

Classificação Hierárquica de Navios em Sinais de Sonar Passivo

Victor Hugo da Silva Muniz, Matheus Bastos de Oliveira 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, oliveiraa.maatheus@poli.ufrj.br e jbfilho@poli.ufrj.br

Resumo—A classificação de possíveis ameaças a submarinos é realizada por operadores de sonar, que analisam as características tonais e espectrais dos ruídos adquiridos no ambiente aquático. Automatizar esta tarefa através da construção de sistemas automáticos de reconhecimento de classes e navios reduziria o desgaste físico e psíquico deste profissional. Este artigo discute a classificação de navios propondo um modelo de classificação hierárquica. Duas técnicas são avaliadas para a construção deste classificador: *Random Forest* e *k-nearest neighbors*. Resultados envolvendo sinais reais adquiridos de 28 navios apontam um melhor desempenho da técnica *k-nearest neighbors*.

Keywords—sonar passivo; *random forest*; *k-nearest neighbors*; sistemas de apoio à decisão; aprendizagem de máquina

I. INTRODUÇÃO

Em ambientes marítimos, as ondas acústicas são a forma primordial de radiação adotada por sistemas de comunicação e rastreamento, visto que as ondas eletromagnéticas são fortemente atenuadas nesse meio.

Sistemas de sonar passivo são o principal mecanismo de defesa de submarinos. Através deles, as vibrações emitidas por outras embarcações são captadas por um arranjo de hidrofones e processadas para a obtenção de características tonais e espectrais. Estas são analisadas por operadores treinados para a identificação da assinatura acústica correspondente, classificando tais contatos como ameaça ou não.

Técnicas de Aprendizagem de Máquina são promissoras para o desenvolvimento de sistemas automáticos de suporte à decisão. Estas ferramentas podem auxiliar o trabalho do operador, aliviando o esforço de vigilância exigido, bem como permitir que sua atuação se concentre em situações de maior risco. Dentre elas, resultados promissores foram obtidos com as redes convolucionais [1], as redes neurais especialistas [2] e a técnica de curvas principais [3] na identificação de classes de contato.

A tarefa de classificação automática de navios costuma ser pouco abordada na literatura. Trata-se de um problema não-trivial, dado o número significativo de categorias existentes, usualmente da ordem de dezenas. Em Fernandes *et al.* [3], foi proposta uma estratégia hierárquica baseada na técnica de Curvas Principais (CP), que representa uma poderosa técnica de extração de características de dados multidimensionais. Segundo esta proposta, para um evento sob avaliação, é identificada a CP representativa da classe mais próxima a ele.

Após, o referido evento é projetado nesta curva, identificando-se o valor do coeficiente de projeção correspondente, que é utilizado para a identificação do navio mais provável.

Este trabalho revisita este problema, considerando, no entanto, o uso de classificadores arbitrários em ambos os níveis desta hierarquia. Assim, primeiramente, emprega-se um classificador para a identificação da classe do contato, para, em seguida, ser utilizado um segundo classificador especializado, cujo papel é identificar qual navio é o mais provável. Nesta avaliação foram considerados os seguintes algoritmos: *k-nearest neighbors* (*k*NN) e *Random Forest* (RF) [4], de eficácia comprovada em várias aplicações da literatura.

A estrutura do artigo é a seguinte: inicialmente, é discutida a construção do sistema proposto. Em sequência, tem-se uma breve descrição dos algoritmos RF e *k*NN. Após, a base de dados e os resultados são reportados. Ao final, têm-se as conclusões e os trabalhos futuros.

II. CLASSIFICAÇÃO DE NAVIOS

Assumindo um conjunto de rótulos de classes $C_C = \{A, B, \dots\}$ e de navios $C_N = \{A1, A2, \dots, B1, \dots\}$ ¹, duas topologias possíveis para a constituição de um sistema de classificação de navios são:

(I) Tradicional ou Direta (DI) - o sinal proveniente do sistema de sonar passivo \mathbf{x} , já devidamente processado, alimenta um único classificador, produzindo um rótulo de saída $r_N \in C_N$ associado ao navio mais provável, conforme a Figura 1.



