

# Aprendizado por Instância para a Identificação de Classes Desconhecidas em Sonares Passivos

Victor Hugo da Silva Muniz, Eduardo Sperle Honorato e João Baptista de Oliveira e Souza Filho

Laboratório de Sinais, Multimídia e Telecomunicações

Programa de Engenharia Elétrica, POLI / COPPE

Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil

Emails: victor.muniz@smt.ufrj.br, honoratoseduardo@poli.ufrj.br e jbfilho@poli.ufrj.br

**Resumo**—Em submarinos, a tarefa dos operadores de sonar consiste na identificação de possíveis ameaças (contatos), utilizando, principalmente, o sistema de sonar passivo. Sistemas de classificação automática de contatos requerem a identificação de embarcações de classes desconhecidas durante a sua operação. Este trabalho discute a construção de um sistema hierárquico para o reconhecimento de tais ocorrências, considerando um estudo experimental envolvendo técnicas de aprendizado por instância, em cenários de crescente complexidade, para este fim. Os experimentos, explorando dados coletados em raia acústica de 28 navios pertencentes a 8 classes em diferentes condições operacionais, apontaram um melhor desempenho da técnica *k-Nearest Neighbors*, atingindo uma taxa de detecção de novidades de 78,0%, conjugada com uma taxa média de identificação de casos conhecidos de 95,0%, para um cenário com 3 classes conhecidas.

**Keywords**—sonar passivo; detecção de novidades; sistemas de apoio à decisão; aprendizagem de máquina

## I. INTRODUÇÃO

Sistemas de sonar passivo são frequentemente utilizados em atividades de patrulhamento por submarinos. Nesta tarefa, as vibrações emitidas pelos mecanismos de propulsão de outras embarcações, bem como por seu próprio deslocamento ao mar, são captadas por este sistema através de um arranjo de hidrofones, sendo subsequentemente processadas visando à identificação da assinatura acústica da embarcação. De posse de características tonais e espectrais do ruído captado, os operadores de sonar definem a classe mais provável do contato.

A automatização da classificação de contatos permite reduzir o desgaste físico e mental do operador e alivia seu esforço de vigilância, aumentando a confiabilidade quanto à tomada de decisões. Algumas técnicas se mostraram eficazes para realizar esta tarefa, entre elas: Classificadores Bayesianos [1], Redes Neurais Convolucionais [2], Redes Neurais especialistas [3], Curvas Principais [4], e *Deep Learning* [5]. Porém, em nenhum dos casos, os sistemas propostos se mostraram capazes de indicar a ocorrência de classes desconhecidas, isto é, aquelas não exploradas (novidades) durante o desenvolvimento dos classificadores. Vale notar que tais ocorrências serão obrigatoriamente classificadas de forma errônea por tais sistemas.

No ambiente do sonar, sistemas automáticos de classificação são construídos considerando um número limitado de classes de embarcações, visto as variadas restrições operacionais e

de custo. Assim, é primordial dispor de mecanismos para a identificação de novidades, isto é, capazes de alertar ao operador quando à confiabilidade de suas predições.

Detectores de novidades desenvolvidos através de aprendizagem por instância são amplamente utilizados em variadas aplicações [6], com destaque para a técnica de *k-Nearest Neighbors* (*k*NN) [7] e variantes, entre elas o *Nearest Neighbor density* (NNd) [8] e o *Local Outlier Factor* (LOF) [9]. Estudos anteriores [10] apontaram que a construção de detectores hierárquicos baseados em *k*NN, considerando como índice de novidade o valor da mediana da distância aos vizinhos mais próximos, supera diferentes técnicas estado-da-arte, inclusive mais complexas.

A proposta deste trabalho é avaliar a construção de detectores de novidades hierárquicos, considerando novos índices para a identificação de novidades, bem como as variantes NNd e LOF, amplamente utilizadas na literatura, porém ainda não explorados neste problema. Este estudo experimental também considera diferentes níveis de complexidade quanto à tarefa de detecção de novidades, contemplando três cenários de avaliação, para os quais é assumido um número crescente de classes conhecidas.

