

CLASSIFICAÇÃO DE IMAGENS DE CRUSTÁCEOS USANDO APRENDIZADO DE MÁQUINA E APRENDIZADO PROFUNDO, COM ÊNFASE NA SUPERORDEM PERACARIDA (MALACOSTRACA: CRUSTACEA)

M. L. de F. DUDA*, L. de S. CABRAL#

Campus Jaboatão dos Guararapes - Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco (IFPE)

ORCID ID: <https://orcid.org/0000-0002-8903-7656>*, <http://orcid.org/0000-0002-4235-5753>#

marialuiza.duda.sci@gmail.com*, luciano.cabral@jaboatao.ifpe.edu.br#

Submetido 23/10/2024 - Aceito 16/05/2025

DOI: 10.15628/holos.2025.17940

RESUMO

Este estudo investiga o uso de Inteligência Artificial na classificação de espécimes da Superordem Peracarida, avaliando a eficácia de diferentes modelos para a identificação desse grupo. Dada a escassez de pesquisas sobre crustáceos, foi realizada uma revisão sistemática sobre o uso de IA na classificação de plâncton. Dois experimentos foram conduzidos: o primeiro comparou Redes Neurais Profundas (DNN), Redes Neurais Convolucionais (CNN) e uma rede neural similar a Máquinas de Vetores de Suporte (SVM) para a classificação de imagens de nove ordens de crustáceos, com a CNN apresentando a maior acurácia (82,8%) devido

à sua capacidade de extrair padrões visuais complexos. No segundo experimento, a CNN foi aplicada exclusivamente à Superordem Peracarida, alcançando uma acurácia de 63,69%, evidenciando a dificuldade de distinção entre as ordens devido à alta similaridade morfológica. Os resultados indicam que, apesar da CNN ser o modelo mais eficaz para classificação geral de crustáceos, a identificação de Peracarida ainda representa um desafio. Este estudo pioneiro contribui para o aprimoramento das técnicas de reconhecimento de imagem aplicadas à taxonomia marinha.

PALAVRAS-CHAVE: Reconhecimento de imagens, Redes Neurais, Biologia Computacional, Amphipoda, Cumacea.

CLASSIFICATION OF CRUSTACEAN IMAGES USING MACHINE AND DEEP LEARNING, WITH EMPHASIS ON THE SUPERORDER PERACARIDA (MALACOSTRACA: CRUSTACEA)

ABSTRACT

This study investigates the use of Artificial Intelligence for classifying specimens of the Superorder Peracarida, evaluating the effectiveness of different models for identifying this group. Given the scarcity of research on crustaceans, a systematic review was conducted on the use of AI in plankton classification. Two experiments were conducted: the first compared Deep Neural Networks (DNN), Convolutional Neural Networks (CNN), and a neural network similar to Support Vector Machines (SVM) for classifying images of nine crustacean orders, with CNN achieving the highest accuracy (82.8%) due to its ability to

extract complex visual patterns. In the second experiment, CNN was applied exclusively to the classification of Peracarida images, achieving an accuracy of 63.69%, highlighting the difficulty in distinguishing between orders due to high morphological similarity. The results indicate that while CNN proved to be the most effective model for general crustacean classification, identifying Peracarida remains a challenge. This pioneering study contributes to the advancement of image recognition techniques applied to marine taxonomy.

KEYWORDS: Image recognition, Neural Networks, Computational Biology, Amphipoda, Cumacea.

1 INTRODUÇÃO

O Subfilo “*Crustacea*” é um grupo taxonômico muito diverso morfológicamente e com representantes marinhos, estuarinos, dulcícolas e até mesmo, terrestres (Dunn et al., 2014). Os crustáceos são conhecidos por possuírem 2 pares de antenas, sendo esses apêndices articulados unirremes ou birremes, corpo com 6 segmentos e larvas *nauplius* (Martin & Davis, 2001).

A Superordem “*Peracarida Calman*”, 1904, inserida na Classe “*Malacostraca*”, é conhecida por possuir representantes com céfalo fundido em 1 ou 2 segmentos torácicos, abdômen com seis segmentos e telson (último segmento do corpo) (Brusca; Moore; Shuster, 2018). As ordens de peracáridos são: “*Amphipoda*, *Bochusacea*, *Cumacea*, *Ingolfiellida*, *Isopoda*, *Lophogastrida*, *Mictacea*, *Mysida*, *Stygiomysida*, *Tanaidacea*” e “*Thermosbaenacea*” (Arai, 2024). O tamanho desses organismos pode variar de acordo com o ambiente em que vivem. Representantes como os cumáceos, por exemplo, podem medir de 1 a 30 milímetros, sendo necessário, métodos específicos de coleta e identificação taxonômica, isto é, a classificação em táxons menores até atingir o nível de espécie, o nível mais específico da Taxonomia Biológica.

As ordens “*Amphipoda*, *Cumacea*, *Isopoda*, *Mysida*” e “*Tanaidacea*”, mostradas na Figura 1, foram escolhidas para o segundo experimento por serem os grupos com a maior quantidade de espécies descritas atualmente (WoRMS, 2025).

Comumente os trabalhos científicos de *Peracarida* explanam a dificuldade de estudar o grupo, seja pela quantidade de estudos disponíveis sobre o tema ou pela difícil metodologia de armazenamento dos exemplares após a coleta (Brito & Serejo, 2020).



Figura 1: Principais ordens da Superordem *Peracarida*. Fonte: (WoRMS, 2025)

Legenda: A. Ordem *Amphipoda*; B. Ordem *Cumacea*; C. Ordem *Mysida*; D. Ordem *Isopoda*; E. Ordem *Tanaidacea*.

A Inteligência Artificial já é muito utilizada na área da Biologia Marinha, seja para análise de dados como para identificação de padrões em imagens (Song *et al.*, 2023). Entretanto, existe um *gap* teórico sobre a utilização de Inteligência Artificial aplicada a taxonomia de crustáceos (ver seção 2).

Alguns exemplos utilizados em grandes corporações, possuem fundamentos na classificação de imagens como: autorização de colaboradores a um serviço ou sistema por meio do reconhecimento facial (Taigman *et al.*, 2014); diagnóstico médico para cânceres metastáticos com a ajuda da classificação de imagens (Jiao *et al.*, 2020); sistemas de monitoramento de segurança que identificam objetos em imagens em tempo real (Ren *et al.*, 2017); monitoramento de danos ambientais como desmatamento, poluição e queimadas (Ronneberger; Fischer; Brox, 2015). Todas essas aplicações possuem um objetivo em comum: realizar uma classificação de forma precisa e rápida a fim de extrair informações relevantes e tomar decisões ou obter *insights*.

Para classificar imagens, a Inteligência Artificial se relaciona com as redes neurais no contexto da identificação de padrões em imagens e posteriormente classificação das mesmas. As redes neurais visam replicar o funcionamento do cérebro humano para processar informações e tomar decisões, para isso possuem três tipos principais de camadas: Camada de entrada, camadas ocultas e camada de saída (Figura 2). Essas camadas são responsáveis por processar e transformar os dados de entrada para obter resultados desejados (Nielsen, 2015).




Figura 2. Esquema de camadas de uma rede neural. Fonte: (Megaputer, 2019).

A “*input layer*” (camada de entrada) é a primeira camada da rede neural e recebe os dados de entrada que podem ser os “*pixels*” de uma imagem, os atributos de um conjunto de dados ou qualquer outra informação que esteja sendo utilizada para realizar a classificação ou previsão. Cada nó corresponde a uma característica dos dados de entrada. Já as “*hidden layers*” (camadas ocultas) são chamadas dessa forma porque os valores dos nós não são diretamente observáveis, diferente dos valores de entrada e saída. As camadas ocultas são responsáveis por realizar cálculos para transformar os dados de entrada em uma forma que possa ser usada para fazer previsões ou classificações.

Em uma Rede Neural Convolutacional (CNN) a visão computacional é comumente utilizada, e por isso as camadas ocultas consistem em camadas de “*pooling*” totalmente conectadas. Nessas camadas, serão aplicados filtros para extrair características relevantes das imagens de entrada, reduzindo a dimensionalidade das características extraídas e tornando o processamento mais eficiente. E as camadas totalmente conectadas são responsáveis por combinar as características extraídas das camadas anteriores para fazer a classificação final.

A “*output layer*” (camada de saída) é a última camada da rede neural e fornece os resultados finais da rede, nela geralmente estão os nós correspondentes às classes ou categorias que a rede está tentando prever ou classificar. Através do processo de treinamento os pesos das conexões entre as unidades em cada camada são ajustados para otimizar o desempenho da rede na tarefa específica com a classificação de imagens do grupo “*Peracarida*”, por exemplo.

Um experimento que permita classificar imagens de “*Peracarida*” pode contribuir para o aumento da disponibilidade de imagens em acesso aberto na internet, já que muitos pesquisadores tiram fotos dos organismos coletados. Essas fotos poderão ser utilizadas no script de treinamento e predição de imagens desenvolvido nos experimentos. A disponibilização dessas imagens como dados abertos pode não apenas apoiar pesquisas sobre o grupo, mas também ampliar o conhecimento da Superordem “*Peracarida*” pela comunidade em geral.

Diante disto, foi formulada a seguinte pergunta de pesquisa: **Qual o modelo de rede neural ideal para classificação de imagens da Superordem “Peracarida”?** Sendo este, o objetivo geral deste trabalho, mensurar a eficácia da classificação de imagens do grupo “Peracarida”.

Para aprofundar os conhecimentos na área da Inteligência Artificial aplicada a classificação de imagens de crustáceos foi realizada uma Revisão Sistemática da Literatura. Em seguida, foi desenvolvida uma pesquisa aplicada, com uso do método experimental para os procedimentos. Este trabalho é pioneiro em estudos de classificação de imagens de crustáceos da Superordem “Peracarida”.

2 REVISÃO DA LITERATURA

Ignacio Heredia (2017) realizou uma pesquisa com o objetivo de classificar imagens de organismos planctônicos marinhos, utilizando um algoritmo previamente desenvolvido para a classificação de plantas (Heredia, 2017).

O algoritmo desenvolvido para a classificação de organismos planctônicos aplicou o código que resolvia um problema da falta de um monitoramento em larga escala da flora, para uma classe de problemas mais restrita, a do zooplâncton marinho. Os resultados de acurácia obtidos para cada agrupamento de classes (cada grupo com 5 classes) foram de 99,77% a 85,79% com imagens de peixes, moluscos, crustáceos, detritos, fibras e outros artefatos que foram coletados juntamente com os organismos. A rede neural utilizada foi a *ResNet-50*, uma rede neural residual com 50 camadas diferentes, sendo um tipo de arquitetura encontrada na *CNN*. Dentre as 50 camadas convolucionais estão incluídas as camadas de *pooling* e camadas totalmente conectadas. A arquitetura inclui blocos residuais que são repetidos várias vezes para formar a estrutura da rede.