Fig. 1. Topologia Direta.

(II) Hierárquica (HI) - Opera em dois estágios, como ilustrado na Figura 2. No primeiro, o dado de entrada \mathbf{x} é submetido a um classificador especializado em classes, que o rotula como sendo oriundo de uma dentre as M classes conhecidas, por meio de $r_C \in C_C$. No segundo, apenas o classificador especializado nos navios desta classe é acionado para a produção do rótulo $r_N \in C_N$ da embarcação.

¹A letra maiúscula designa a classe do navio, enquanto a combinação de letra e número refere-se a um navio em particular desta classe.

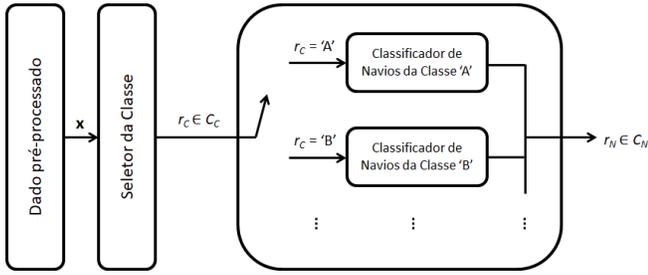


Fig. 2. Topologia Hierárquica.

III. ALGORITMOS DE CLASSIFICAÇÃO

Foram considerados os algoritmos RF e k NN, que são atrativos pela robustez e reduzido número de hiperparâmetros envolvidos, além de adotarem estratégias significativamente distintas de operação. Ademais, consistem em duas técnicas clássicas frequentemente empregadas em trabalhos na área do Aprendizado de Máquina ([5], [6], [7]).

A. Random Forest

O RF é uma técnica de comitê baseada no algoritmo de Árvores de Decisão [4], a qual é responsável por inferir dos dados um conjunto de regras capazes de determinar seus rótulos. Assumindo dados descritos por p atributos, são criadas m árvores, cada uma considerando um subconjunto aleatório de s atributos, onde $s \leq m$ (comumente arbitra-se $s = \sqrt{p}$), e uma amostra *bootstrap* dos dados. A saída da “floresta” é definida pelo rótulo mais frequente, processo ilustrado na Figura 3, onde um dado arbitrário é aplicado a m árvores, cujas saídas, pela moda, apontam que o rótulo a ser atribuído é o correspondente à Classe 2.

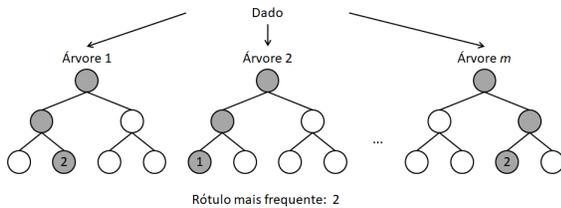


Fig. 3. Ilustração do método *Random Forest*.

B. k NN

O k NN é uma técnica de aprendizado baseada em instâncias que explora a proximidade de um dado com seus vizinhos mais próximos, usualmente inferida por meio da distância euclidiana. Para um dado sob avaliação, são identificados os k vizinhos mais próximos, sendo considerado o rótulo mais frequente dentre tais vizinhos para definir a saída do classificador. A Figura 4 ilustra este processo, onde o indicador estrela sinaliza um dado arbitrário a ser classificado. Assumindo $k = 4$, claramente o rótulo correspondente será Classe 2.

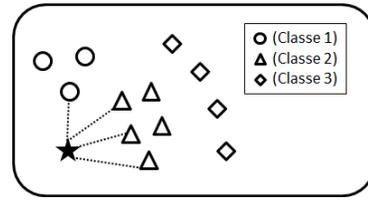


Fig. 4. Ilustração do método *k-nearest neighbors*.