A organização do trabalho é a seguinte: inicialmente, é apresentada a estrutura hierárquica adotada para a construção do sistema de detecção de novidades, e discutida a aplicação das técnicas NNd, *k*NN, e LOF para a construção de tais detectores. Em seguida, são apresentados a base de dados e os resultados. Encerrando o trabalho, têm-se as conclusões e os trabalhos futuros.

## II. SISTEMA DETECTOR DE NOVIDADES

Nesta seção serão abordadas a topologia do sistema, as técnicas utilizadas para o desenvolvimento dos detectores, as figuras de mérito visando à avaliação de seu desempenho, e discutido o processo de sintonia dos seus hiperparâmetros.

### A. Topologia

A estrutura do detector hierárquico [10] explorado neste trabalho é apresentada na Figura 1. É possível observar que um dado arbitrário pré-processado é, primeiramente, submetido a um classificador de alta-eficiência, que o rotula como oriundo de uma dentre as  $N$  classes conhecidas. Em seguida, apenas o detector relativo a esta classe (especializado) é selecionado

para gerar a saída do sistema, identificando-o ou não como novidade.

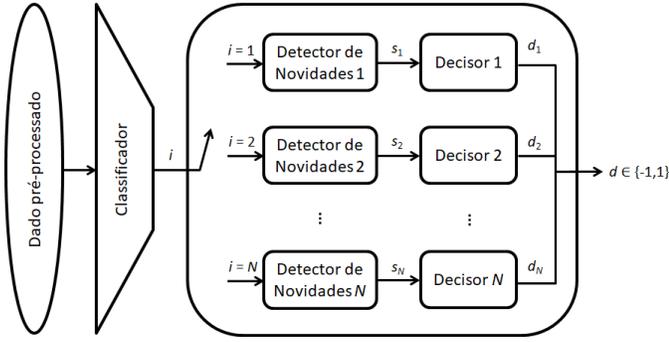


Fig. 1. Topologia hierárquica do sistema detector de novidades.

Em síntese, cada detector produz uma variável  $s_i$  ( $1 \leq i \leq N$ ) relacionada à dissimilaridade entre o dado sob avaliação ( $\mathbf{x}$ ) e a classe que este detector representa. Por sua vez, esta variável alimenta o bloco decisor  $i$ , que possui um limiar interno  $\lambda_i$ , produzindo como saída a variável  $d_i$ , tal que  $d_i = 1$ , se  $s_i \geq \lambda_i$ , isto é, o dado é muito dissimilar a  $i$ -ésima classe, e  $d_i = -1$ , caso contrário.

### B. Técnicas

Foram investigadas três técnicas de aprendizagem por instância, a saber: NNd,  $k$ NN, e LOF, sendo exploradas diferentes formas de medir as distâncias aos protótipos de cada classe, a serem utilizadas como medida de dissimilaridade nos detectores correspondentes.

1) *NNd*: A técnica NNd utiliza como medida de dissimilaridade uma razão entre duas distâncias, conforme a Equação 1. O numerador corresponde à distância entre o sinal sob avaliação ( $\mathbf{x}$ ) e o seu  $k$ -ésimo vizinho mais próximo  $NN_k^{tr}(\mathbf{x})$  do conjunto de treinamento. O denominador considera a distância entre este vizinho ( $NN_k^{tr}(\mathbf{x})$ ) e o dado mais próximo deste conjunto, portanto  $NN_1^{tr}(NN_k^{tr}(\mathbf{x}))$ .

$$s = \frac{\text{dist}(\mathbf{x}, NN_k^{tr}(\mathbf{x}))}{\text{dist}(NN_k^{tr}(\mathbf{x}), NN_1^{tr}(NN_k^{tr}(\mathbf{x})))} \quad (1)$$

2) *kNN*: O  $k$ NN avalia a proximidade de um dado sob análise em relação a seus vizinhos mais próximos, identificados no conjunto de treinamento, conforme ilustrado na Figura 2. Neste exemplo arbitrário, considerando-se um total de 5 vizinhos mais próximos ( $k = 5$ ), obtém-se a seguinte ordem crescente de distâncias aos vizinhos:  $d_1, d_3, d_2, d_5$  e  $d_4$ .

