de treinamento e também apoiam-se nas ferramentas computacionais do sistema sonar. A identificação destes contatos é frequentemente conseguida através de seus espectros de frequência. Análises como a LOFAR (*low frequency analysis and recording*) e DEMON (*demodulation on noise*), em adição a análise Áudio, são ferramentas utilizadas na prática para identificação. As máquinas do navio (sistema de propulsão, máquinas auxiliares, bombas, dentre outras) produzem formas características no espectrograma vistas como linhas espectrais, e estas mostram a gama de tons por tempo. As combinações das informações obtidas em cada um destes testes dispõem relações entre elas e então obtém-se padrões característicos para identificar a plataforma ou classe a que estes padrões pertencem[1]

Alguns trabalhos têm sido realizados na literatura, aplicações em sonar podem ser vistas em [1-6], cujo uso de Redes Neurais e MVS (*Support Vector Machine-SVM*) foram utilizados amplamente para classificação.

Conforme ver-se em seguida, a Máquina de Vetor de Suporte (MVS) tem se mostrado bastante promissora quanto ao seu uso em classificadores, sendo assim nosso trabalho visa verificar a performance de um classificador de sinais acústicos otimizados pelo algoritmo *Grid Search* para reconhecimento de classe de navios utilizando dados de frequência provenientes da análise LOFAR e RPM (Revolução Por Minuto) do eixo-propulsor extraídos dos sinais acústicos.

## II. MÁQUINA DE VETOR DE SUPORTE (MVS)

“Exagero ou Salvação?” é um provocativo título usado por Bennett Campbell (2000) em uma revisão da Máquina de Vetor de Suporte (MVS). MVS é atualmente um tópico relevante na comunidade de Aprendizado de Máquina [7-11], criando no momento um entusiasmo similar ao das Redes Neurais Artificiais usadas antes. Longe de ser uma panacea, MVS ainda representa uma poderosa técnica para classificação em geral (não linear), regressão e detecção de outlier com um intuitivo modelo de representação [12] MVS implementa uma simples idéia – eles constroem os vetores padrões a uma alta dimensão nos espaços de atributos onde um ‘melhor’ hiperplano de separação (o hiperplano de máxima margem) é construído.

A teoria da MVS é introduzida brevemente na forma que segue um conjunto de treinamento  $A$  é dado em (1).

$$A = \{(x_i, y_i), i = 1, \dots, n \mid x_i \in \mathbb{R}^d, y_i \in \{1, -1\}\} \quad (1)$$

Para o caso linearmente separável, o objetivo é encontrar um ótimo hiperplano tal que (2) é assegurado.

$$\begin{cases} \text{se } wx_i + b \geq 1 & \text{então } y_i = 1 \\ \text{se } wx_i + b \leq -1 & \text{então } y_i = -1 \end{cases} \quad (2)$$

A MVS maximiza a margem de separação entre classes, que é  $2/\|w\|$ . Então para encontrar o hiperplano ótimo é necessário resolver um problema de otimização restrita dado abaixo .

$$\begin{aligned} &\text{minimizar} && \frac{\|w\|^2}{2} \\ &\text{sujeito a} && y_i (wx_i + b) \geq 1 \quad i = 1, 2, \dots, n \end{aligned} \quad (3)$$

<sup>1</sup> Mikey da Silva Neto, mikey@ita.br, Moacyr Machado Cardoso Júnior, Moacyr@ita.br, Rodrigo Arnaldo Scarpel, rodrigo@ita.br

O problema de otimização restrita acima pode ser resolvido por uma programação quadrática (QP). Contudo, para o caso não linearmente separável, algumas amostras não são classificadas corretamente. Portanto, a MVS introduz variáveis de folgas não negativas transformando em

$$y_i (wx_i + b) \geq 1 - \xi_i \quad i = 1, 2, \dots, n \quad (4)$$

Como para o caso não-linear, o original espaço de entradas é mapeado dentro de alta de dimensão do produto interno via kernel. O novo espaço é chamado de espaço de atributos, em que um hiperplano ótimo é determinado para maximizar a habilidade de generalização. O hiperplano ótimo deve ser determinado somente por poucos pontos dos dados chamados vetores de suporte (SVs) [12].