A aplicação da Inteligência Artificial já foi preconizada por uma pesquisa realizada por Sadaippan et al. em 2021 com copépodes onde foram identificadas unidades taxonômicas operacionais bacterianas que foram dominantes em espécies dos gêneros *Calanus* e *Pleuromamma*. O *Gradient Boosting Classifier* (GBC) apresentou melhores resultados que o *Random Forest Classifier* (RFC). O modelo *RFC* obteve uma precisão geral de 0,923, com uma proporção de precisão de 1,68. O modelo *GBC* apresentou uma precisão de previsão de 0,967, com uma proporção de precisão de 1,76. A precisão na previsão das OTUs importantes em *Calanus spp.* e *Pleuromamma spp.* foi de 1,00 para ambos os modelos (Sadaippan et al., 2021). Diferente da pesquisa desenvolvida por Céspedes Sisniega (2018), esta não utilizou redes neurais, mas sim algoritmos de aprendizado de máquina.

2.1 Revisão Sistemática de Literatura

A revisão sistemática foi conduzida entre dezembro de 2022 e janeiro de 2023, e os resultados foram buscados em 27 de janeiro de 2023. Seguindo as diretrizes de Nakagawa (2017) e Wohlin et al., (2020), a revisão seguiu os seguintes passos: identificar a necessidade da revisão, especificar uma pergunta de pesquisa, desenvolver e avaliar um protocolo de revisão, conduzir a revisão com base no protocolo e analisar os resultados.

Durante a etapa de planejamento, é necessário considerar a pergunta de pesquisa, a seleção de fontes e estudos. Durante a execução, estudos são selecionados, avaliados e revisados, bem como a extração de informações. A análise dos resultados pode ser qualitativa, quantitativa ou mista. Diversas técnicas são aplicadas nesta fase, como análise bibliométrica, por exemplo. Neste artigo, a bibliometria foi realizada para visualizar quantitativamente as informações extraídas da revisão sistemática, com o objetivo de informar futuros projetos de pesquisa.

Para desenvolver a pergunta de pesquisa, foram definidos os seguintes parâmetros para o planejamento da revisão sistemática: População, algoritmos de análise de imagem com aprendizado profundo; Intervenção, modelos de redes neurais usados para treinar e analisar imagens; Comparação, comparar o nível de precisão dos modelos usados nos artigos; Resultado, identificar os modelos de redes neurais com o maior nível de precisão na análise de imagens. A pergunta formulada foi: **“Qual modelo de rede neural é mais eficaz para treinar e analisar imagens de organismos planctônicos?”**

2.1.1 Critérios de seleção de fontes

Foram escolhidos dois bancos de dados bibliográficos para iniciar a revisão sistemática. O banco de dados *IEEE* é amplamente reconhecido no campo da tecnologia e inclui mais de 300 revistas, por exemplo. O Scopus é um banco de dados frequentemente usado para buscar artigos nas ciências naturais, escolhido para esta revisão sistemática devido à sua quantidade considerável de dados.

2.1.2 Idioma dos estudos

Os termos de busca foram definidos em inglês para ampliar os resultados, já que é a língua predominante na maioria das publicações científicas.

2.1.3 Identificação de fontes, métodos e strings de busca

Para obter os resultados necessários, uma cadeia de busca foi desenvolvida para ser utilizada nos bancos de dados *IEEE* e *Scopus* por meio de busca manual na web. Como o tema principal da pesquisa é "Inteligência Artificial" e especificamente "Reconhecimento de Imagem", essas foram as duas primeiras palavras escolhidas para compor a cadeia de busca. No entanto, a combinação dessas duas palavras resultou em resultados muito amplos, sendo necessário focar no objeto de estudo biológico, os crustáceos da ordem *Cumacea*.

Tabela 1. Análise comparativa dos resultados obtidos nos bancos de dados IEEE e Scopus

String de Busca	Bases Bibliográficas	Total de resultados	Resultados obtidos no contexto
("Full Text & Metadata":cumacea) AND ("Full Text Only":artificial intelligence) AND ("Full Text Only":image recognition)	IEEE	1	1
ALL (cumacea) AND TITLE-ABS-KEY (artificial AND intelligence) AND TITLE-ABS-KEY (image AND recognition)	Scopus	0	0

("Full Text & Metadata":crustacea) AND ("Full Text Only":artificial intelligence) AND ("Full Text Only": image recognition)	IEEE	1	0
ALL (crustacea) AND TITLE-ABS-KEY (artificial AND intelligence) AND TITLE-ABS-KEY (image AND recognition)	Scopus	2	1
("Full Text & Metadata":plankton) AND ("Full Text Only":artificial intelligence) AND ("Full Text Only": image recognition)	IEEE	72	10
ALL (plankton) AND TITLE-ABS-KEY (artificial AND intelligence) AND TITLE-ABS-KEY (image AND recognition)	Scopus	24	10

Fonte: Elaborado pela Autora (2023)

A escolha do operador “AND” a ser utilizado entre as três palavras de busca e a grafia das palavras em inglês foram fatores escolhidos para obter uma gama mais ampla de resultados. A primeira palavra relacionada ao grupo biológico foi buscada com o índice mais abrangente para garantir que mais resultados pudessem ser encontrados. As outras duas palavras relacionadas ao tema de Inteligência Artificial foram buscadas com um filtro restrito ao título, resumo e/ou palavras-chave do artigo para garantir que os resultados obtidos fossem mais próximos da população esperada de artigos.

Inicialmente, a primeira palavra-chave na sequência de busca continha a palavra “Cumacea” na tentativa de obter artigos mais específicos sobre uma ordem taxonômica particular de crustáceos, a fim de direcionar a revisão sistemática da literatura para a análise de imagens de um grupo específico. No entanto, poucos resultados foram obtidos, então o segundo teste foi realizado com a palavra “Crustacea” na tentativa de obter resultados mais abrangentes sobre o grupo de interesse.

Finalmente, o último teste foi realizado com a palavra “Plankton”, o que resultou em mais artigos, uma vez que abrange vários grupos, incluindo a ordem Cumacea, o grupo de interesse que justifica o desenvolvimento desta revisão sistemática da literatura. Usando essa palavra-chave, foi possível obter resultados de artigos sobre o reconhecimento de imagens de fitoplâncton (algas microscópicas), o que também pode ser relevante porque as redes neurais usadas em alguns estudos são as mesmas para ambos os tipos de organismos, sejam algas ou animais (Céspedes Sisniega, 2018). Usando a palavra-chave “Plankton”, foram obtidos 72 resultados no banco de dados da IEEE e 24 resultados no banco de dados do Scopus, com 8 e 10 resultados dentro do contexto da pesquisa, respectivamente. Para a revisão sistemática, foram considerados artigos obtidos tanto no banco de dados da IEEE quanto no do Scopus, a fim de garantir uma análise abrangente dos resultados.

2.1.4 Critério de seleção dos artigos obtidos

Para garantir a relevância e a qualidade dos estudos incluídos na revisão sistemática, foram adotados os seguintes critérios de seleção: (i) apenas artigos revisados por pares, publicados em revistas científicas ou conferências; (ii) estudos disponíveis em acesso aberto para garantir a reprodutibilidade da pesquisa; (iii) publicações escritas exclusivamente em inglês, devido à predominância desse idioma na literatura científica; (iv) artigos cujo título, resumo e/ou palavras-

chave estivessem diretamente relacionados ao contexto da pesquisa; e (v) estudos experimentais ou empíricos, excluindo revisões sistemáticas da literatura. Esses critérios asseguraram a inclusão de estudos alinhados ao objetivo do trabalho, que é deep learning aplicado ao plâncton ou pequenos crustáceos.

Os artigos obtidos dentro do contexto de pesquisa e que não atenderam a esses critérios estão listados no apêndice deste artigo para justificar o motivo da não inclusão.

2.1.5 Resultados qualitativos da Revisão Sistemática de Literatura

A sequência de busca escolhida utilizou as seguintes palavras-chave: “*Plankton*”, “*Artificial Intelligence*” e “*Image Recognition*”. Foi realizada uma análise comparativa sobre a usabilidade das plataformas e a disponibilidade de artigos, como mostrado na Tabela 2.

Tabela 2. Análise comparativa dos resultados obtidos nos bancos de dados da IEEE e do Scopus

Base bibliográfica	Resultados no contexto	Acesso aberto	Usabilidade da Plataforma de busca	Outros idiomas além do Inglês
IEEE	8	7	Interface amigável, busca simplificada, exportação automatizada para .csv e em formato .zip.	1
Scopus	10	6	Interface amigável, busca simplificada, exportação automatizada para .csv, BibTex, RIS, HTML, RefWorks e em formato .zip.	1

Fonte: Elaborado pela autora (2023)

Para a seleção primária dos estudos obtidos nas bases de dados *IEEE* e *Scopus*, foi adotada uma abordagem qualitativa de seleção, onde os critérios da Tabela 3 foram utilizados para a avaliação.

Tabela 3. Critérios para avaliação qualitativa dos artigos obtidos

CrITÉrios	Peso
Existe uma declaração clara dos objetivos da pesquisa?	1
A pesquisa analisa imagens de organismos planctônicos?	2
A documentação dos métodos de pesquisa é adequada?	1
Foi documentado o modelo de rede neural mais adequado para a pesquisa?	2
Os resultados são relatados de forma clara?	1
O artigo cita referências com objetivos semelhantes?	1
Os resultados adicionam valor ao campo de pesquisa?	1
A pesquisa aborda especificamente a identificação de cumáceos por meio do reconhecimento de imagens?	1

Fonte: Elaborado pela autora (2023)

Para determinar quais artigos seriam discutidos, o título, resumo e resultados obtidos foram analisados, seguindo essa ordem para excluir artigos que não estão alinhados com o tema da pesquisa (Dyba; Dingsøyr; Hanssen, 2007). O número de artigos dentro do contexto da pesquisa é refletido na segunda coluna da Tabela 2, ou seja, foram considerados estudos sobre a identificação de organismos planctônicos por meio de treinamento e reconhecimento de imagens.

Com base nos critérios de avaliação e nos pesos atribuídos, os artigos selecionados foram pontuados conforme a tabela 4.