IV. AVALIAÇÃO DOS CLASSIFICADORES

A avaliação dos classificadores possui um papel fundamental na escolha dos seus hiperparâmetros, bem como relativamente a sua avaliação final, sendo dependente da figura de mérito escolhida. Neste problema, duas figuras de mérito foram consideradas: a taxa de acerto no reconhecimento dos navios e a acurácia média, definidas a seguir.

Seja um conjunto de navios \mathcal{K} dado por $\mathcal{K} = \{K_1, K_2, \dots, K_N\}$, onde N representa o número total de navios. A taxa de acerto no reconhecimento do i -ésimo navio (TA_i), onde $1 \leq i \leq N$, é dada por:

$$TA_i = \frac{1}{\#K_i} \sum_{\mathbf{x}_j \in K_i} I(r_{N_j} = t_j), \quad (1)$$

onde: \mathbf{x}_j designa um exemplo arbitrário do conjunto de dados associado ao navio K_i , $\#K_i$ representa a cardinalidade de K_i e a função indicadora $I(\cdot)$ possui saída 1, caso a saída r_{N_j} produzida pelo classificador seja igual ao rótulo real t_j ; e 0, caso contrário.

Como medida global de desempenho será considerada a acurácia média, correspondente a:

$$TA = \frac{1}{N} \sum_{i=1}^N TA_i, \quad (2)$$

definida pela média aritmética simples dos valores de TA_i .

A estimativa do desempenho dos modelos considerou a técnica de reamostragem *k-fold* aninhado [8]. Assumiu-se $k = 10$, portanto o conjunto de dados foi dividido em 10 grupos, dos quais um era reservado para a definição do conjunto de teste a cada rodada. Por sua vez, os demais foram reagrupados e particionados em outros 10 grupos, sendo agora um reservado para a formação do conjunto de validação, enquanto os restantes para o conjunto de treinamento. Tal procedimento gerou 100 trios de conjuntos de treino, validação, e teste.

V. DIMENSIONAMENTO DOS CLASSIFICADORES

Para o projeto do classificador hierárquico, faz-se necessária a definição dos hiperparâmetros do algoritmo de classificação base, portanto o número de árvores (m) no RF e de vizinhos mais próximos (k) no k NN, os quais, naturalmente, influenciam no desempenho do modelo.

A definição do melhor hiperparâmetro considerou a maior mediana de TA_i ou TA nos ensaios da técnica *k-fold* aninhado. Nos casos de empate, isto é, quando dois ou mais

hiperparâmetros possuíam resultados equivalentes, o critério de desempate considerou a maior mediana sobre a pior classe, isto é, aquela associada ao menor valor de TA_i .

VI. BASE DE DADOS

A metodologia proposta foi avaliada utilizando sinais gravados em ensaios controlados realizados na raia acústica da Marinha do Brasil, localizada em Arraial do Cabo. A base de dados é constituída pelo áudio irradiado por 28 navios pertencentes a 8 classes, durante 263 corridas de provas.

O áudio emitido pelas embarcações foi captado por um hidrofone localizado junto ao fundo do assoalho da raia acústica. Em seguida, este foi amostrado, pré-processado e normalizado [9], de forma a definir um conjunto de janelas espectrais de 557 pontos cada uma, cobrindo uma faixa de frequência de 0 a 3 kHz, aproximadamente.

Cada janela espectral \mathbf{x}_i está associada a um rótulo de classe y_i , tal que $Q_C = \{(\mathbf{x}_i, y_i) | \mathbf{x}_i \in \mathbf{R}^{557}, y_i \in \{A, B, C, D, E, F, G, H\}, i = 1, \dots, 29277\}$ ou, de forma mais específica, relativamente aos seus navios, $Q_N = \{(\mathbf{x}_i, y_i) | \mathbf{x}_i \in \mathbf{R}^{557}, y_i \in \{A1, A2, A4, B1, B2, B3, B5, C1, C2, C3, C4, C5, D1, D3, D4, E1, E2, E3, E4, F1, F2, F3, F4, G1, G2, H1, H2, H5\}, i = 1, \dots, 29277\}$, conforme a Tabela I.