De posse de  $k$  distâncias ordenadas de forma crescente ( $S = d_1, \dots, d_k$ ), três possíveis medidas de dissimilaridade foram consideradas:

(a) De forma similar à [10], assumiu-se como dissimilaridade o valor da mediana da distância euclidiana entre o dado e os seus  $k$  vizinhos, de acordo com a Equação 2.

$$s = \text{mediana}(d_1, d_2, \dots, d_{k-1}, d_k) \quad (2)$$

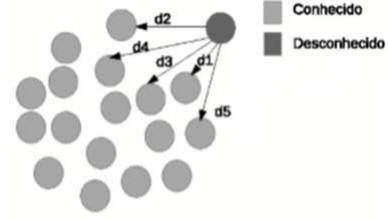


Fig. 2. Técnica  $k$ NN.

(b) Esta variante considerou, ao invés da mediana, a média da distância euclidiana entre o dado e seus  $k$  vizinhos mais próximos, conforme a Equação 3.

$$s = (d_1 + d_2 + \dots + d_{k-1} + d_k)/k \quad (3)$$

(c) Neste caso, a medida de dissimilaridade é dada pela média de três distâncias: a distância da mediana (Equação 2) e as distâncias adjacentes. Ressalta-se que esta técnica requer  $k$  ímpar. Assumindo  $k = 2t + 1$ , em que  $t$  é inteiro, e a distância correspondente à mediana dada por  $d_t$ , esta dissimilaridade é descrita pela Equação 4:

$$s = (d_{t-1} + d_t + d_{t+1})/3 \quad (4)$$

3) *LOF*: A técnica LOF compara a densidade local de um dado relativamente à densidade local de seus vizinhos, identificando novidades quando tais densidades são suficientemente distintas. Para um dado arbitrário  $\mathbf{x}$ , o índice é calculado como a razão entre o valor médio da densidade de alcançabilidade local -  $lrd_k(o)$  - de seus  $k$  vizinhos -  $N_k(\mathbf{x})$  - onde  $o \in N_k(\mathbf{x})$  e a densidade de alcançabilidade local do próprio dado -  $lrd_k(\mathbf{x})$  - conforme a Equação 5 [9]:

$$s = LOF_k(\mathbf{x}) = \frac{1}{k} \sum_{o \in N_k(\mathbf{x})} \frac{lrd_k(o)}{lrd_k(\mathbf{x})} \quad (5)$$

Neste caso, como um valor de  $s$  superior a 1 indica que o dado tende a ser um *outlier*, tal score é assumido como medida de dissimilaridade.

### C. Avaliação do detector

As principais figuras de mérito para a avaliação de um detector de novidades são as taxas de detecção de classes conhecidas e desconhecidas que representam interesses contraditórios a serem maximizados. Assim, para um conjunto de classes  $\mathcal{K} = \{K_1, K_2, \dots, K_N\}$  extraído de uma base de dados  $\mathcal{D}$ , a taxa de detecção da  $i$ -ésima classe conhecida ( $TC_i$ ) é dada por:

$$TC_i = \frac{1}{\#K_i} \sum_{\mathbf{x}_j \in K_i} I(d_j(\mathbf{x}_j) = -1), \quad (6)$$

onde  $\#K_i$  representa a cardinalidade de  $K_i$  ( $1 \leq i \leq N$ ), enquanto a função indicadora  $I(\cdot)$  possui saída 1 caso a condição seja verdadeira; e 0, caso contrário.

Note que um indicador global de desempenho é a taxa média de detecção de classes conhecidas, definida como:

$$TC = \frac{1}{N} \sum_{i=1}^N TC_i, \quad (7)$$

portanto, simplesmente, correspondente a média dos valores de  $TC_i$ .