Pela escolha do gráfico de uma função não-linear  $\Phi(x_i)$ , a MVS deve construir um hiperplano ótimo neste novo espaço de atributos. Substituindo  $\Phi(x_i)$  em (4), obtemos

$$y_i (w \cdot \Phi(x_i) + b) \geq 1 - \xi_i \quad i = 1, 2, \dots, n \quad (5)$$

Agora o objetivo da MVS é encontrar um hiperplano de separação em que o erro de classificação deva ser minimizado enquanto maximiza a margem de separação. Para encontrar o hiperplano ótimo no caso não linearmente separável é necessário resolver o seguinte problema de otimização restrita

$$\text{minimizar } \phi(w, \zeta) = \frac{1}{2} (w \cdot w) + C \left( \sum_{i=1}^n \zeta_i \right) \quad (6)$$

$$\text{sujeito a } y_i (w \cdot \Phi(x_i) + b) \geq 1 - \xi_i \quad i = 1, 2, \dots, n \quad (7)$$

$$\zeta_i \geq 0$$

Onde C é um parâmetro positivo definido pelo usuário, e  $\zeta_i \geq 0$ . Este controla a troca entre a complexidade da máquina e o número de pontos não-separável. Em particular, ele é um parâmetro livre na MVS. Pela introdução dos multiplicadores de Lagrange  $\alpha_i$  e  $\gamma_i$  leva-nos a (8).

$$L(w, b, \zeta, \alpha, \gamma) = \frac{1}{2} (w \cdot w) + C \left( \sum_{i=1}^n \zeta_i \right) - \sum_{i=1}^n \alpha_i [y_i (w \cdot \Phi(x_i) + b) - 1 + \zeta_i] - \sum_{i=1}^n \zeta_i \gamma_i \quad (8)$$

Onde  $\alpha_i \geq 0, \zeta_i \geq 0$ .

o problema primal torna-se a tarefa de encontrar o ponto de sela do langrangiano. Então, o correspondente dual langrangiano é dado abaixo.

$$\begin{aligned} \text{maximizar } W(\alpha) &= \sum_{n=1}^n \alpha_i - \frac{1}{2} \sum \alpha_i \alpha_j y_i y_j K(x_i, x_j) \\ \text{sujeito a } &0 \leq \alpha_i \leq C \\ &\sum_{i=1}^n \alpha_i y_i = 0 \end{aligned} \quad (9)$$

Onde  $K(x_i, x_j)$  é uma função kernel e  $K(x_i, x_j) = \Phi(x_i) \bullet \Phi(x_j)$ . Pela resolução do dual langrangiano acima, obtemos

$$w = \sum_{i=1}^n \alpha_i^* y_i x_i \quad (10)$$

Os multiplicadores não-nulos de Langrange são denotados por  $\alpha_i$ , estes pontos são denominados vetores de suporte (SVs). O resultado da função de decisão pode ser mostrada em (11).

$$f(x) = \text{sgn} \left[ \sum_{i=1}^n \alpha_i^* y_i K(x_i, y_i) + b^* \right] \quad (11)$$

### 2.1 Funções Kernel

A idéia básica dos algoritmos kernels é transformar os dados  $x_i$  do espaço de entradas a uma alta dimensão no espaço de atributos dos vetores  $\Phi(x_i)$ , onde o produto interno pode ser calculado usando uma função kernel positiva definida satisfazendo a condição de Mercer [13].

$$K(x, y) = \langle x, y \rangle$$

Esta simples e elegante ideia permite-nos obter versões não-lineares de algum algoritmo linear expresso em termos de produto interno, sem talvez conhecer a exata forma da função. Uma característica particularmente interessante do espaço de atributos é sua *Reproducing Kernel Hilbert Space* (RKHS).

Existem muitos tipos de kernels que podem ser usados na MVS. A tabela lista algumas formas comumente usadas.

TABELA I FUNÇÕES KERNEL

Kernel	Fórmula	Parâmetros
Linear	$u^T v$	(nenhum)
Polinomial	$\Gamma(u^T v + c_0)^d$	$\Gamma, d, c_0$
Função de Base Radial	$\exp\{-\Gamma u-v ^2\}$	$\Gamma$
Sigmóide	$\tanh\{\Gamma u^T v + c_0\}$	$\Gamma, c_0$

Um ponto de grande dificuldade para uso da função kernel de Base Radial descrita acima juntamente com a MVS é a descoberta do C e  $\Gamma$  para tarefa de classificação.