Tabela 4. Pontuação dos artigos analisados

Autores	Pontuação	Breve descrição
Li et al., 2022	9/10	Desenvolvimento de sistema de imagem subaquática para monitoramento de mesoplâncton.
Yang et al., 2021	9/10	Avaliação de foco em imagens de plâncton usando gradiente de borda e CNN.
Bergum et al., 2020	9/10	Segmentação de plâncton in situ com Mask R-CNN, melhorando a análise ecológica.
Apostol et al., 2016	9/10	Sistema RaDSS para classificação de radiolários via SVM.
Leow et al., 2015	9/10	Identificação automatizada de copépodes com Rede Neural DNN.
Bi et al., 2015	9/10	Uso de SVM na análise de plâncton, contribuindo para estudos sobre redes neurais.

Luo et al., 2004	9/10	Seleção de imagens com SVM para análise de plâncton.
Setiawan et al., 2021	7/10	Sistema especialista para identificação de algas nocivas com 73,33% de precisão.
Lai et al., 2016	7/10	Estudo sobre lentes para captura de imagens de plâncton, ligado à citometria.
Li et al., 2020	7/10	Revisão das principais redes neurais para identificação de plâncton.
Sun et al., 2022	7/10	Processamento de imagens para melhorar a qualidade visual de ambientes marinhos.

Fonte: Elaborado pela autora (2023)

Foram analisados 16 artigos obtidos por meio da revisão nas bases de dados da Scopus e IEEE. Todos estão sendo discutidos nesta seção. Entre os 16 artigos, três não analisaram imagens de organismos planctônicos e outros dois não foram publicados no idioma inglês, e portanto foram excluídos da revisão.

Essas pontuações refletem a qualidade geral e a adequação de cada artigo aos objetivos da pesquisa. Luo et al. (2004), Bi et al. (2015), Leow et al. (2015), Bergum et al. (2020), Apostol et al. (2016), Li et al. (2022) e Yang et al. (2021) obtiveram as pontuações mais altas de 9 pontos, indicando que abordaram de forma abrangente os objetivos da pesquisa, analisaram organismos planctônicos, documentaram adequadamente os métodos de pesquisa, relataram resultados claros, citaram referências relevantes, acrescentaram valor ao campo de pesquisa e abordaram especificamente a identificação de organismos planctônicos por meio do reconhecimento de imagens.

Por outro lado, Lai et al. (2016), Li et al. (2020), Sun et al. (2022) e Setiawan et al. (2021) receberam pontuações de 7 pontos. Embora esses artigos tenham atendido a vários critérios de avaliação, eles podem ter apresentado limitações em determinados aspectos, como não analisar organismos planctônicos (Sun et al., 2022) ou não possuir um modelo adequado de rede neural (Lai et al., 2016) (Li et al., 2020). Setiawan et al. (2021) apresentou um método inovador, mas sua precisão de 73,33% pode indicar limitações no uso para monitoramento automatizado em larga escala.

É importante observar que essas pontuações são relativas e baseadas nos critérios de avaliação especificados e nos pesos atribuídos a cada pergunta. Elas servem como uma medida quantitativa para comparar os artigos selecionados e identificar seus pontos fortes e fracos em relação aos objetivos da pesquisa.

O artigo publicado por Luo et al. em 2004 teve como objetivo desenvolver uma nova estratégia para seleção de imagens usando Máquinas de Vetores de Suporte ou “*Support Vector Machines*” (SVM) para treinamento e redução de dados. Além de SVM ser eficaz para conjuntos de dados menores, foi feita uma comparação com a rede neural “*Cascade Correlation*”, que é mais eficiente tanto para conjuntos de dados grandes quanto pequenos (Luo et al., 2004). Dez anos depois, o artigo publicado por Bi et al. em 2015 também utilizou SVM para análise de organismos

planctônicos, contribuindo para uma melhor compreensão desse tipo de rede neural na identificação de plâncton (Bi et al., 2015).

A publicação de Leow et al. em 2015 concentrou-se em um grupo específico de organismos, os copépodes, que têm uma distribuição ampla (Leow et al., 2015). O principal objetivo foi automatizar técnicas de identificação de copépodes até o nível das espécies usando técnicas de processamento de imagens. Neste trabalho, apenas uma rede neural artificial, que os autores chamaram de “ANN (*Artificial Neural Network*)”, entretanto, analisando as informações contidas no artigo, tais como a arquitetura da rede é “*feed-forward*” com duas camadas (entrada e densa) com função de ativação sigmóide (dez nós em cada camada) e uma camada de saída (oito nós) com função de ativação softmax, a rede foi treinada com retropropagação de gradiente conjugado escalonado usando 143 épocas, ou seja, na realidade foi utilizada uma rede neural multicamada ou “*Multi Layer Perceptron*” (MLP) ou rede neural densa (DNN).

Seguindo essa linha de identificação automatizada, o estudo de Apostol et al. (2016) apresentou o RaDSS, um sistema baseado em SVM para classificar espécies de radiolários em microfotografias. Ele detalha a extração de características das imagens e o treinamento do modelo para identificação automatizada, agilizando a classificação desses organismos. Já Bergum; Saad; Stahl (2020) focou na segmentação de plâncton in situ utilizando Mask R-CNN, melhorando a precisão da análise ecológica ao superar métodos tradicionais de segmentação.

No campo da identificação automatizada de organismos nocivos, Setiawan et al. (2021) propôs um sistema especialista assistido por ontologia para a identificação de algas causadoras de blooms prejudiciais. O sistema utilizou fatores de certeza e um banco de conhecimento baseado em características morfológicas, alcançando uma precisão de 73,33%. Esse método se mostrou uma alternativa útil para identificação rápida e monitoramento precoce desses organismos.

O desenvolvimento de sistemas para captura e monitoramento in situ de plâncton foi abordado em diferentes estudos. Li et al. (2022) descreveu a criação de um sistema de imagem subaquática acoplado a uma boia, combinando iluminação otimizada, processamento de imagens a bordo e aprendizado profundo para análise automática. Os testes mostraram que o sistema melhora a precisão e a eficiência do monitoramento de plâncton em longo prazo.

A qualidade das imagens obtidas para identificação também foi tema de pesquisas. Yang et al. (2021) apresentou métodos para avaliação de foco em imagens in situ de plâncton marinho obtidas com iluminação em campo escuro. Dois algoritmos foram propostos: um baseado em estatísticas de gradiente de borda e outro em CNNs, equilibrando eficiência computacional e precisão. Lai et al. (2016), por sua vez, exploraram a química das lentes utilizadas para capturar imagens de plâncton, contribuindo para a melhoria da qualidade das imagens obtidas. Sun et al. (2022) propôs um novo método de processamento de imagens voltado para melhorar a qualidade visual dos ambientes onde os organismos planctônicos são encontrados, o que pode auxiliar na obtenção de imagens mais precisas para análise.

Entre os artigos analisados, os principais objetivos observados foram: identificação de organismos planctônicos por meio da análise de imagens, automação do processo de treinamento de imagens e melhoria da qualidade das imagens analisadas. O volume de artigos referenciados que

compartilham o mesmo foco de pesquisa sugere que esse campo está passando por um número crescente de estudos, apresentando uma excelente oportunidade para estudar as metodologias já empregadas e desenvolver novos métodos de treinamento e processamento de imagens, incluindo colaboração com pesquisadores que já estão estudando o tema. Nenhum dos artigos analisou imagens de cumáceos, o que apresenta uma oportunidade para desenvolver o primeiro estudo focado exclusivamente nessa ordem na literatura, integrando Taxonomia e Inteligência Artificial aplicada a esse grupo. Portanto, foi constatado o gap teórico, que confere o caráter pioneiro da pesquisa.

3 METODOLOGIA

A pesquisa aplicada enfatiza o desenvolvimento de soluções práticas. Nesse sentido, ela se adequa ao objetivo de mensurar a eficácia da classificação de imagens de *Peracarida*, uma vez que consiste em avaliar a precisão e o desempenho dos modelos de aprendizagem de máquina. O método de procedimento escolhido foi do tipo experimental, sendo amplamente utilizado na ciência para investigar fenômenos, testar hipóteses e obter resultados confiáveis e replicáveis. No caso específico da classificação de crustáceos peracáridos, o método experimental foi escolhido devido à sua capacidade de fornecer dados precisos e sistemáticos, permitindo uma análise objetiva.

Tomando como base as aplicações da Inteligência Artificial nas Ciências Biológicas, foram propostos dois experimentos, um para treinar e validar imagens do “*Crustacea, ZooScan Image Database*” e outro para treinar e validar imagens de um *dataset* específico para a superordem Peracarida. O objetivo do primeiro experimento é comparar os modelos de *DNN* e algoritmos de *SVM* obtidos na Revisão Sistemática de Literatura, e também modelos de *CNN* eficientes para classificação de imagens (Krizhevsky, Sutskever and Hinton, 2012). Já o objetivo do segundo experimento é a partir do primeiro proposto, de utilizar o modelo *CNN* para treinar um novo banco de imagens de crustáceos peracáridos com imagens retiradas da internet por um *web crawler*, autorais e fornecidas por pesquisadores especialistas nas ordens *Amphipoda*, *Cumacea*, *Isopoda*, *Mysida* e *Tanaidacea*. Como foram feitos dois experimentos, o primeiro será referido por Classificação de Microcrustáceos e o segundo por Classificação de Peracarida.

3.1 Materiais

Abaixo estão listadas as ferramentas utilizadas para desenvolver os scripts de treinamento de imagens.

3.1.1 Linguagem de programação, frameworks e bibliotecas de aprendizado de máquina e processamento de imagens:

- *Python*: Linguagem com sintaxe limpa acompanhada de várias bibliotecas nativas e de terceiros.
- *Tensor Flow: Framework* de código aberto utilizado para desenvolver e treinar modelos de redes neurais.

- *Keras*: Biblioteca de alto nível para construir e treinar redes neurais, que utiliza o *Tensor Flow* como *backend*.
- *OpenCV*: Biblioteca utilizada para o pré-processamento das imagens, ajustando propriedades como altura, largura e canais.
- *Scikit-learn*: Biblioteca de aprendizado de máquina em *Python* que fornece ferramentas para treinamento e avaliação de modelos, incluindo métricas de precisão.

3.1.2 Definições, Componentes e técnicas:

- *Adam*: Otimizador utilizado para compilar os modelos de redes neurais.
- *Categorical cross entropy*: Função de perda utilizada para medir a diferença entre as probabilidades preditas e as classes reais das imagens.
- *Flatten layer*: Camada de achatamento que transforma a imagem em um vetor unidimensional.
- *Dense layer*: Camada densa que mapeia as características da imagem para a classificação.
- *Convolutional Neural Network (CNN)*: Modelo de rede neural especializado no processamento de imagens.
- *Deep Neural Network (DNN)*: Modelo de rede neural artificial com várias camadas de neurônios interconectados.
- *Support Vector Machine (SVM)*: Algoritmo de aprendizado supervisionado usado para classificação e regressão.
- *train_test_split*: Função do scikit-learn utilizada para separar as imagens em conjuntos de treinamento e validação.
- *Dropout*: Camada que desativa aleatoriamente alguns neurônios durante o treinamento, com o objetivo de evitar o overfitting e melhorar a regularização do modelo.
- *MaxPooling2D*: Camada de pooling utilizada para reduzir a dimensionalidade dos mapas de características.