TABELA I

Distribuição do quantitativo de espectros (N.E.) para as 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 |
| C | C1 | 512 | D | D1 | 1401 |
| | C2 | 1081 | | D3 | 406 |
| | C3 | 799 | | D4 | 1265 |
| | C4 | 705 | | | |
| | C5 | 1700 | | | |
| | | Total | 4797 | | Total |
| E | E1 | 2462 | F | F1 | 636 |
| | E2 | 717 | | F2 | 857 |
| | E3 | 3505 | | F3 | 628 |
| | E4 | 391 | | F4 | 813 |
| | | Total | 7075 | | Total |
| G | G1 | 867 | H | H1 | 1680 |
| | G2 | 1276 | | H2 | 975 |
| | | | | H5 | 737 |
| | Total | 2143 | | | Total |

VII. RESULTADOS

O algoritmo RF assumiu a Impureza de Gini [10] para a divisão dos ramos, a qual foi realizada até que todos os nós fossem puros. O número de árvores (m) avaliado para a construção das florestas considerou a seguinte faixa: $m \in \{10, 25, 50, 100, 250, 350, 500\}$.

Em relação ao algoritmo k NN, as faixas de valores investigados no processo de validação cruzada foram: (i) abordagem

tradicional - $k \in \{1 \leq k \leq 9\}$; (ii) abordagem hierárquica - primeiro estágio (seletor da classe) - $k \in \{1 \leq k \leq 13\}$; (iii) abordagem hierárquica - segundo estágio (classificador de navios) - $k \in \{1 \leq k \leq 16\}$. Os hiperparâmetros selecionados para cada caso são apontados nas seções subsequentes.

A. RF

A Tabela II sintetiza o número de árvores selecionadas para a técnica RF. É interessante observar que na modalidade direta, o número de árvores é maior do que o empregado pela hierárquica (estágio 1). Tal fato é coerente, visto que, naturalmente, a separação de navios é mais complexa do que a de classes.

TABELA II

Número de árvores selecionadas para os classificadores baseados em RF.

| Direta: | | | | | | | | 350 |
|--------------|-----|-----|-----|-----|-----|-----|-----|-----|
| Hierárquica: | | | | | | | | |
| - Estágio 1: | | | | | | | | 250 |
| - Estágio 2: | | | | | | | | |
| A | B | C | D | E | F | G | H | |
| 250 | 100 | 100 | 250 | 100 | 250 | 500 | 250 | |

As Figuras 5 e 6 apresentam os valores das medianas associadas a cada TA_i para os 100 ensaios realizados. É possível observar que a abordagem hierárquica se destaca apenas para a classificação de um total de 4 navios (A4, D3, E4, e H2), enquanto a topologia direta é melhor quanto a classificação de 10 navios (A1, B2, B5, C2, C3, C4, C5, D4, E3, e H5). Para os 14 navios restantes, o desempenho de ambas abordagens foi similar.

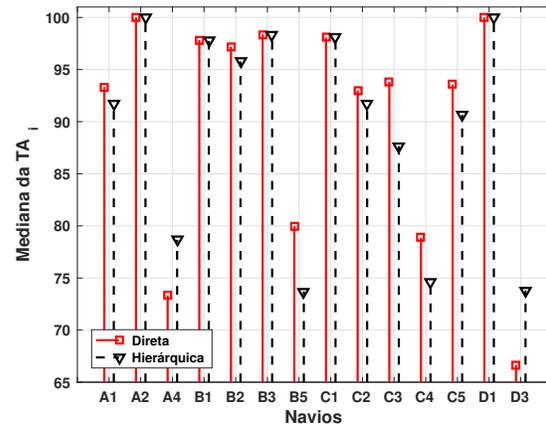


Fig. 5. Mediana da eficiência de cada topologia na classificação dos navios (A1-D3) ao utilizar o RF.