### III.DADOS EMPREGADOS E ANÁLISES REALIZADAS

Neste ponto do artigo descreveremos como foram obtidos os dados, sua estrutura e forma como foram trabalhados com o algoritmo *Grid Search*.

#### 3.1 Coleta de dados

Este estudo baseou-se nos dados coletados em raia acústica do Instituto de Estudos do Mar Almirante Paulo Moreira-IEAPM (Marinha do Brasil), pelos quais diferentes classe de de navios foram submetidas a diferentes velocidades e seus sinais acústicos foram adquiridos. As classes de navios foram designadas por “A”, “C”, “F” e “J”. Na Fig.1 vemos um modelo simplificado de como seriam obtidos informações através de um hidrofone no fundo com a passagem do navio durante uma corrida.

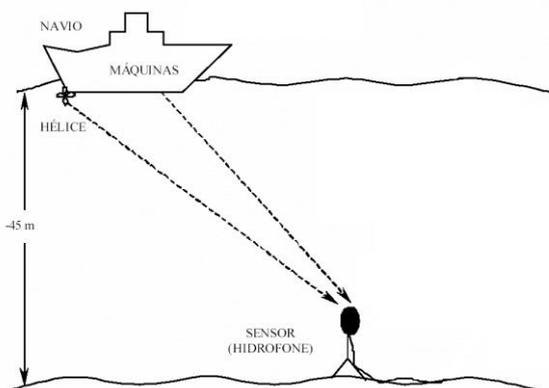


Fig.1 Representação de uma raia acústica[14]

Os dados foram obtidos através das análises de lofogramas e demogramas, dos mesmos extraímos a frequência corresponde às máquinas dos navios em Hertz e sua respectiva velocidade angular do eixo-propulsor dadas em RPM. Pela Fig. 2 poderemos verificar a distribuição aproximada da massa de dados levando-se em conta os atributos supracitados.Os dados ainda podem ser explicitados como uma matriz 481 por 3, onde a coluna 1 representa as classes de navios, ou seja “A”, “C”, “F” e “J”, uma segunda coluna estaria a frequência e a terceira suas respectivas RPM. Os dados foram normalizados objetivando evitar disparidades de escala das variáveis.

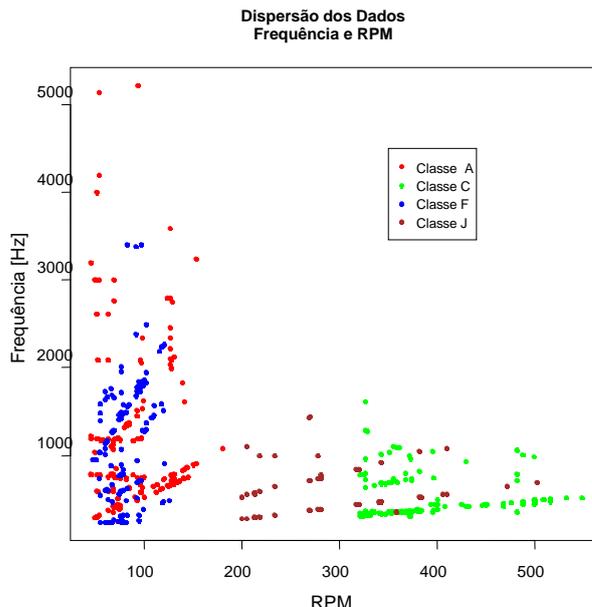


Fig. 2. Apresentação dos dados

Dos dados é possível notar que há uma dificuldade de classificação por simples inspeção de frequência e RPM.

Com objetivo na classificação de informação, uma técnica de MVS foi utilizada e testada com uma Função de Base Radial –RBF(*default*), sendo esta normalmente utilizada quando ainda não se testou nenhuma das outras possíveis, a mesma necessita que os parâmetros de otimização  $\Gamma$  (gama) e C (custo) sejam encontrados. Gama representa o parâmetro kernel e C o custo de violação das restrições, um termo constante de regularização na formulação do Langrangiano.