3.1.3 Métricas de avaliação e representação visual:

- *Acurácia*: Métrica utilizada para avaliar o desempenho dos modelos.
- *Precisão*: Métrica que mede a proporção de exemplos classificados corretamente como positivos em relação ao total de exemplos classificados como positivos.
- *Recall*: Métrica que mede a proporção de exemplos classificados corretamente como positivos em relação ao total de exemplos que deveriam ter sido classificados como positivos.
- *F1-score*: Métrica que fornece uma medida combinada de precisão e *recall*, levando em consideração tanto os falsos positivos quanto os falsos negativos.
- *Matriz de confusão*: Representação visual do desempenho do modelo em termos de imagens classificadas corretamente e incorretamente para cada classe.

3.2 Métodos

3.2.1 Classificação de crustáceos

3.2.1.1 Conjunto de dados

O conjunto de dados originalmente extraído do *Kaggle*¹ (Du Toit, 2015) incluía 24 classes, representando gêneros, famílias e ordens de crustáceos. Para atender ao objetivo deste estudo, que era treinar imagens de crustáceos, incluindo a ordem *Cumacea*, todos os gêneros e famílias presentes no conjunto de dados foram agrupados em suas respectivas ordens, resultando em nove classes: *Calanoida*, *Calyptopsis*, *Cladocera*, *Cumacea*, *Cyclopoida*, *Decapoda*, *Harpacticoida*, *Mysida* e *Ostracoda*. As imagens foram obtidas de um *ZooScan*, que é um dispositivo para escanear amostras biológicas que utiliza uma câmera para capturar imagens de alta resolução e posteriormente produzir imagens tridimensionais dessas amostras.

Para a ordem *Cumacea*, foram utilizadas fotos originais tiradas pela autora do artigo usando um estereomicroscópio, bem como imagens obtidas de vários bancos de dados, como *Wikispecies*², *BioDiversity4All*³, *Smithsonian Museum*⁴, *Aphotomarine*⁵, *Alchetron*⁶ e *Pinterest*⁷. No entanto, foram encontradas apenas 87 imagens de *Cumacea*, destacando a dificuldade de encontrar bancos de dados de imagens para a ordem *Cumacea*, mas também para crustáceos em geral. Por outro lado, as demais ordens possuem números consideráveis de imagens para treinamento, como *Calanoida* com 10.352 imagens, *Calyptopsis* com 1.505 imagens, *Cladocera* com 162 imagens, *Cyclopoida* com 493 imagens, *Decapoda* com 51 imagens, *Harpacticoida* com 917 imagens, *Mysida* com 179 imagens e *Ostracoda* com 6.241 imagens.

Neste estudo, as classes no diretório de treinamento e validação também são categorizadas por ordem taxonômica, refletindo sua hierarquia de nomenclatura biológica.

3.2.1.2 Script de Treinamento de imagens

O experimento de classificação de imagens de crustáceos utilizou três técnicas distintas: **DNN** (Rede Neural Profunda), **CNN** (Rede Neural Convolucional) e Rede Neural com arquitetura inspirada no **SVM** (Máquina de Vetores de Suporte). A escolha desses modelos foi baseada em sua eficácia demonstrada em trabalhos relacionados, onde mostraram resultados promissores em tarefas similares. As **DNNs** são eficazes para aprender representações complexas, as **CNNs** destacam-se em tarefas de visão computacional, e as **SVMs** são robustas em cenários com dados

¹ <https://www.kaggle.com/datasets/iandutoit/crustacea-zooscan-image-database>

² <https://species.wikimedia.org/wiki/Cumacea>

³ https://www.biodiversity4all.org/observations?place_id=any&subview=map&taxon_id=144115

⁴ <https://collections.nmnh.si.edu/search/iz/>

⁵ <https://www.aphotomarine.com/cumacea.html>

⁶ <https://alchetron.com/Cumacea>

⁷ <https://br.pinterest.com/>

menores. O treinamento foi realizado com **TensorFlow** e **Keras**, ferramentas amplamente utilizadas para redes neurais.

O modelo *SVM* é um algoritmo de aprendizado supervisionado usado para classificação e regressão. Para esse experimento, o algoritmo foi o inspirador para o desenvolvimento de uma rede neural com uma *flatten layer* (camada de achatamento), que transforma a imagem em um vetor unidimensional, e uma *dense layer* (camada densa), que é responsável por mapear as características da imagem para a classificação (Demir and Erturk, 2009). O *SVM* é compilado através da função de perda categorial *cross entropy*, que mede a diferença entre as probabilidades preditas e as classes reais das imagens, juntamente com métricas de precisão do *scikit learn* para avaliar o desempenho do modelo.

O modelo *DNN* é uma rede neural artificial, que consiste em várias camadas de neurônios interconectados (Ahmed; Dey; Sarma, 2011). Neste experimento o modelo *DNN* possui três camadas densas. Além disso, são incorporadas duas camadas de *dropout*, que são responsáveis por desativar aleatoriamente alguns neurônios durante o treinamento, com o objetivo de evitar o *overfitting* e melhorar a regularização do modelo. Assim como o *SVM*, o modelo de *DNN* é compilado com a função de perda *categorical cross entropy* e métricas de precisão.

O modelo *CNN* é um tipo de rede neural especializada no processamento de imagens e por esse motivo é mais complexo possuindo duas camadas convolucionais para extrair características das imagens, duas camadas de *pooling* para reduzir a dimensionalidade dos dados, duas camadas densas para a classificação final e uma camada de *dropout* para regularização (Nielsen, 2015) (Nunes & Dantas, 2021) (Silva, Peixoto & Santos, 2023). Assim como nos modelos anteriores, a *CNN* é compilada com a função de perda *categorical cross entropy* e métricas de precisão.

3.2.2 Classificação da Superordem Peracarida

3.2.2.1 Dataset

Para desenvolver um experimento que classifique especificamente imagens de peracáridos, foi feito um segundo experimento com a criação de um novo *dataset*. As imagens foram obtidas por meio da implementação de um *web crawler* para capturar imagens no site *images.google.com* e também imagens fornecidas por pesquisadores especialistas em Peracarida, com imagens de no máximo 250 x 250 *pixels*. As referências para as imagens incluem as seguintes fontes em ordem alfabética: *Alchetron*, *Aphotomarine*, *BioDiversity4All*, *Canadian Museum of Nature*⁸, *Flickr*⁹, *iNaturalist*¹⁰, *iStock*¹¹, *Idtools*¹², *International Barcode of Life*¹³, *Magnolia Press*¹⁴, *Monterey Bay*

⁸ <https://nature.ca/en/our-science/collections/online-collection-data/>

⁹ <https://www.flickr.com/search/?text=cumacea>

¹⁰ <https://www.inaturalist.org/observations>

¹¹ <https://www.istockphoto.com/br>

¹² <https://idtools.org/>

¹³ <https://ibol.org/>

¹⁴ <https://mapress.com/>

*Aquarium, Pinterest, World Register of Marine Species*¹⁵, *Smithsonian Museum, WikiSpecies, Wikipedia, Wikitionary* e outras bases de dados de imagens gratuitas. Após esse procedimento, obtivemos 5 classes e um total de 895 imagens distribuídas da seguinte forma: Amphipoda com 187 imagens; Cumacea com 308 imagens; Isopoda com 217 imagens; Mysida com 86 imagens; Tanaidacea com 98 imagens.

3.2.2.2 Script de treinamento de imagens

Com base nos resultados obtidos no primeiro experimento, o modelo de rede neural mais eficiente foi escolhido para o treinamento e validação do *dataset* de Peracarida, e usou a função *to_categorical* provisionada pelo *tensorflow.keras.utils*. A configuração do modelo foi realizada usando os hiperparâmetros, escolhidos manualmente: *batch_size* = 16, *input_shape* = (150, 150, 3), *random_state* = 42, *alpha* = 1e-5, *epoch* = 10. O otimizador escolhido foi o *Adam*, com o *learning_rate* = 0.0001. Para a compilação, foi utilizado o *sparse categorical cross entropy* como função de perda, e a métrica de acurácia (*accuracy*) foi usada para avaliar cada época de treinamento. A validação foi realizada em um procedimento semelhante para calcular a acurácia e a perda usando os grupos de treinamento e validação.

O conjunto de dados não tinha um padrão para as imagens, já que foram obtidas de várias fontes diferentes onde o único filtro e requisito foi que houvesse apenas um indivíduo com o corpo inteiro na foto. A falta de padronização pode ter dificultado os resultados do modelo usado. O conjunto de dados de imagens não é fornecido neste artigo, pois algumas das fotos representam novas espécies para a ciência, e que ainda não foram publicadas.

3.2.3 Processamento de imagem

Para ambos os experimentos foram utilizadas duas pastas de imagens para treinamento do modelo: uma para treinamento e outra para validação. A biblioteca *OpenCV* foi utilizada para pré-processar as imagens ajustando propriedades como a altura, largura e canais de cada imagem. O segundo experimento diferenciou no primeiro ao utilizar a função *train_test_split* que pertence a biblioteca do *Python, scikit-learn* e tem a função de separar as imagens por um valor pré-definido, nesse caso 80% para treinamento e 20% para validação de forma aleatória. O primeiro experimento teve uma proporção geral aproximada de 90% para treinamento e 10% para validação.

A escolha das proporções de dados para treinamento e validação depende de fatores como a quantidade de dados e o objetivo do modelo. No primeiro experimento (90%/10%), usou-se 90% para treinamento para maximizar a quantidade de dados disponíveis para o modelo, enquanto 10% foi suficiente para uma avaliação razoável. No segundo experimento (80%/20%), a proporção 80/20 foi escolhida para garantir uma validação mais rigorosa, fornecendo uma avaliação mais precisa do desempenho do modelo. A diferença nas proporções reflete a intenção de equilibrar treinamento e validação, com a escolha sendo influenciada pelo contexto e pela quantidade de dados disponíveis.

¹⁵ <https://www.marinespecies.org/index.php>

3.2.4 Arquitetura dos modelos de redes neurais

Abaixo estão as arquiteturas das redes neurais *DNN*, *CNN* e *SVM* utilizadas no primeiro experimento com a finalidade de comparar e entender qual a melhor rede neural para ser utilizada no segundo experimento.