Quanto ao reconhecimento das classes desconhecidas, qualquer teste experimental envolvendo o detector demandaria o conhecimento destas a priori, o que as tornaria conhecidas. Para lidar com esta contradição, vamos supor a existência de uma base de dados  $\mathcal{U}$ , contendo um conjunto de  $R$  classes, definido como  $\mathcal{U} = \{U_1, U_2, \dots, U_R\}$ , tal que  $\mathcal{D} = \mathcal{K} \cup \mathcal{U}$ . Assim, estamos supondo que parte das classes de  $\mathcal{D}$  são conhecidas e o restante, desconhecidas. Deste modo, similar à Equação 6, é possível definir uma taxa de detecção da  $i$ -ésima classe desconhecida ( $TD_i$ ), conforme a Equação 8, bem como uma taxa média de detecção de eventos desconhecidos, dada pela Equação 9.

$$TD_i = \frac{1}{\#U_i} \sum_{\mathbf{x}_j \in U_i} I(d_j(\mathbf{x}_j) = 1) \quad (8)$$

$$TD = \frac{1}{R} \sum_{i=1}^R TD_i \quad (9)$$

Ambos indicadores  $TC$  e  $TD$  são dependentes da escolha do limiar de decisão do detector associado à cada classe. Para a avaliação de diferentes compromissos entre tais indicadores, a serem estabelecidos por diferentes escolhas de limiar, de modo similar à curva de operação do receptor (ROC) [11], define-se a curva de operação do detector (COD), expressando-se  $TD$  em função de  $TC$ . Esta curva associa as taxas de reconhecimento de classes desconhecidas e conhecidas, obtidas para cada limiar pertencente a uma dada faixa de avaliação.

Uma forma eficaz para a definição de tais limiares é considerar diferentes valores de percentis da medida de dissimilaridade às classes, tal que  $\{\alpha_1, \alpha_2, \dots, \alpha_{p-1}, \alpha_p\} = \{0\%, 5\%, \dots, 95\%, 100\%\}$ , considerando o conjunto de validação de cada classe. Assim, para eventos da  $i$ -ésima classe do conjunto de validação, o  $x\%$ -percentil das dissimilaridades associadas a seus dados define um valor para  $\lambda_i$ , tal que  $TC_i = x\%$ . Como os detectores são independentes, assumindo um classificador “quase-ideal” no primeiro estágio do detector, teremos:  $T \approx TC_1 = TC_2 = \dots = TC_N$ .

Um indicador síntese útil baseado na COD é a área abaixo da curva (AUC) [11]. Note que um detector ideal apresentaria  $TC = TD = 100\%$ , portanto AUC com valor máximo igual a 1 na curva COD. Claramente, a obtenção de maiores valores de  $TD$  para diferentes valores de  $TC$  indica um melhor detector, resultando em um maior valor para a AUC.

#### D. Sintonia dos detectores

As técnicas consideradas para a produção dos indicadores avaliados possuem como principal hiperparâmetro a quantidade de vizinhos a considerar, a qual influencia diretamente no desempenho do detector. A ideia aqui é realizar a melhor escolha para uma ampla faixa de valores de  $TC$  e  $TD$ . Para evitar qualquer viés nesta escolha, optou-se pela definição do hiperparâmetro segundo um esquema de “um-contra-todos” envolvendo as classes conhecidas. Assim, assumindo conhecidas as classes arbitrárias A, B e C, a sintonia relativa à classe A considerou esta como conhecida, enquanto as classes B e C desconhecidas. Por sua vez, para a classe B, as classes A e C figuram como desconhecidas; e assim, sucessivamente. Como figura de mérito adotou-se a AUC relativa à COD em tal esquema, segundo um processo de validação cruzada que considerou a técnica de reamostragem 10-fold aninhado [11].

### III. BASE DE DADOS

Neste trabalho, os experimentos utilizaram dados reais obtidos na raia acústica da Marinha do Brasil, localizada em Arraial do Cabo, onde 28 navios pertencentes a 8 classes de embarcações diferentes efetuaram 263 corridas de prova. Um hidrofone localizado no fundo da raia acústica captou os ruídos emitidos pelas embarcações e o sinal resultante foi amostrado a uma taxa de 22050 Hz, utilizando 16 bits de resolução.