Considerando que não há um guia eficiente para seleção de parâmetros[15], e que estes valores desempenham um fator central na eficiência da classificação, esta foi então realizada em duas fases seguintes:1-Otimização dos parâmetros ;2-Medição da eficiência de classificação dos parâmetros de otimização.

Os parâmetros  $\Gamma$  e C foram otimizados utilizando o algoritmo *Grid Search*, com objetivo de determinar a combinação dos dois parâmetros com os melhores resultados. O “e1071” R CRAN pacote foi usado [16]. Esta técnica requer apenas a variação de  $\Gamma$  e C para seleção; e a escolha da amostra que foi feita com um dos métodos seguintes : *k-cross validation*, *fix split* no conjunto treino ou *Bootstrap*. A variação de  $\Gamma$  foi considerada de  $2^{-7}$  a  $2^9$ , e a de C ficou entre  $2^{-5}$  a  $2^9$ . As técnicas de amostragens utilizadas foram a *Cross-validation* usando um conjunto *10-fold*, um conjunto de *Bootstrapping* de 10 realocáveis informações e um *fix split* usado com 2/3 para o conjunto de treino.

Finalmente com os parâmetros otimizados utiliza-se para acesso à classificação e qualidade do ajuste (*good-of-fit*),uma tabela de contingência.

IV.RESULTADOS OBTIDOS

Utilizando os dados e as técnicas conforme descritos anteriormente os resultados do algoritmo *Grid Search* podem ser resumidos na TABELA II. A Fig. 3 ilustra o resultado encontrado com o *Grid Search* em conjunto com o *Bootstrapping*.A partir da análise dos resultados pode-se inferir que a melhor performance foi alcançada com o *10-fold cross validation*, pois possui no exemplo o menor valor do erro de classificação (0,1082908) configurando-se nos ótimos parâmetros de gama e custo.Estes parâmetros foram considerados como principais avaliações conforme esclarece [15].

Utilizou-se para classificação um PC AMD Turion Dual-core 3.0GB de memória,obtendo em média 20s para cálculo do resultados.

TABELA II RESULTADOS DO BOOTSTRAPPING,CROSS-VALIDATION E FIX SPLIT

	Gama $\Gamma$	Custo C	Melhor performance	Número de Vetores Suporte
Bootstrapping	64	16	0,1336382	266
10-Fold Cross-validation	16	16	0,1082908	229
Fix-Split	32	64	0,1242236	219

Aplicando a otimização de parâmetros para um kernel de Função de Base Radial na MVS, foi atingido 100% na performance de classificação no conjunto de dados de classificação de navios,isto pode ser evidenciado naturalmente pela matriz de confusão na TABELA III abaixo.

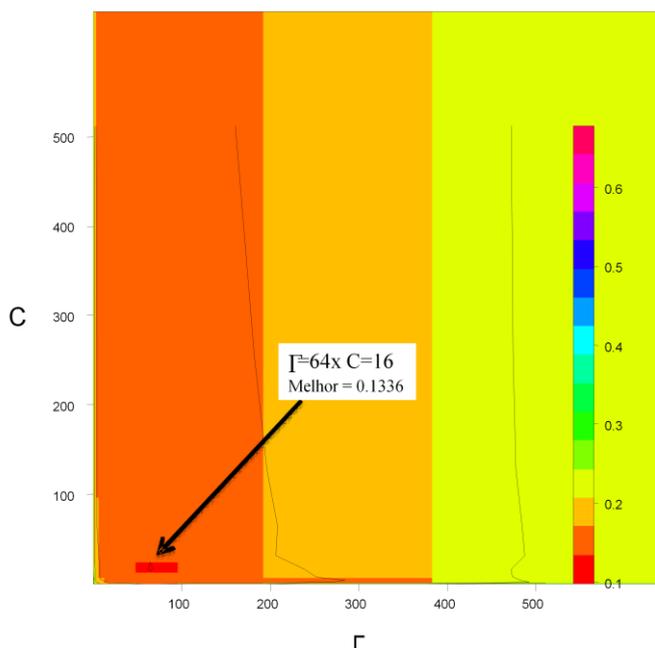


Fig. 3 Indicação do parâmetros ótimos encontrados com o Bootstrapping.