3.2.4.1 Arquitetura do DNN, CNN e SVM na classificação de crustáceos

3.2.4.1.1 Arquitetura DNN

A criação do modelo de rede neural DNN possui a seguinte arquitetura:

- Camada de achatamento (*Flatten*): Essa camada recebe a entrada com um formato de tensor e a transforma em um vetor unidimensional. No caso desse modelo, a entrada é a imagem com o formato (224, 224, 3).
- Camada densa (*Dense*) com ativação *ReLU*: Essa camada possui 128 unidades e usa a função de ativação *ReLU* (*Rectified Linear Unit*), que introduz não linearidade no modelo. A camada densa é responsável por mapear os recursos extraídos pela camada de achatamento para representações mais abstratas.
- Camada densa (*Dense*) com ativação *softmax*: Essa camada é a camada de saída do modelo e é responsável por mapear as saídas da camada anterior para as classes de destino usando a função de ativação *softmax*. O número de unidades nessa camada é igual ao número de classes do problema (*num_classes*).

Essa arquitetura segue um padrão comum em modelos de redes neurais para classificação de imagens. A camada de achatamento transforma a imagem em um vetor de características, as camadas densas adicionam não linearidade e realizam a classificação final. A função de ativação *ReLU* é amplamente utilizada para introduzir não linearidade e a função de ativação *softmax* é usada para obter as probabilidades de classificação para cada classe.

O modelo *DNN* é compilado com o otimizador *Adam*, a função de perda *categorical_crossentropy* (para problemas de classificação com múltiplas classes) e a métrica de avaliação acurácia (*accuracy*). Em seguida, ele é treinado usando os dados de treinamento (*train_generator*) de acordo com um número específico de épocas.

3.2.4.1.2 Arquitetura CNN

- Camada convolucional (*Conv2D*) com 32 filtros e tamanho de *kernel* 3x3: Essa camada recebe a entrada com o formato (224, 224, 3) representando uma imagem colorida de 224x224 pixels com 3 canais (*RGB*). Ela aplica 32 filtros convolucionais de tamanho 3x3 em cada canal da imagem, produzindo mapas de características.
- Camada de *max pooling* (*MaxPooling2D*) com tamanho de pool 2x2: Essa camada reduz a dimensionalidade dos mapas de características pela metade, mantendo as características mais relevantes. Isso ajuda a reduzir a quantidade de parâmetros e computação necessários no modelo.

- Outra camada convolucional (*Conv2D*) com 64 filtros e tamanho de *kernel* 3x3: Essa camada aplica mais 64 filtros convolucionais de tamanho 3x3 aos mapas de características obtidos na camada anterior, gerando mapas de características mais complexas.
- Outra camada de *max pooling* (*MaxPooling2D*) com tamanho de pool 2x2: Essa camada realiza a redução de dimensionalidade novamente, mantendo as características mais importantes.
- Camada de achatamento (*Flatten*): Essa camada transforma as saídas da camada anterior em um vetor unidimensional, preparando os dados para a entrada em uma rede neural densa.
- Camada densa (*Dense*) com 128 unidades e ativação *ReLU*: Essa camada densamente conectada mapeia as características extraídas da camada anterior para representações mais abstratas. Ela utiliza a função de ativação *ReLU* para introduzir não linearidade no modelo.
- Camada densa (*Dense*) com o número de unidades igual ao número de classes (*num_classes*) e ativação *softmax*: Essa é a “camada de saída” do modelo, que produz as probabilidades de classificação para cada classe. A função de ativação *softmax* é utilizada para garantir que as probabilidades somem 1 e sejam interpretadas como distribuição de probabilidade.

A arquitetura do modelo *CNN* segue o padrão comum de camadas convolucionais seguidas por camadas de max pooling para extrair características relevantes da imagem. Em seguida, as camadas densas são usadas para a classificação final. A função de ativação *ReLU* é aplicada nas camadas convolucionais e densas para introduzir não linearidade. A função de ativação *softmax* é usada na camada de saída para obter as probabilidades de classificação.

O modelo é compilado com o otimizador Adam, a função de perda *categorical_crossentropy* (para problemas de classificação com múltiplas classes) e a métrica de avaliação *accuracy* (acurácia). Em seguida, o modelo é treinado usando os dados de treinamento por um número especificado de épocas.

3.2.4.1.3 Arquitetura inspirada no modelo SVM

A arquitetura descrita, composta por uma camada de achatamento (*Flatten*) seguida de uma camada densa (*Dense*) com ativação *softmax*, foi inspirada no modelo de aprendizagem de máquina denominado Máquinas de Vetores de Suporte ou SVM, que é um classificador linear. O modelo SVM busca encontrar um hiperplano que melhor separe as diferentes classes em um espaço de características, e, de forma análoga, a camada de achatamento transforma a entrada (imagem) em um vetor unidimensional, representando um conjunto de características extraídas da imagem. Em seguida, a camada densa realiza a classificação final com base nessas características, de forma similar ao que o SVM faria ao realizar a separação entre classes no espaço vetorial.

A escolha de uma camada de achatamento seguida de uma camada densa reflete a ideia de mapear as características extraídas da entrada para uma decisão final, como o modelo SVM, que faz a classificação com base em um espaço vetorial linear. A ativação *softmax* na camada densa é usada para fornecer uma probabilidade para cada classe, similar à forma como o SVM gera uma previsão para a classe mais próxima do hiperplano. Embora essa arquitetura não inclua camadas

convolucionais, o princípio de mapeamento das características para a classificação é semelhante ao processo do SVM, tornando essa arquitetura uma adaptação simplificada, mas eficaz, do conceito de separação linear do SVM. O uso do otimizador Adam, da função de perda “*categorical_crossentropy*” e da métrica “*accuracy*” são escolhas comuns em redes neurais para tarefas de classificação multi-classe, complementando o processo de treinamento e avaliação do modelo.

3.2.4.2 Arquitetura de rede neural para classificação de Peracáridos

Para o segundo experimento, voltado para peracáridos, foi escolhida a rede neural com o melhor desempenho, isto é, a melhor acurácia obtida durante o primeiro experimento. A arquitetura utilizada também foi a mesma, porém foi necessária uma avaliação das camadas, já que o objetivo do segundo experimento é mais específico e receberá imagens de várias fontes, diferente do primeiro cenário que trabalhou apenas com fotografias tiradas por uma *Zooscan*.

4 EXPERIMENTOS, RESULTADOS E DISCUSSÃO

Para avaliar o desempenho dos modelos, matrizes de confusão foram geradas usando a biblioteca *Scikit-learn*¹⁶. As matrizes de confusão forneceram uma representação visual do desempenho do modelo em termos de imagens classificadas corretamente e incorretamente para cada classe. Essa análise ajudou a identificar quais classes eram mais desafiadoras para os modelos distinguir e determinar áreas para melhoria no processo de treinamento. Visando avaliar ainda mais o desempenho dos modelos, várias métricas foram calculadas, incluindo precisão, *recall* e pontuação *F1*. A métrica de precisão mede o desempenho geral do modelo em termos de imagens classificadas corretamente, enquanto a métrica de *recall* mede a proporção de classificações verdadeiras positivas entre todas as classificações positivas.

A métrica de *recall*, também conhecida como sensibilidade ou taxa de verdadeiros positivos, mede a proporção de classificações verdadeiras positivas entre todas as instâncias positivas reais. Por fim, a pontuação *F1* é a média harmônica da precisão e do *recall* e fornece uma medida da precisão geral do modelo, levando em consideração tanto os falsos positivos quanto os falsos negativos. Essas métricas foram calculadas para cada modelo e cada classe para fornecer uma avaliação abrangente do desempenho do modelo.

4.1 Avaliação de resultados e comparação entre redes neurais sobre a classificação de imagens de crustáceos

As principais diferenças entre as arquiteturas *DNN*, *CNN* e *SVM* são:

- Arquitetura *DNN*: Não utiliza camadas convolucionais, apenas camadas densas para a extração de características e classificação. A função de ativação *ReLU* é usada nas camadas densas.

¹⁶ <https://scikit-learn.org/stable/index.html>

- Arquitetura *CNN*: Utiliza camadas convolucionais para extrair características relevantes da imagem. Além disso, possui camadas de max pooling para reduzir a dimensionalidade dos mapas de características. A função de ativação *ReLU* é aplicada nas camadas convolucionais e densas.
- Arquitetura inspirada no *SVM*: Não utiliza camadas convolucionais, apenas camadas densas para a extração de características e classificação. Utiliza a função de ativação *softmax* na camada de saída para obter as probabilidades de classificação. É um classificador linear que busca encontrar um hiperplano que melhor separa as classes.

Essas diferenças na arquitetura influenciam o desempenho e a capacidade de generalização de cada modelo. As camadas convolucionais da arquitetura *CNN* permitem a extração automática de características relevantes das imagens, enquanto as camadas densas realizam a classificação final com base nessas características. Por isso, a arquitetura *CNN* é mais adequada para tarefas de visão computacional, onde as características espaciais das imagens são importantes.

Tabela 3. Comparação das três redes neurais, *DNN*, *CNN* e *SVM*.

Características de redes neurais	Arquitetura <i>DNN</i>	Arquitetura <i>CNN</i>	Arquitetura inspirada no <i>SVM</i>
Camada de achatamento (<i>Flatten</i>)	Transforma a entrada em um vetor unidimensional	Transforma a saída da camada anterior em um vetor unidimensional	Transforma a entrada em um vetor unidimensional
Camada densa (<i>Dense</i>)	128 unidades, ativação ReLU	128 unidades, ativação ReLU	Ativação softmax, número de unidades = <i>num_classes</i>
Camada de saída	Ativação softmax, <i>num_classes</i> unidades	Ativação softmax, <i>num_classes</i> unidades	Ativação softmax, <i>num_classes</i> unidades
Função de ativação	ReLU	<i>ReLU</i>	<i>Softmax</i>
Uso de camadas convolucionais	Não	Sim	Não

Fonte: Elaborado pela autora (2023)

Os resultados obtidos a partir do script desenvolvido, mostram que o modelo de rede neural *CNN* teve a melhor precisão geral no procedimento de treinamento, com 82,8%, seguido pelo *SVM* com 72,8% e *DNN* com 71,7%, (Figura 3).




Figura 3. Comparação entre os valores de acurácia por rede neural. Fonte: Elaborado pela autora (2023)

A *CNN* também teve a maior precisão para as ordens *Calyptopsis*, *Cyclopoida*, *Harpacticoida* e *Mysida*, enquanto o *SVM* teve a maior precisão para a ordem *Ostracoda*. A *DNN* teve a maior precisão para a ordem *Calanoida*. A ordem *Cumacea* teve a mesma taxa de precisão para os modelos *SVM* e *CNN*, (Figura 4). As ordens *Cladocera* e *Decapoda* não obtiveram uma taxa significativa de precisão em nenhum dos modelos de rede neural e foram omitidas da Figura 4.




