

Classificação de Sons de Navios por Aprendizado de Máquina na Acústica Submarina

Marco André Desbrousses Cotta

Centro de Guerra Acústica e Eletrônica da Marinha (CGAEM), Niterói /RJ – Brasil

Resumo — Este trabalho apresenta um sistema de classificação automática de sons de navios em ambientes submarinos utilizando redes neurais convolucionais (*Convolutional Neural Networks – CNN*). A metodologia baseia-se na coleta de sinais acústicos passivos, extração de características espectrais como LOFAR e DEMON, e posterior treinamento de modelos de *deep learning* para reconhecimento de padrões. O objetivo é identificar embarcações específicas por suas assinaturas acústicas, mesmo em ambientes complexos e com ruído de fundo. A proposta foi testada com bases de dados reais, obtendo resultados promissores quanto à acurácia e aplicabilidade operacional. Observou-se, por exemplo, índice de acerto médio de 92% para fragatas, 88% para corvetas, 95% para submarinos e 85% para navios de apoio logístico. Por fim, discute-se a viabilidade de integração do sistema a modelos de propagação acústica, como o TRACEO, para aprimorar a detecção e localização. Perspectivas futuras incluem o uso de arquiteturas híbridas e implementação embarcada em plataformas navais.

Palavras-Chave — Classificação Acústica Submarina, Redes Neurais Convolucionais e *Machine Learning*.

I. INTRODUÇÃO

No Brasil, o Centro de Guerra Acústica e Eletrônica da Marinha (CGAEM) é detentor da biblioteca acústica submarina de gravações de assinaturas acústicas de navios, a qual serve de base para o desenvolvimento e validação de metodologias de classificação automática.

A detecção e classificação de embarcações através de sons subaquáticos são práticas amplamente utilizadas por sistemas de vigilância acústica passiva. Com o avanço da tecnologia de aprendizado de máquina, tornou-se possível automatizar o processo de identificação a partir de grandes bancos de dados de sons gravados, aumentando a precisão e reduzindo o tempo de resposta das operações navais [1]. Os sons gerados por navios, como os de cavitação de hélices, motores e sistemas auxiliares, formam uma assinatura acústica única. A comparação desses padrões com dados previamente armazenados permite a inferência do tipo de embarcação, sua propulsão e até seu estado operacional [2].

II. REDES NEURAS CONVOLUCIONAIS (CNN)

As CNN são eficazes na classificação de sons transformados em representações visuais, como espectrogramas apresentado na Fig.1. Inspirada no córtex visual de mamíferos, a arquitetura é estruturada em camadas convolucionais seguidas por funções de ativação, operações de *pooling* para redução de dimensionalidade e camadas densas para a etapa de classificação [3].