TABELA III-MATRIZ DE CONFUSÃO

Predito otimizado pelo SVM	A	C	F	J
A	85	0	0	0
C	0	66	0	0
F	0	0	60	0
J	0	0	0	29

V CONCLUSÃO

O uso do kernel MVS mostrou um resultado excelente para proposta de classificação, mas é importante ter em mente que estes depende da escolha adequada dos parâmetros  $\Gamma$  e C. A utilização de apenas dados de frequência e RPM é uma simplificação para classificação de sinais acústicos navios, considerando-se a hipótese de que os mesmos são suficientes para esta finalidade em trabalhos poderão ser considerados outros atributos,bem como outras funções kernel. Neste exemplo teve-se custo computacional relativamente baixo, contudo se os números de informações cresce torna-se evidentemente necessária uma nova validação das amostras.

REFERÊNCIAS

- [1] Paula,M.D “Estudo de Tons e Suas Características para Uso no Classificador de Navios Baseado em Redes Neurais”,Tese M.sc, COPPE/UFRJ, Rio de Janeiro ,RJ,Brasil 2007.
- [2] Rodrigues,C.V.S;Soares-Filho,W., “Análise de Métodos de Sinais Acústicos Submarinos Usando Tons Característicos”,Revista Pesquisa Naval,no 19,pp 36-42,Rio de Janeiro,RJ,Brasil,2007
- [3] Guangzhi,S.; Junchuan, H.;Mei,H. e Yuyang, L., “Underwater Acoustic Target Recognition Based on Multi-timeslice Demodulation Line Spectrum Feature”, Proceedings of 2008 IEEE International Conference of Information and Automation, pp 835-839,June 20-23, Zhangjiajie, China.
- [4] Guangzhi Shi, Junchuan Hu, “Dynamic Recognition Method Study Using the Support Vector Machine,” Proceedings of the 2007 IEEE International Conference on Mechatronics and Automation, pp. 1694-1698, August 2007.
- [5] Guangzhi Shi, Junchuan Hu, “Dynamic Artificial Neural Networks Based on the Target Feature and Application in Target Recognition,” Proceedings of the 2007 IEEE International Conference on Robotics and Biomimetics, pp. 2106-2109, December 2007.
- [6] Guangzhi Shi, Junchuan Hu, “Target Recognition Study Using SVM,ANNs and Expert Knowledge” Proceedings of the 2008 IEEE International Conference on Automation and Logistics, pp. 1507-1511, September 2008.
- [7] Joachims T., Text categorization with Support Vector Machines: Learning with many relevant features, Proceedings of European Conference on Machine Learning, Springer, 1998.
- [8] Joachims T., Christianni N., and Shawe Taylor J., Composite Kernels for Hypertext categorization, Proceedings of the International Conference on Machine Learning, 2001
- [9] Mori S., Suen C. Y., and Yamamota K., Historical review of OCR research and development, IEEE Proceedings, Vol. 80, 1992.
- [10] Mukkamala S., Janoski G., and Sung A. H., Intrusion Detection using Neural Networks and Support Vector Machines, IEEE Proceedings on International Joint Conference on Neural Networks, 2002.
- [11] Schmidt M., Identifying speaker with Support Vector Networks, Interface '96 Proceedings, Sydney, 1996.
- [12] Vapnik V. N., The Nature of Statistical Learning Theory, Springer, Berlin Heidelberg, New York, 1995.
- [13] C.Burges, “A tutorial on support vector machines for pattern recognition,” *Data Mining and Knowledge Discovery*, Vol. 2, pp. 121-167, 1998.

- [14] SOARES-FILHO, W. Classificação do Ruído Irrradiado por Navios Usando Redes Neurais. Tese de D. Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2001
- [15] Meyer, D., "SVM –The Interface to libsvm in package e1071", Technische Universität, Wien, Austria, Mar-3-2010.
- [16] Dimitriadou, E., Hornik, K., Leisch, F., Meyer, D., & Weingessel, A. (2009). e1071: Misc Functions of the Department of Statistics (e1071). Access Mar 18 2010, Source R CRAN: <http://CRAN.R-project.org/package=e1071>