Figura 4. Comparação entre os valores de acurácia por classes e redes neurais. Fonte: Elaborado pela autora (2023)

O desbalanceamento no número de imagens por classe pode impactar significativamente os resultados do modelo, pois quanto mais imagens uma classe contiver, mais exemplos o modelo terá para aprender as características específicas dessa classe. Isso pode levar a um desempenho superior para as classes com mais imagens, como observado por Deng (2009). Além disso, é importante ressaltar que o desbalanceamento de classes também pode afetar o desempenho do modelo, com classes com menos dados apresentando resultados menos precisos. Para mitigar esses efeitos, foram adotadas estratégias como oversampling manual nas classes minoritárias, entretanto, por se

tratar de imagens coletadas em microscópio específico, não se conseguiu número relevante de amostras adicionadas. No entanto, outros fatores também influenciam o desempenho do modelo, como a qualidade e diversidade das imagens em cada classe, a complexidade da tarefa de classificação, e a escolha do modelo e dos hiperparâmetros. A discussão sobre o desbalanceamento e suas implicações foi incluída no trabalho para contextualizar os resultados e justificar as possíveis limitações.

Esses resultados sugerem que o algoritmo *CNN* é o mais adequado para a tarefa de classificação usada neste estudo. No entanto, é importante observar que outras métricas de avaliação, além da acurácia, podem ser usadas para comparar o desempenho dos algoritmos, como as taxas de Precisão, *Recall* e *F1-score*. A Precisão é a proporção de exemplos classificados corretamente como positivos em relação ao número total de exemplos classificados como positivos. O Recall é a proporção de exemplos classificados corretamente como positivos em relação ao número total de exemplos que deveriam ter sido classificados como positivos. O *F1-score* é uma média harmônica da Precisão e do *Recall* e é usado para avaliar a precisão geral do modelo.

A Tabela 4 mostra que algumas classes (como *Calanoida* e *Ostracoda*) apresentam um desempenho razoável, com valores de Precisão, *Recall* e *F1-score* acima de 0,3, enquanto outras classes (como *Calyptopsis*, *Cladocera* e *Cyclopoida*) têm um desempenho muito fraco, com valores de Precisão, *Recall* e *F1-score* próximos de zero.

Tabela 4. Resultados da matriz de confusão

Class	Precision	Recall	F1
Calanoida	0.590	0.572	0.580
Calyptopsis	0.000	0.062	0.010
Cladocera	0.000	0.000	0.000
Cumacea	0.022	0.022	0.012
Cyclopoida	0.000	0.016	0.000
Decapoda	0.000	0.000	0.000
Harpacticoida	0.000	0.042	0.000
Mysida	0.000	0.037	0.000
Ostracoda	0.395	0.329	0.362

Fonte: A autora (2023)

Na tabela 4 podemos observar que a Ordem *Calanoida* possui uma precisão de 0.590, o que indica que 59% dos exemplos classificados como *Calanoida* foram corretos. O *recall* para essa classe é de 0.572, o que significa que 57.2% dos exemplos foram corretamente identificados. O *F1-score* é de 0.580, fornecendo uma medida combinada do desempenho da classe. No entanto, outras classes como *Calyptopsis*, *Cladocera*, *Cyclopoida*, *Decapoda*, *Harpacticoida* e *Mysida* têm valores de precisão, recall e *F1-score* muito baixos ou iguais a zero, indicando um desempenho fraco do modelo para essas classes. Por outro lado, a classe *Ostracoda* possui uma precisão de 0.395, *recall* de 0.329 e *F1-score* de 0.362, indicando um desempenho moderado para essa classe.

Esses resultados são importantes para avaliar a capacidade do modelo em classificar corretamente as diferentes classes e identificar as classes com melhor e pior desempenho.

4.2 Avaliação dos resultados da classificação de imagens de Peracarida

4.2.1 Adaptações na arquitetura da rede neural CNN do primeiro experimento

Para o segundo experimento foi utilizada a mesma arquitetura da rede *CNN* com a adição de uma camada. A diferença principal entre as duas arquiteturas de *CNN* é a presença da camada de dropout na segunda arquitetura (arquitetura 2). Essa camada de dropout descarta aleatoriamente 50% das ativações da camada anterior durante o treinamento, o que ajuda a evitar o overfitting ao reduzir a dependência de neurônios específicos.

Essa diferença pode influenciar nos resultados de cada arquitetura. Para o primeiro experimento, que trabalhou com crustáceos em geral, não há a camada de dropout, o que pode fazer com que o modelo seja mais suscetível a *overfitting*. O *overfitting* ocorre quando o modelo se ajusta muito bem aos dados de treinamento, mas não generaliza bem para novos dados. Portanto, essa arquitetura pode ter maior tendência a super ajustar os dados de treinamento.

Já a arquitetura voltada para o experimento com a superordem *Peracarida*, a adição da camada de *dropout* ajuda a combater o overfitting. A aleatoriedade na descartada de ativações durante o treinamento faz com que o modelo seja mais robusto e menos dependente de neurônios específicos. Isso pode resultar em um modelo que generaliza melhor para dados não vistos, reduzindo a probabilidade de overfitting e melhorando a capacidade de generalização do modelo.

Portanto, a inclusão da camada de dropout na segunda arquitetura pode fornecer uma regularização adicional ao modelo, tornando-o mais robusto e com melhor capacidade de generalização em comparação com a primeira arquitetura.

4.2.2 Resultado após adaptações na arquitetura da CNN para peracáridos

De acordo com as Figuras 5 e 6, o comportamento do modelo é semelhante ao *overfitting*, onde um bom desempenho com os dados de treinamento é obtido, porém não alcança bons resultados com os dados de validação.

Especificamente, até a época 5, essas características não foram visualizadas, mas depois disso, a diferença entre as linhas de treinamento e teste em ambos os gráficos é crescente.

Abaixo estão os gráficos gerados e também a matriz de confusão na Figura 7.




Figura 5. Acurácia do treinamento e validação. Fonte: Elaborado pela autora (2023)

O modelo se comporta adequadamente com evolução monotonicamente crescente até a época 4-5, utilizar um número maior de épocas, devido ao tamanho do dataset de imagens, pode causar *overfitting*, que pode ser solucionado com adição de mais instâncias ao *dataset*, o que adiciona potencial complexidade ao mesmo, prevenindo *overfit*. O uso de *dropout* também pode prevenir o *overfitting*, uma vez que abandona parte dos caminhos da rede neural que, por ventura, possam influenciar na especialização ao treinamento, ao invés da generalização. Uma última estratégia é o uso do *early stopping*, que consiste na técnica de preferir obter menor acurácia para treinamento e teste, ao invés de deixá-lo continuar e especializar em excesso os dados de treinamento no modelo, o que causaria o *overfitting*.




Figura 6 - Função de perda para o treinamento e validação. Fonte: Compilado pela autora (2023)

O modelo se comporta de forma similar a acurácia na análise dos erros através da função de perda, pois apresenta uma evolução decrescente até a época 4-5. Para esse resultado a utilização de um número maior de épocas, devido ao tamanho do dataset de imagens, pode causar overfitting. Esse comportamento pode ser visto no gráfico da Figura 6 através da diferença da curva de treino para a curva de teste. Observa-se um erro menor na curva de treino a cada época, podendo chegar a zero caso fossem adicionadas mais 4 épocas. Já a curva de erro para os dados de teste é estabilizada na época 5. Fatores de minimização de tal problema já foram explanados no parágrafo anterior.




Figura 7. Matriz de confusão. Fonte: Elaborado pela autora (2023)

As classes 0, 1 e 2, ou seja *Amphipoda*, *Cumacea* e *Isopoda*, respectivamente, foram consideradas adequadas, com ressalva para a classe *Amphipoda*, que teve um alto número de predições como classe 2, ou seja, denotando quase 50% de falsos positivos. O alto número de falsos positivos para a ordem *Amphipoda* pode ser associado a grande similaridade da proporção do tamanho dos segmentos com relação ao corpo. Já as classes 3 e 4, respectivamente *Mysida* e *Tanaidacea*, não apresentaram número suficiente de amostras.

Outras métricas foram calculadas neste experimento, utilizando apenas os dados de teste. Foram calculados os valores de Precisão, *Recall*, *F1* e suporte para cada classe, bem como a média macro e ponderada de todas as classes.

Tabela 5. Métricas por classe

Label	Precision	Recall	F1	Support
Amphipoda	0.76	0.43	0.55	37
Cumacea	0.65	0.95	0.77	62
Isopoda	0.60	0.79	0.68	43
Mysida	0.33	0.06	0.10	17

Tanaidacea	0.57	0.20	0.30	20
accuracy			0.64	179
macro average	0.58	0.49	0.48	179
weighted average	0.62	0.64	0.59	179

Fonte: A autora (2023)

Observa-se na tabela 5 que algumas classes obtiveram resultados melhores do que outras. Por exemplo, a Ordem *Amphipoda* apresentou uma alta precisão (0,65) e *recall* (0,95), indicando um bom desempenho na classificação correta dos exemplos positivos. Por outro lado, a Ordem *Mysida* obteve valores baixos de precisão (0,33) e *recall* (0,06), indicando um desempenho ruim na identificação dos exemplos positivos. Isso se deve a quantidade de imagens no *dataset*, já que os anfípodes possuem 187 e os misídeos 86, sendo a ordem com a menor quantidade de imagens disponíveis para treinamento e validação.

A tabela também apresenta a precisão média macro (*macro average*) e a precisão ponderada (*weighted average*) para todas as classes, que foram 0,58 e 0,62, respectivamente.

A tabela 6 fornece as métricas gerais do experimento, onde a acurácia geral do modelo foi de 0,6369, indicando que ele classificou corretamente aproximadamente 63,69% dos exemplos. A precisão média ponderada foi de 0,6209, indicando uma média ponderada das precisões para todas as classes. O *recall* médio ponderado foi de 0,6369, indicando uma média ponderada dos *recalls* para todas as classes. O F1-score médio ponderado foi de 0,5871, representando uma média ponderada do F1-score para todas as classes. O coeficiente de Kappa de Cohen foi de 0,4937, indicando um nível moderado de concordância além do acaso.