B. k NN

A Tabela III aponta o número de vizinhos selecionados para o algoritmo k NN para cada topologia. Observa-se que o número de vizinhos adequado para a seleção das classes é maior do que para a seleção direta dos navios. Por sua vez,

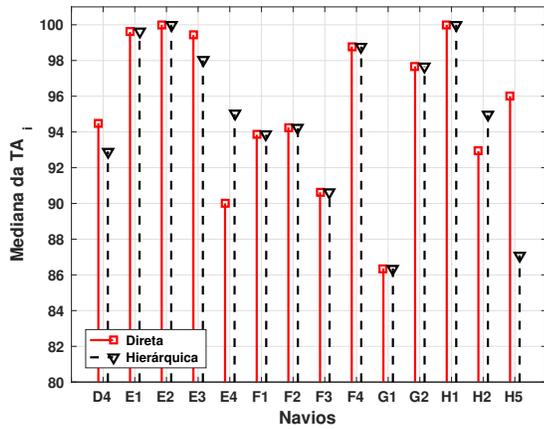


Fig. 6. Mediana da eficiência de cada topologia na classificação dos navios (D4-H5) ao utilizar o RF.

com exceção da classe H, a complexidade da tarefa quanto à seleção de navios de uma mesma classe (hierárquico - estágio 2) parece ser menor do que a seleção das classes, visto a utilização de um menor número de vizinhos.

TABELA III

Número de vizinhos selecionados para os classificadores baseados em kNN .

| | | | | | | | | | |
|---------------------|----------|----------|----------|----------|----------|----------|----------|--|--|
| Direta: | | 4 | | | | | | | |
| Hierárquica: | | 11 | | | | | | | |
| - Estágio 1: | | | | | | | | | |
| - Estágio 2: | | | | | | | | | |
| A | B | C | D | E | F | G | H | | |
| 8 | 2 | 3 | 3 | 5 | 3 | 5 | 12 | | |

Os valores das medianas de cada TA_i para os ensaios realizados são apresentados nas Figuras 7 e 8. Neste caso, a topologia direta se destaca na classificação de 3 navios (B5, C3, e E4), enquanto a topologia hierárquica lidera na classificação de 9 navios (D3, D4, F2, F3, F4, G2, H1, H2, e H5). Para os 16 navios restantes, o desempenho de ambas é equivalente. Cabe ressaltar que o enfoque hierárquico obtém um desempenho nitidamente superior para todos os navios da classe H.

C. Comparação das acurácias médias

Na Figura 9 é exibido o diagrama de caixas dos valores de TA para as seguintes combinações de algoritmo e topologia: RF-DI, kNN -DI, RF-HI, e kNN -HI. Considerando o teste de Friedman [8], é possível afirmar que os métodos possuem um desempenho distinto ($\chi^2(3) = 287,1, p < 0,001$). A maior mediana corresponde ao kNN -HI (95,6%), cujo desempenho é estatisticamente superior aos demais ($p < 0,0002$), segundo o teste *post-hoc* de Tukey [8]. Ademais, o desempenho do kNN é claramente superior ao RF em ambos os casos (direto e hierárquico). Contrariamente ao esperado, a hierarquização não se mostrou atrativa para a técnica RF. Tal fato pode estar

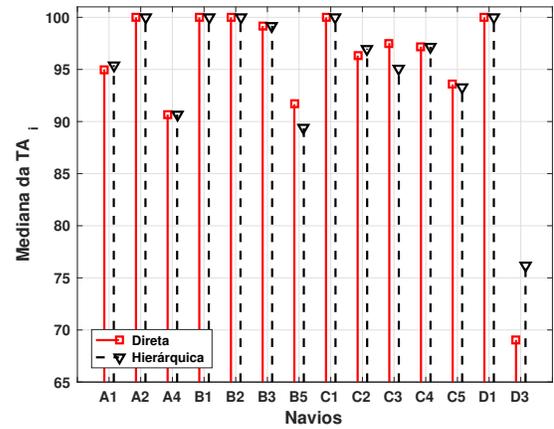


Fig. 7. Mediana da eficiência de cada topologia na classificação dos navios (A1-D3) ao utilizar o kNN .