Estes sinais foram pré-processados de acordo com a cadeia descrita em [10], gerando janelas espectrais de norma euclidiana unitária, considerando 557 frequências regularmente espaçadas na faixa de 0 à 3 kHz.

Cada janela espectral está associada a um rótulo de classe  $r_C \in \{A, B, C, D, E, F, G, H\}$ , ou, de forma mais específica, a um rótulo de navio  $r_N \in \{A1, A2, A4, B1, B2, B3, B5, C1, C2, C3, C4, C5, D1, D3, D4, E1, E2, E3, E4, F1, F2, F3, F4, G1, G2, H1, H2, H5\}$ , conforme a Tabela I, onde N.E. representa o número de janelas espectrais resultantes associadas a cada navio em particular.

### IV. CENÁRIOS INVESTIGADOS

Para a avaliação dos modelos, as 8 classes de embarcações da base de dados foram particionadas nos conjuntos de classes supostamente conhecidas ( $\mathcal{K}$ ) e desconhecidas ( $\mathcal{U}$ ). Foram assumidos três cenários de avaliação, envolvendo 3, 5 e 7 classes conhecidas, que representam diferentes complexidades quanto à tarefa de identificação de novidades. Para a definição das classes integrantes de  $\mathcal{K}$  em cada cenário, foram realizadas simulações contemplando todas as combinações possíveis para cada caso. No entanto, por restrições computacionais, em tais ensaios, foi assumido um detector de novidades mais simples, definido tão somente pela distância ao vizinho mais próximo (*Nearest Neighbor* [7]). De posse de tais simulações, foi escolhida para cada cenário a combinação de classes conhecidas que resultou no menor valor de mediana da AUC. Tal critério adotado aponta a combinação mais conflitante, portanto, o cenário de avaliação mais crítico. Como resultado, foram consideradas como conhecidas (desconhecidas) as seguintes

TABELA I

Número de janelas espectrais (N.E.) resultantes do pré-processamento dos sinais provenientes das diferentes classes e navios.

Classe	Navio	N.E.	Classe	Navio	N.E.
A	A1	1191	B	B1	914
	A2	504		B2	700
	A4	737		B3	1224
				B5	594
	Total	2432		Total	3432
Classe	Navio	N.E.	Classe	Navio	N.E.
C	C1	512	D	D1	1401
	C2	1081		D3	406
	C3	799		D4	1265
	C4	705			
	C5	1700			
	Total	4797		Total	3072
Classe	Navio	N.E.	Classe	Navio	N.E.
E	E1	2462	F	F1	636
	E2	717		F2	857
	E3	3505		F3	628
	E4	391		F4	813
	Total	7075		Total	2934
Classe	Navio	N.E.	Classe	Navio	N.E.
G	G1	867	H	H1	1680
	G2	1276		H2	975
				H5	737
	Total	2143		Total	3392

classes: A, C e G (B, D, E, F e H); A, B, C, F e G (D, E e H); e A, B, C, E, F, G e H (D).

## V. RESULTADOS

Os modelos foram avaliados considerando valores de AUC produzidos através da técnica de reamostragem 10-fold aninhado. Por esta técnica, o conjunto de dados contendo as classes conhecidas (para determinado cenário investigado) foi subdividido em 10 subconjuntos, dos quais um foi alocado como conjunto de teste a cada rodada. Os demais foram reagrupados e subdivididos novamente em 10 subconjuntos, agora um deles reservado para a validação e os nove restantes para o treinamento. Tal procedimento gerou 100 trios de conjuntos de treino, validação e teste.

Por simplicidade, o classificador adotado no primeiro nível também foi baseado em  $k$ NN, com o número de vizinhos definido por validação cruzada, assumindo como figura de mérito a acurácia média [11]. Os quantitativos associados a cada classe e ensaio são resumidos na Tabela II.