Tabela 6. Métricas gerais do experimento

Métrica	Valor
<i>General accuracy</i>	0.6369
<i>Precision (weighted avg)</i>	0.6209
<i>Recall (weighted avg)</i>	0.6369
<i>F1 (weighted avg)</i>	0.5871
<i>Cohen Kappa</i>	0.4937
<i>Sensitivity</i>	0.7619
<i>Specitivity</i>	1.0000

Fonte: A autora (2023)

A sensibilidade do modelo foi de 0,7619, representando a proporção de exemplos positivos corretamente classificados, e a especificidade foi de 1,0000, representando a proporção de exemplos negativos corretamente classificados.

Visando aplicar o segundo experimento em um sistema distribuído, foi desenvolvido um *Minimum Product Viable (MVP)* chamado *Peracarida Classifier*, que recebe uma imagem de um usuário e faz uma predição da ordem a qual aquela imagem pertence. Foram levantados três containers para cada serviço, um com o script do segundo experimento responsável por fazer a predição da imagem do usuário, outro com o frontend da aplicação que foi desenvolvida em *Next.js*

e o último com o backend utilizando o *RabbitMQ* para fazer a comunicação entre o envio e recebimento das requisições entre os serviços do sistema.

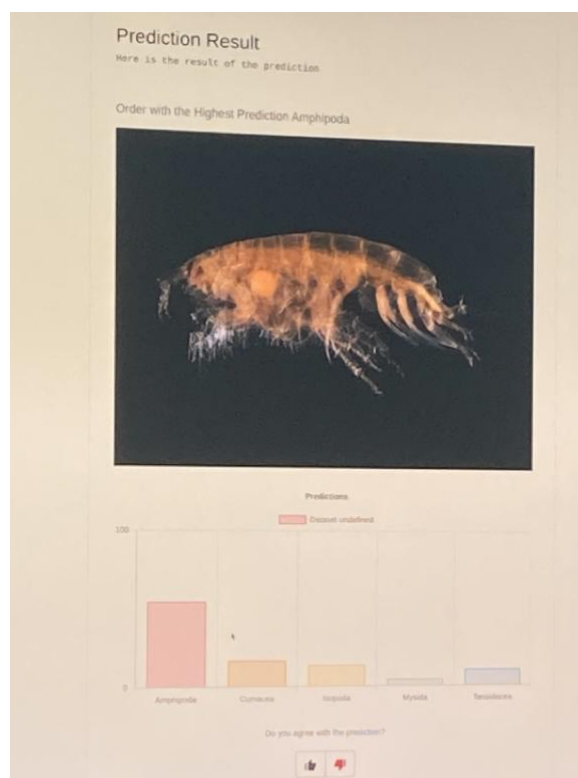


Figura 8 - Tela de resultado da predição. Fonte: Elaborado pela autora (2023)

O resultado é exibido para o usuário com um gráfico que mostra a porcentagem de chance da imagem ser cada uma das ordens treinadas. No exemplo da figura 8 o usuário fez o upload de uma imagem de um anfípode e a predição foi feita corretamente apontando um grande percentual para a ordem Amphipoda.

5 CONSIDERAÇÕES FINAIS

A partir da avaliação do primeiro experimento sobre classificação de crustáceos em geral, os resultados contribuíram para entender que o *CNN* é o melhor modelo para classificar imagens desses organismos. Além de ajudar a embasar estudos futuros, já que foi o primeiro experimento realizado com o objetivo de classificar imagens das ordens de crustáceos já citadas.

Algumas estratégias podem ser utilizadas para melhorar o desempenho geral dos modelos de rede neural, como a utilização de técnicas de aumento de dados para aumentar o número de exemplos nas classes, utilização de *dropout*, *early stopping*, *cross validation* e ainda *active learning*. A falta de um bom computador com *GPU* (*Graphics Processing Unit*) para executar o experimento pode limitar a sintonização de hiper parâmetros e o uso de modelos mais complexos. Outras métricas de avaliação, como *Precisão*, *Recall* e *F1-score*, também devem ser consideradas além da acurácia para avaliar o desempenho geral dos modelos.

Sobre a classificação de imagens de peracáridos, sugerimos para os futuros trabalhos de mesmo objetivo, uma revisão mais detalhada do conjunto de dados, buscando compor as pastas de treinamento e validação com a mesma proporção de quantidade de imagens e com imagens que possuam características variadas (cor de fundo, configuração microscópica, cor e luz frontal, etc.), melhorando a quantidade e normalizando a distribuição, em uma visão simples. Acreditamos que seguindo essas recomendações, será possível melhorar o desempenho do script experimentado e, conseqüentemente, ajudar a aprimorar a classificação de crustáceos microscópicos usando métodos de aprendizado de máquina e deep learning. No geral, este estudo contribui para o desenvolvimento da Inteligência Artificial aplicada à área da Taxonomia biológica, especificamente para a classificação de imagens de microcrustáceos.

Os resultados obtidos aqui podem ser usados como ponto de partida para o desenvolvimento de uma aplicação que permita aos usuários fazer upload de imagens e obter resultados de predição sobre a ordem a qual a imagem pertence. Para este objetivo um MVP já foi desenvolvido (Ver figura 8) e poderá ser replicado ou ainda melhorado em trabalhos futuros. Os experimentos também podem ser utilizados como precursores de estudos que forneçam uma melhor compreensão da diversidade e importância desses organismos para a manutenção do ecossistema marinho por meio da Inteligência Artificial.

● AGRADECIMENTOS

Agradecemos às pesquisadoras: Aurinete Oliveira Negromonte, Catarina de Lourdes Araújo Silva, Débora Lucatelli de Albuquerque, Emanuely Pauliny Modesto dos Santos, Marcele Sabrina dos Santos e Rayanne Gleyce Oliveira dos Santos por fornecerem um número significativo de fotos para o conjunto de dados do segundo experimento. Também agradecemos a participação do estudante do IFPE Campus Jaboatão dos Guararapes, Marcílio Gonçalves, que atuou no desenvolvimento do MVP Peracarida Classifier mencionado nos resultados deste trabalho

● REFERÊNCIAS

- AHMED, S. A.; DEY, S.; SARMA, K. K. (2011). *Image texture classification using Artificial Neural Network (ANN)*. In: National Conference on Emerging Trends and Applications in Computer Science, 2., 2011. doi: 10.1109/ncetacs.2011.5751383. Disponível em: <<https://doi.org/10.1109/ncetacs.2011.5751383>>. Acesso em: 27 jan. 2023.
- APOSTOL, L. A.; MÁRQUEZ, E.; GASMEN, P.; SOLANO, G. (2016). *RadSS: A radiolarian classifier using support vector machines*. 2016 7th International Conference on Information, Intelligence, Systems & Applications (IISA), Chalkidiki, Greece, 2016, pp. 1-6. Disponível em: <<https://doi.org/10.1109/IISA.2016.7785347>>. Acessado em: 20 mar. 2023.
- ARAI, T. I. (2024). *Peracarida in Catálogo Taxonômico da Fauna do Brasil*. PNUD. Disponível em: <http://fauna.jbrj.gov.br/fauna/faunadobrasil/186142>. Acesso em: 20 jan. 2024

- BERGUM, S.; SAAD, A.; STAHL, A. (2020). *Automatic in-situ instance and semantic segmentation of planktonic organisms using Mask R-CNN*. Global Oceans 2020: Singapore – U.S. Gulf Coast, Biloxi, MS, USA, 2020, pp. 1-8. Disponível em: <<https://doi.org/10.1109/IEEECONF38699.2020.9389377>>. Acessado em: 20 mar. 2023.
- BI, H.; GUO, Z.; BENFIELD, M. C.; FAN, C.; FORD, M.; SHAHRESTANI, S.; SIERACKI, J. M. (2015). *A semi-automated image analysis procedure for in situ plankton imaging systems*. PloS one, vol. 10, no. 5, p. e0127121, 2015. Disponível em: <<https://doi.org/10.1371/journal.pone.0127121>>. Acesso em: 12 mar. 2025.
- BRITO, A. D. R.; SEREJO, C. S. (2020). *On the taxonomy of the genus Cyclaspis Sars, 1865 (Crustacea: Cumacea: Bodotriidae) from the Brazilian coast, with three new records and descriptions of three new species*. Marine Biodiversity, v. 50, n. 5, p. 66, 2020. Disponível em: <<https://doi.org/10.1007/s12526-020-01073-9>>. Acesso em: 12 mar. 2025.
- BRUSCA, R. C.; MOORE, W.; SHUSTER, S. E. (2018). *Invertebrados*, 3a edição. Saraiva Academic Press, São Paulo, translated by Guanabara Koogan, Portuguese Edition.
- CÉSPEDES SISNIEGA, J. (2018). *Clasificación de imágenes de especies de zooplankton utilizando Deep Learning*. Master Thesis. 2018. Disponível em: <<http://hdl.handle.net/10902/16300>>. Acesso em: 12 mar. 2025.
- DEMİR, B.; ERTÜRK, S. (2009). *Improving SVM classification accuracy using a hierarchical approach for hyperspectral images*. In: IEEE International Conference on Image Processing (ICIP), 2009, 16., 2009. doi: 10.1109/icip.2009.5414491. Disponível em: <<https://doi.org/10.1109/icip.2009.5414491>>. Acesso em: 12 mar. 2025.
- DENG, J.; DONG, W.; SOCHER, R.; LI, L.-J.; LI, K.; FEI-FEI, L. (2009). *ImageNet: A Large-Scale Hierarchical Image Database*. IEEE Conference on Computer Vision and Pattern Recognition, Miami, FL, pp. 248-255, 2009. Disponível em: <<https://doi.org/10.1109/CVPR.2009.5206848>>. Acesso em: 12 mar. 2025.
- DUNN, C. W.; GIRIBET, G.; EDGECOMBE, G. D.; HEJNOL, A. (2014). *Animal phylogeny and its evolutionary implications*. Annual review of ecology, evolution, and systematics, vol. 45, pp. 371-395, 2014. Disponível em: <<https://doi.org/10.1146/annurev-ecolsys-120213-091627>>. Acesso em: 12 mar. 2025.
- DU TOIT, I. (2015). *Crustacea Zooscan Image Database*. Kaggle, 2015. Disponível em: <<https://www.kaggle.com/datasets/iandutoit/crustacea-zooscan-image-database>>. Acesso em: 12 mar. 2025.
- DYBÅ, T.; DINGSØYR, T.; HANSSEN, G. (2007). *Applying Systematic Reviews to Diverse Study Types: An Experience Report*. Proceedings - 1st International Symposium on Empirical Software Engineering and Measurement, pp. 225-234, ESEM 2007. Disponível em: <<https://doi.org/10.1109/ESEM.2007.59>>. Acesso em: 12 mar. 2025.