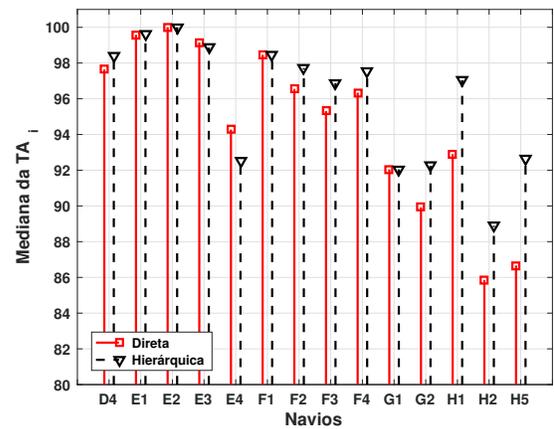


Fig. 8. Mediana da eficiência de cada topologia na classificação dos navios (D4-H5) ao utilizar o kNN .

associado à aleatoriedade intrínseca dos subespaços explorados para a classificação por este algoritmo, cabendo uma investigação profunda deste aspecto em trabalhos futuros.

Em relação à literatura, obteve-se uma acurácia média de acertos de navios de 95,6%, valor superior aos 91,4% reportados para a técnica de Curvas Principais por Limites Heurísticos [3].

VIII. CONCLUSÃO

Este trabalho propôs um sistema de classificação hierárquica de navios. Para a sua construção, o algoritmo kNN se mostrou bastante eficaz, levando a ganhos sensíveis na classificação de navios da classe H, e resultando numa acurácia média relativa a classificação de navios de 95,6%, valor superior ao obtido em trabalhos anteriores.

Como trabalhos futuros, espera-se explorar outros classificadores base em ambos níveis desta hierarquia, entre eles o *Support-Vector Machine* (SVM), as redes neurais do tipo MLP

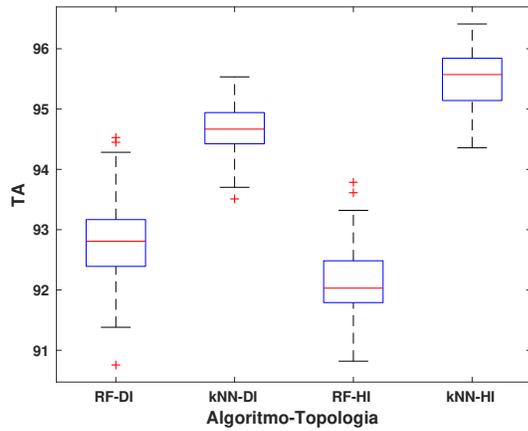


Fig. 9. Diagrama de caixas da acurácia média para as diferentes combinações de algoritmos e topologias.

e *Radial Basis Function* (RBF), bem como avaliar mecanismos de seleção de instâncias para a redução do custo computacional do algoritmo k NN.

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] 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.
- [2] 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.
- [3] T. S. P. Fernandes, J. B. O. Souza Filho, and E. S. Alves, “Identificação de navios em sinais de sonar passivo por curvas principais,” in *XII Congresso Brasileiro de Inteligência Computacional*, (Curitiba, Brasil), 2015.
- [4] K. P. Murphy, *Machine learning: a probabilistic perspective*. MIT press, 2012.
- [5] T. A. Babu and P. R. Kumar, “Characterization and classification of uterine magnetomyography signals using knn classifier,” in *Conference on Signal Processing And Communication Engineering Systems (SPACES)*, (Vijayawada, India), pp. 163–166, 2018.
- [6] Qing Song, Xiaoou Liu, and Lu Yang, “The random forest classifier applied in droplet fingerprint recognition,” in *12th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD)*, (Zhangjiajie, China), pp. 722–726, 2015.
- [7] R. G. Devi and P. Sumanjani, “Improved classification techniques by combining knn and random forest with naive bayesian classifier,” in *2015 IEEE International Conference on Engineering and Technology (ICETECH)*, (Coimbatore, India), pp. 1–4, 2015.
- [8] N. Japkowicz and M. Shah, *Evaluating Learning Algorithms: A Classification Perspective*. Cambridge University Press, 2011.
- [9] 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.