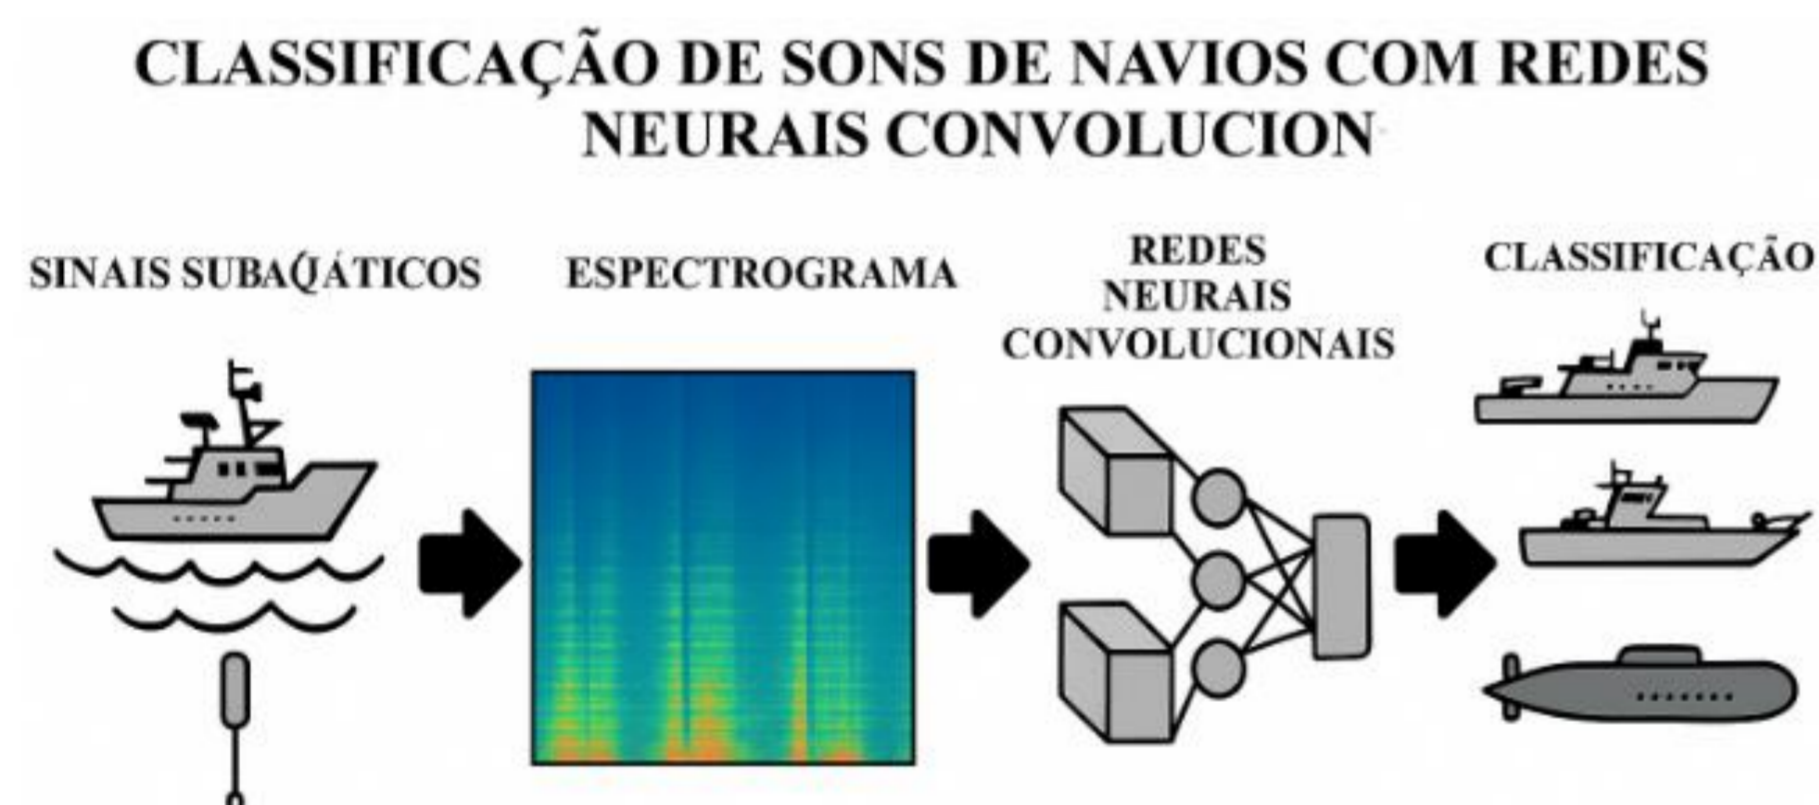


Fig. 1. Fluxo de Processamento Acústico com CNNs para Classificação de Navios.

Na classificação de sons de navios, as CNN são utilizadas por sua eficácia na análise de espectrogramas. Um componente essencial é a função de ativação ReLU (*Rectified Linear Unit*), que acelera o treinamento e reduz o risco de gradientes desaparecendo em redes profundas [4].

A operação fundamental das CNN é a convolução entre um filtro (*kernel*) e a matriz de entrada com apresentado na Fig.2:

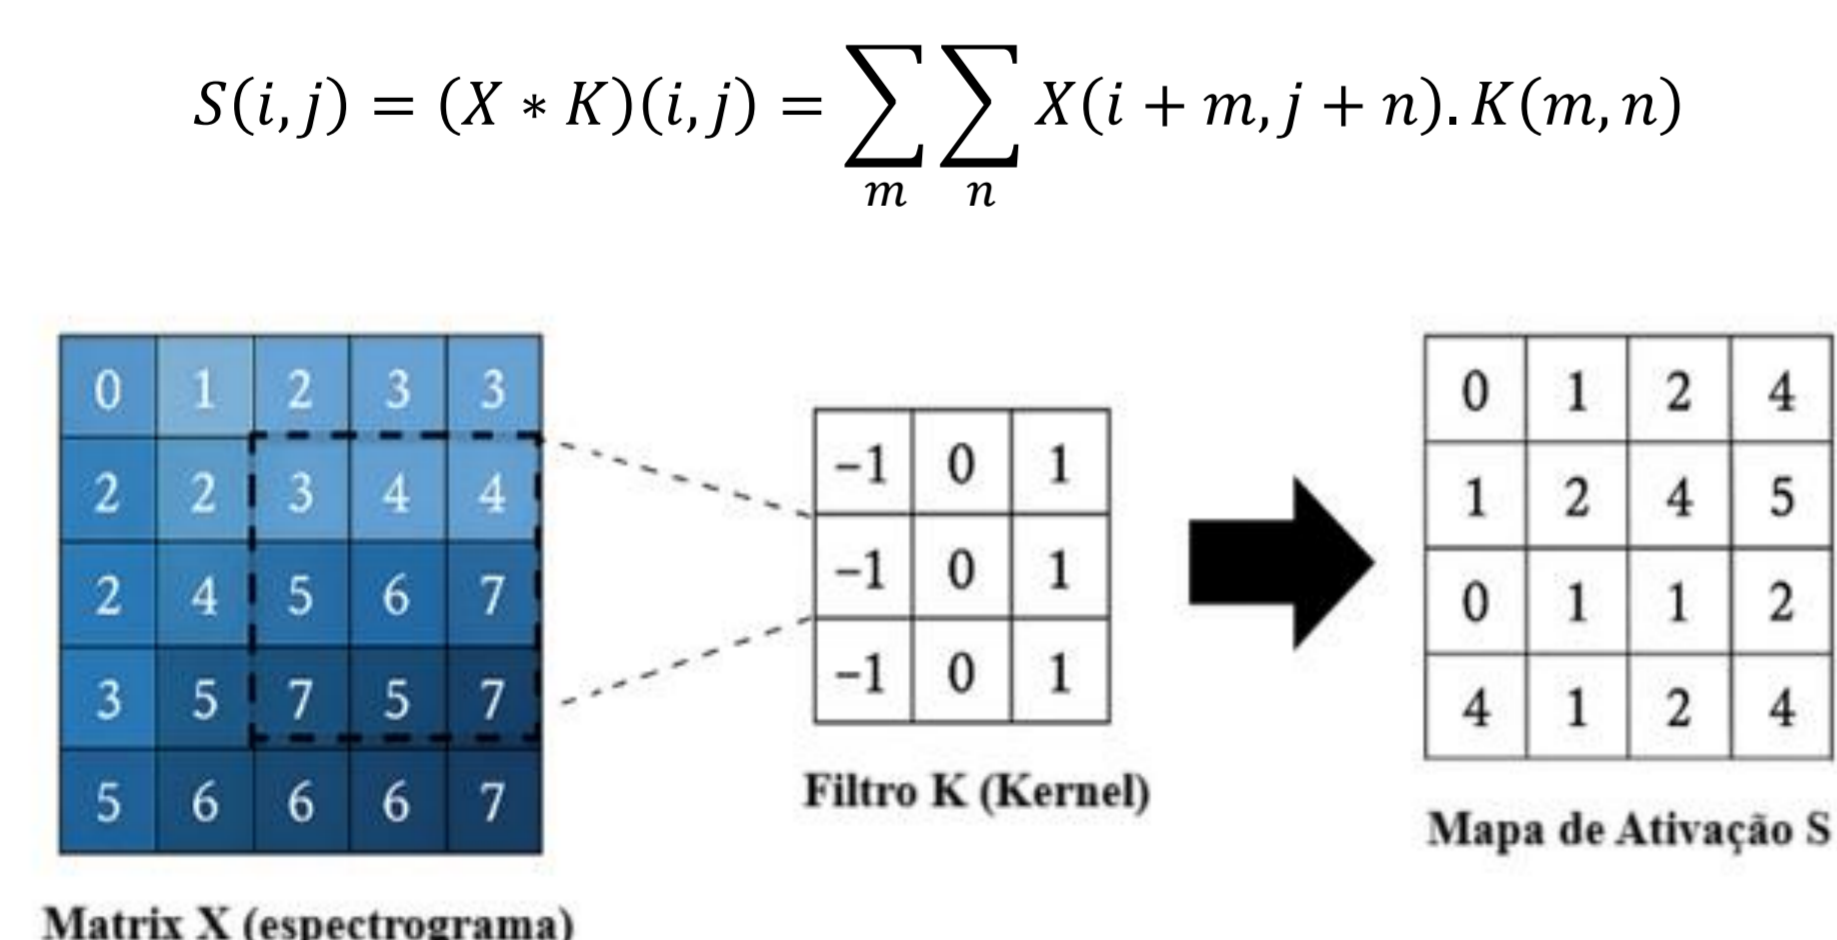


Fig. 2. Esquema da operação de convolução em uma Rede Neural Convolucional.