TABELA II

Hiperparâmetros selecionados para o classificador.

ACG	ABCFG	ABCEFGH
7	7	9

A Tabela III apresenta as faixas de hiperparâmetros avaliadas para cada técnica, que foram definidos através de alguns ensaios experimentais.

A Tabela IV exhibe os hiperparâmetros selecionados pelo processo de validação cruzada para cada classe nos três

cenários investigados, considerando as diferentes técnicas avaliadas.

TABELA III

Faixas de investigação do hiperparâmetro de cada técnica.

Técnicas	Faixa do hiperparâmetro
NNd	[1,5]
$k$ NN(a)	[1,30]
$k$ NN(b)	[1,30]
$k$ NN(c)	Ímpares de [3,63]
LOF	[2,30]

TABELA IV

Hiperparâmetros selecionados para os detectores.

Cenário	Classe	NNd	$k$ NN(a)	$k$ NN(b)	$k$ NN(c)	LOF
ACG	A	1	6	7	5	12
	C	1	2	2	3	4
	G	2	15	15	13	21
ABCFG	A	1	5	5	7	14
	B	1	2	2	3	11
	C	1	2	3	3	4
	F	1	2	3	3	9
	G	1	15	15	13	19
ABCEFGH	A	1	5	9	5	10
	B	1	2	2	3	11
	C	1	2	2	3	4
	E	1	2	4	3	4
	F	1	2	3	3	8
	G	1	15	15	13	20
	H	1	14	17	13	28

Adotou-se o teste de Friedman com nível de significância de 5% [11] para verificar se os valores do indicador AUC obtidos para os diferentes métodos eram estatisticamente distintos. Para os casos onde tal diferença foi observada, foi aplicado o teste  $HSD$  [11] para identificar entre quais pares de métodos isso ocorre.

### A. Classes conhecidas: A, C e G

Na Figura 3 é apresentado o diagrama de caixas da AUC para este cenário de avaliação. Observa-se um melhor desempenho das abordagens baseadas em  $k$ NN. A técnica LOF se sobressai também em relação a NNd, o que está provavelmente associado ao critério mais sofisticado de estimação da densidade local adotado pela primeira. Os testes de hipótese confirmam diferenças de desempenho entre os métodos ( $\chi^2(4) > 332,4, p < 0,001$ ), com melhor desempenho da técnica  $k$ NN(b) sobre as demais ( $p < 0,014$ ).

### B. Classes conhecidas: A, B, C, F e G

Os resultados são exibidos na Figura 4. Observa-se um comportamento similar ao ensaio com 3 classes, sendo identificado que os métodos apresentam um desempenho distinto ( $\chi^2(4) > 289,2, p < 0,001$ ). No entanto, o método  $k$ NN(c) é similar ao  $k$ NN(a) ( $p = 1$ ) e ao  $k$ NN(b) ( $p = 0,971$ ), porém apresenta maior mediana.

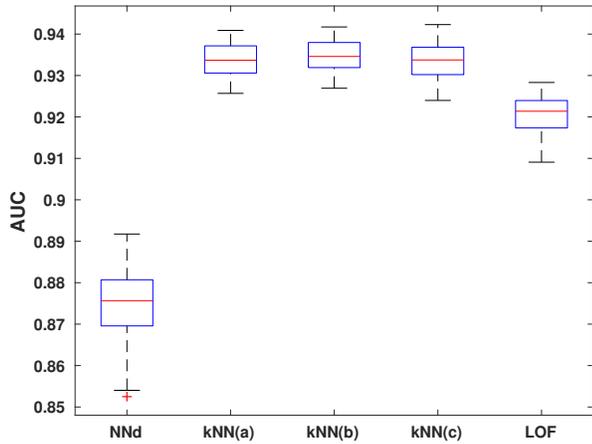


Fig. 3. Diagrama de caixas da AUC do ensaio considerando 3 classes conhecidas (vide texto).