- HEREDIA, I. (2017). *Large-scale plant classification with deep neural networks*, in Proceedings of the Computing Frontiers Conference, pp. 259–262, ACM, 2017. Disponível em: <<https://doi.org/10.1145/3075564.307559>>. Acesso em: 12 mar. 2025.
- JIAO, W.; ATWAL, G.; POLAK, P.; KARLIC, R.; Cuppen, E.; PCAWG Tumor Subtypes and Clinical Translation Working Group; DANYI, A.; DE RIDDER, J.; VAN HERPEN, C.; Lolkema, M. P.; Steeghs, N.; Getz, G.; MORRIS, Q. D.; STEIN, L. D.; PCAWG Consortium. (2020). *A deep learning system accurately classifies primary and metastatic cancers using passenger mutation patterns*. Nat Commun, vol. 11, no. 1, p. 728, 2020. Disponível em: <<https://doi.org/10.1038/s41467-019-13825-8>>. Acesso em: 23 jun. 2023.
- WOHLIN, C.; MENDES, E.; FELIZARDO, K. R.; KALINOWSKI, M. (2020). *Guidelines for the search strategy to update systematic literature reviews in software engineering*. Information and Software Technology, vol. 127, 2020, 106366, ISSN 0950-5849. Disponível em: <<https://doi.org/10.1016/j.infsof.2020.106366>>. Acesso em: 12 mar. 2025.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. (2012). *Imagenet classification with deep convolutional neural networks*. Advances in neural information processing systems, pp. 1097-1105, 2012. Disponível em: <<https://doi.org/10.1145/3065386>>. Acesso em: 12 mar. 2025.
- LAI, Q. T. K.; LAU, A. K. S.; TANG, A. H. L.; WONG, K. K. Y.; TSIA, K. K. (2016). *High-throughput time-stretch imaging flow cytometry of phytoplankton*. High-Speed Biomedical Imaging and Spectroscopy: Toward Big Data Instrumentation and Management, SPIE, pp. 137-142, 2016. Disponível em: <<https://doi.org/10.1364/OE.24.028170>>. Acesso em: 12 mar. 2025.
- LEOW, K. Y.; CHONG, V. C.; CHOO, W. H. (2015). *Automated identification of copepods using digital image processing and artificial neural network*. Environmental Science and Pollution Research, vol. 22, no. 18, pp. 14160-14169, 2015. Disponível em: <<https://doi.org/10.1186/1471-2105-16-S18-S4>>. Acesso em: 18 fev. 2023.
- LI, J.; CHEN, T.; YANG, Z.; CHEN, L.; LIU, P.; ZHANG, Y. (2022). *Development of a Buoy-Borne Underwater Imaging System for In Situ Mesoplankton Monitoring of Coastal Waters*. IEEE Journal of Oceanic Engineering, vol. 47, no. 1, pp. 88-110, Jan. 2022, Disponível em: <<https://ieeexplore.ieee.org/document/9580972>>. Acesso em: 20 mar. 2023.
- LI, Q.; SUN, X.; DONG, J.; SONG, S.; ZHANG, T.; LIU, D.; ZHANG, H.; HAN, S. (2020). *Developing a microscopic image dataset in support of intelligent phytoplankton detection using deep learning*. ICES Journal of Marine Science, Volume 77, Issue 4, Pages 1427-1439. Disponível em: <<https://doi.org/10.1093/icesjms/fsz171>>. Acesso em: 20 mar. 2023.
- LUO, T.; KRAMER, K.; GOLGOF, D. B.; HALL, L. O.; SAMSON, S.; REMSEN, A.; HOPKINS, T. (2004). *Recognizing plankton images from the shadow image particle profiling evaluation recorder*. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), vol. 34, no. 4, pp. 1753-1762, 2004. Disponível em: <<https://doi.org/10.1109/TSMCB.2004.830340>>. Acesso em: 12 mar. 2025.

- MARTIN, J. W.; DAVIS, G. E. (2001). *An updated classification of the recent Crustacea*. Science Series, vol. 39, pp. 1-124, 2001. Disponível em: <<https://doi.org/10.1163/20021975-99990355>>. Acesso em: 12 mar. 2025.
- NAKAGAWA, E. Y.; SCANNAVINO, K. R. F.; FABBRI, S. C. P. F.; FERRARI, F. C. (2017). *Revisão Sistemática da Literatura em Engenharia de Software: Teoria e Prática*. Elsevier Brasil, 2017. Disponível em: <<https://repositorio.usp.br/item/002944453>>. Acesso em: 14 jul. 2023.
- NIELSEN, M. (2015). *Neural Networks and Deep Learning: A Textbook*. 2015. Disponível em: <<http://neuralnetworksanddeeplearning.com>>. Acesso em: 20 abr. 2023.
- NUNES, L. dos S., & DANTAS, D. O. (2021). USE OF DEEP LEARNING TO DIAGNOSE COVID-19 BASED ON COMPUTED TOMOGRAPHY IMAGES. HOLOS, 3, 1–13. Disponível em: <<https://doi.org/10.15628/holos.2021.11054>>. Acesso em: 17 maio 2025.
- PEDREGOSA et al. (2011). *Scikit-learn: Machine Learning in Python*. JMLR 12, pp. 2825-2830, 2011.
- RONNEBERGER, R.; FISCHER, P.; BROX, T. (2015). *U-net: Convolutional networks for biomedical image segmentation*. Springer International Publishing, 18th International Conference, Munich, Germany, October 5-9, Part III 18, pp. 234-241, 2015. Disponível em: <<https://doi.org/10.48550/arXiv.1505.04597>>. Acesso em: 16 jul. 2023.
- REN, S.; HE, K.; GIRSHICK, R.; SUN, J. (2017). *Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks*. IEEE Trans. Pattern Anal. Mach. Intell., vol. 39, no. 6, pp. 1137–1149, Junho 2017. Disponível em: <<https://doi.org/10.1109/TPAMI.2016.2577031>>. Acesso em: 15 jun. 2023.
- SADAIAPPAN, B.; PRASANNAKUMAR, C.; NAMBIAR, V. U. et al. (2021). *Meta-analysis cum machine learning approaches address the structure and biogeochemical potential of marine copepod associated bacteriobiomes*. Sci Rep, vol. 11, no. 1, p. 3312, 2021. Disponível em: <<https://doi.org/10.1038/s41598-021-82482-z>>. Acesso em: 11 abr. 2023.
- SETIAWAN, F. A.; PUSPASARI, A.; MANIK, L. P.; AKBAR, Z.; KARTIKA, Y. A. (2021). *Ontology-Assisted Expert System for Algae Identification With Certainty Factors*. in IEEE Access, vol. 9, pp. 147665-147677, 2021. Disponível em: <<https://doi.org/10.1109/ACCESS.2021.3123562>>. Acessado em: 20 mar. 2023.
- SILVA, V. de A., PEIXOTO, M. & SANTOS, F. L. (2023). PREVISÃO DE PRECIPITAÇÃO MENSAL NO MUNICÍPIO DE BARRA MANSA/RJ USANDO TÉCNICAS DE DEEP LEARNING TIME SERIES. HOLOS, 5(39). Disponível em: <<https://doi.org/10.15628/holos.2023.16340>>. Acessado em: 17 maio 2025.

- SONG, T.; PANG, C.; HOU, B.; XU, G.; XUE, J.; SUN, H.; MENG, F. (2023). *A review of artificial intelligence in marine science*. *Frontiers in earth science*, 11. Disponível em: <<https://doi.org/10.3389/feart.2023.1090185>>. Acesso em: 12 mar. 2023.
- SUN, Z.; CHANG N. B.; CHEN, C. F.; GAO W. (2022). *Lake algal bloom monitoring via remote sensing with biomimetic and computational intelligence*. *International Journal of Applied Earth Observation and Geoinformation*, 2022. Disponível em: <<https://doi.org/10.1016/j.jag.2022.10299>>. Acesso em: 15 abr. 2023.
- TAIGMAN, Y.; YANG, M.; RANZATO, M.; WOLF, L. (2014). *DeepFace: Closing the Gap to Human-Level Performance in Face Verification*. *IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, OH, USA, pp. 1701-1708, 2014. Disponível em: <<https://doi.org/10.1109/CVPR.2014.220>>. Acesso em: 12 jun. 2023.
- WoRMS Editorial Board (2025). *World Register of Marine Species*. Disponível em: <<https://www.marinespecies.org>> em VLIZ, doi:10.14284/170. Acesso em: 08 mar. 2023.
- YANG, Z.; CHEN, T.; LI, J.; SUN, J. (2021). *Focusing Evaluation for In situ Darkfield Imaging of Marine Plankton*. *OCEANS 2021: San Diego – Porto*, San Diego, CA, USA, 2021, pp. 1-8. Disponível em: <<https://doi.org/10.23919/OCEANS44145.2021.97060299>> Acessado em: 20 mar. 2023.

HOW TO CITE THIS ARTICLE:

Duda, M. L. de F., & Cabral, L. de S. CLASSIFICAÇÃO DE IMAGENS DE CRUSTÁCEOS USANDO APRENDIZADO DE MÁQUINA E APRENDIZADO PROFUNDO, COM ÊNFASE NA SUPERORDEM PERACARIDA (MALACOSTRACA: CRUSTACEA). HOLOS, 5(41). Recuperado de <https://www2.ifrn.edu.br/ojs/index.php/HOLOS/article/view/17940>

M. L. F. DUDA

PhD student in Computer Science at the Computer Science Center/CIn of the Federal University of Pernambuco/UFPE; Master in Oceanography from the Department of Oceanography/DO of the Federal University of Pernambuco/UFPE; Bachelor in Biological Sciences from the Federal University of Pernambuco/UFPE and in Systems Analysis and Development from the Federal Institute of Education, Science and Technology of Pernambuco/IFPE (Brazil); DevOps at Aubay (Portugal).

E-mail: marialuiza.duda.sci@gmail.com

ORCID ID: <https://orcid.org/0000-0002-8903-7656>

L. S. CABRAL

PhD in Electrical Engineering from the Department of Electronics and Systems/DES of the Federal University of Pernambuco/UFPE; Master in Computer Science from the Center for Informatics/CIn of the Federal University of Pernambuco/UFPE; Professor at the Federal Institute of Education, Science and Technology of Pernambuco/IFPE (Brazil); Leader of the Advanced Computing, Applied Research, Intelligent Computing and Emerging Technologies/CAPACITE Group at IFPE.

E-mail: luciano.cabral@jaboatao.ifpe.edu.br

ORCID ID: <http://orcid.org/0000-0002-4235-5753>

Editor: Francinaide de Lima Silva Nascimento

Ad Hoc Reviewer: Brehme de Mesquita e Viviane Dal Molin



Submitted: October 23, 2024

Accepted: May 16, 2025

Published: December 23, 2025