III. AVALIAÇÃO E MÉTRICAS DE DESEMPENHO

A acurácia, precisão, recall, F1-score e a matriz de confusão são métricas amplamente utilizadas para avaliar o desempenho de modelos de classificação. Em cenários com classes desbalanceadas, técnicas como reamostragem (*oversampling* ou *undersampling*) e penalização de erros (*class weighting*) são aplicadas para mitigar o viés do modelo em relação à classe majoritária. Além disso, a curva ROC (*Receiver Operating Characteristic*) e a métrica AUC (*Area Under the Curve*) são empregadas para medir a capacidade discriminativa do classificador em diferentes limiares de decisão, sendo úteis mesmo quando há desequilíbrio entre as classes [5].

Diversas arquiteturas de redes convolucionais foram testadas em tarefas de classificação submarina. Modelos como LeNet-5, VGG16 e ResNet-18 foram adaptados para trabalhar com imagens espectrais geradas a partir de sinais submarinos [3]. A escolha da arquitetura impacta diretamente a complexidade computacional e o desempenho final. ResNet, por exemplo, utiliza conexões residuais que facilitam o treinamento de redes profundas, enquanto MobileNet oferece uma alternativa leve para aplicações em dispositivos embarcados com poder computacional restrito.

IV. RESULTADOS DE CLASSIFICAÇÃO

O sistema foi avaliado utilizando dados reais de diferentes tipos de navios em condições operacionais variadas. Foram considerados fragatas, corvetas, submarinos e navios de apoio, com múltiplas gravações por embarcação em diferentes tipos de regimes de operação e condições ambientais.

TABELA I. RESULTADO DE ACURÁCIA DE CLASSIFICAÇÃO PARA DIFERENTES NAVIOS

Tipo de Navio	Acurácia (%)	Precisão (%)	Recall (%)	F1-score (%)
Fragatas	92	91	93	92
Corvetas	88	86	89	87
Submarinos	95	96	94	95
Navios de Apoio	85	84	86	85

Os resultados indicaram alta acurácia na classificação das diferentes classes de navios. As fragatas apresentaram 92% de acerto, com assinaturas acústicas consistentes, embora sujeitas a pequenas variações por velocidade e condições ambientais. As corvetas obtiveram 88% de acurácia, refletindo maior variabilidade de cavitação e sobreposição com navios de apoio, com F1-score de 87%, evidenciando equilíbrio entre precisão e recall. Os submarinos tiveram o melhor desempenho, com 95% de acerto, destacando a eficácia do modelo em identificar assinaturas discretas e tonais. Já os navios de apoio alcançaram 85% de acurácia, resultado impactado pela diversidade de ruídos gerados por múltiplos sistemas auxiliares.

V. COMPARAÇÃO ENTRE ARQUITETURAS CNN

Na comparação entre arquiteturas, a LeNet-5 obteve 88% de acurácia, com limitações na extração de características profundas, especialmente em navios de apoio. A VGG16 alcançou 91%, destacando-se na identificação de fragatas e submarinos, porém com maior custo computacional. Já a ResNet-18 apresentou o melhor desempenho, com 93% de acurácia, beneficiada pelas conexões residuais que possibilitam o treinamento de redes mais profundas sem degradação do gradiente.

VI. CURVAS ROC E AUC

Para cada classe, foram geradas curvas ROC (*Receiver Operating Characteristic*) e calculadas as áreas sob a curva (*Area Under the Curve - AUC*), conforme Fig. 3:

- ✓ Submarinos: AUC = 0,97
- ✓ Fragatas: AUC = 0,94
- ✓ Corvetas: AUC = 0,91
- ✓ Navios de Apoio: AUC = 0,89