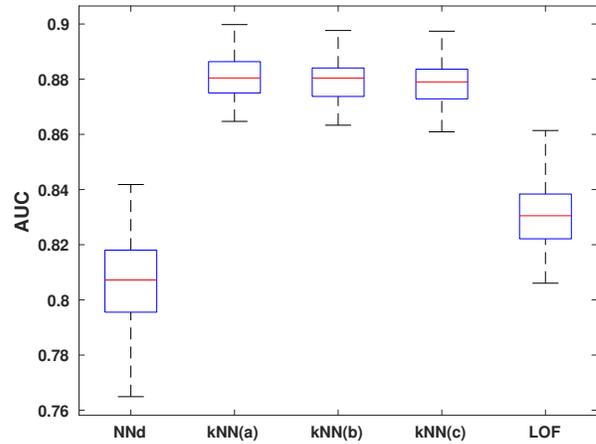


Fig. 5. Diagrama de caixas da AUC do ensaio considerando 7 classes conhecidas (vide texto).

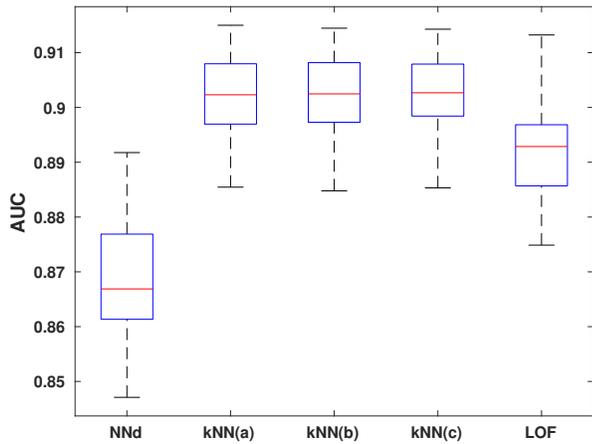


Fig. 4. Diagrama de caixas da AUC do ensaio considerando 5 classes conhecidas (vide texto).

### C. Classes conhecidas: A, B, C, E, F, G e H

A Figura 5 resume os resultados. Observa-se um mesmo padrão de comportamento dos ensaios anteriores, com os métodos apresentando diferente desempenho ( $\chi^2(4) > 341,6, p < 0,001$ ). No entanto, o  $kNN(a)$  se sobressai com um valor superior de mediana, porém seu desempenho é equivalente ao  $kNN(b)$  ( $p = 0,434$ ).

### D. Discussão

As técnicas baseadas em  $kNN$  assumem um melhor resultado, uma vez que dentre os algoritmos avaliados é o que melhor mapeia o contorno da classe dos navios.

Cabe notar que o aumento do número de classes conhecidas do sistema leva a uma redução do desempenho quanto à detecção de novidades. Tal resultado é coerente, visto que

um maior número de classes conhecidas leva a uma maior complexidade quanto a definição de uma novidade ou não. Adicionalmente, como a detecção é hierárquica, é esperado uma redução da acurácia média do classificador empregado no primeiro nível quando mais classes são consideradas.

Em virtude da base de dados estudada ser confidencial, não se pode obter extrair nenhuma relação entre os resultados obtidos e as características reais das classes e navios.

A Tabela V apresenta os valores de  $TD$  associados aos valores de  $TC = \{75\%, 95\%\}$  para os modelos associados a mediana dos diferentes ensaios de cada cenário.

TABELA V

Valores médios de  $TD$  (associados a valores médios de  $TC$ ) obtidos nas melhores técnicas de cada cenário investigado.

Cenário - Técnica	$TC = 75\%$	$TC = 95\%$
ACG - $kNN(b)$	93,4%	78,0%
ABCFG - $kNN(c)$	89,6%	66,5%
ABCEFGH - $kNN(a)$	86,4%	42,4%

Relegando-se as diferenças entre as base de dados e as sistemáticas de avaliação, observa-se que nosso modelo para o cenário de 3 classes conhecidas supera o proposto em [12], baseado em Máquinas de Vetor-Suporte de Uma Classe (*One-Class SVM*), o qual obteve  $TD = 75\%$  para  $TC = 62,4\%$ .

## VI. CONCLUSÃO

Este trabalho se dedicou a avaliar diferentes técnicas de aprendizado por instância para a construção de um detector de classes desconhecidas a ser utilizado em sistemas de sonar passivo.

Dentre as técnicas avaliadas, o método  $kNN$  se sobressaiu em relação às técnicas LOF e NNd. No entanto, para cada cenário investigado, tem-se uma melhor medida de dissimilaridade para a construção do detector. O incremento do

número de classes conhecidas também levou a uma redução no desempenho do detector.

Como trabalhos futuros, espera-se avaliar outras técnicas de Aprendizagem de Máquina para a geração das dissimilaridades, entre elas a técnica de Análise de Componentes Principais por *Kernel* (KPCA), *One-Class SVM* e algoritmos de *Deep Learning*, entre eles os *Autoencoders*. Busca-se-á também técnicas para a redução da complexidade computacional dos detectores baseados em  $k$ NN. Outra abordagem a ser investigada consiste na construção de detectores especializados diretamente nos navios, e não apenas em suas classes.

#### AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), e da Fundação de Amparo a Pesquisa do Estado do Rio de Janeiro (FAPERJ). Agradecemos também ao Instituto de Pesquisas da Marinha (IPqM) pela disponibilização da base de dados e pela cooperação técnico-científica.

#### REFERÊNCIAS

- [1] A. Das, A. Kumar, and R. Bahl, "Marine vessel classification based on passive sonar data: the cepstrum-based approach," *IET Radar, Sonar and Navigation*, vol. 7, pp. 438 – 441, 2013.
- [2] G. M. R. Rocha and J. B. O. Souza Filho, "Redes convolucionais para a classificação de sinais de sonar passivo," in *XI Encontro de Tecnologia em Acústica Submarina*, (Rio de Janeiro, Brasil), 2014.
- [3] J. B. O. Souza Filho and J. M. Seixas, "Class-modular multi-layer perceptron networks for supporting passive sonar signal classification," *IET Radar Sonar and Navigation*, vol. 10, pp. 311 – 317, 2015.
- [4] T. C. C. Oliveira and J. B. O. Souza Filho, "Otimização de classificadores de sinais de sonar passivo baseados em curvas principais hierárquicas," in *Simpósio Brasileiro de Automação Inteligente*, (Porto Alegre, Brasil), 2017.
- [5] H. Yang, S. Shen, X. Yao, and et al., "Competitive deep-belief networks for underwater acoustic target recognition," *Sensors*, 2018.
- [6] M. A. Pimentel, D. A. Clifton, L. Clifton, and L. Tarassenko, "A review of novelty detection," *Signal Processing*, vol. 99, pp. 215 – 249, 2014.
- [7] K. P. Murphy, *Machine learning: a probabilistic perspective*. MIT press, 2012.
- [8] D. M. J. Tax and R. P. W. Duin, "Outlier detection using classifier instability," in *Advances in Pattern Recognition* (A. Amin, D. Dori, P. Pudil, and H. Freeman, eds.), (Berlin, Germany), pp. 593–601, Springer Berlin Heidelberg, 1998.
- [9] M. M. Breunig, H.-P. Kriegel, R. T. Ng, and J. Sander, "Lof: Identifying density-based local outliers," in *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data*, (New York, NY, USA), pp. 93–104, ACM, 2000.
- [10] G. M. R. Rocha and J. B. O. Souza Filho, "Sistemas de classificação de contatos de sonar passivo com rejeição à classes desconhecidas," in *XXI Congresso Brasileiro de Automática*, (Vitória, Brasil), 2016.
- [11] N. Japkowicz and M. Shah, *Evaluating learning algorithms: a classification perspective*. Cambridge University Press, 2011.
- [12] N. N. Moura Junior, *Deteção de novidade em sistemas de sonar passivo*. PhD thesis, Universidade Federal do Rio de Janeiro, 2018.