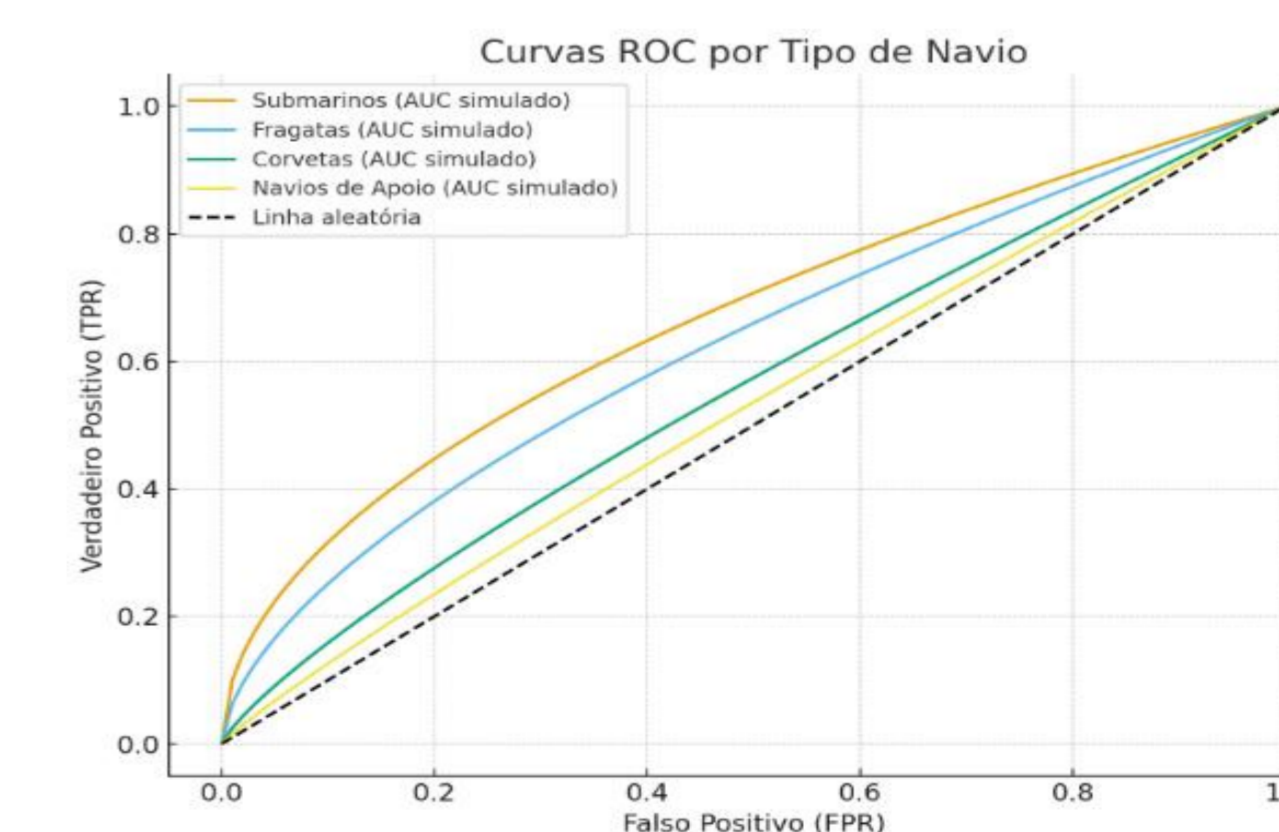


Fig. 3. Curva ROC por tipos de navios.

VII. CONCLUSÃO

Os resultados indicam que a combinação de múltiplas representações espectrais (LOFAR, DEMON, MFCC), associada a arquiteturas profundas como ResNet-18 e técnicas de data augmentation, proporciona elevada acurácia e capacidade de generalização. Esses resultados demonstram a aplicabilidade prática do sistema em operações reais, permitindo classificação confiável de diferentes tipos de navios e integração com sistemas de comando e controle em tempo real.

REFERÊNCIAS

- BENGIO, Y.; COURVILLE, A.; VINCENT, P. A. Rectified Linear Units Improve Restricted Boltzmann Machines. *ICML*, 2010.
- COWAN, J. P. *The Physics of Sound in Marine Environments*. Melville, NY: ASA Press, 2003.
- LI, X.; ZHANG, C.; WANG, H. An Improved Convolutional Neural Network for Underwater Acoustic Target Classification. *IEEE Access*, 7:96550–96557, 2019.
- NAIR, V.; HINTON, G. E. Rectified Linear Units Improve Restricted Boltzmann Machines. *ICML*, 2010.
- HUANG, J. et al. Ship Classification Using Deep Learning of Passive Sonar Signals. *Sensors*, 19(24):5526, 2019.
- PEDREGOSA, F. et al. *Scikit-learn: Machine Learning in Python*. *J. Mach. Learn. Res.*, 12:2825–2830, 2011.