ISSN:2594-6153

Desenvolvimento de algoritmo de k-nearest neighbors (vizinhos mais próximos) para classificação de imagens de organismos do plâncton.

Agatha Manzi[2,3], Bruno Paes De-Carli [1,2,3]

[1]ETEC Aristóteles Ferreira, Instituto de Ciência e Tecnologia "Centro Paula Souza", Santos-SP, Brasil
[2]Universidade Estadual Paulista "Júlio de Mesquita Filho" – Câmpus Litoral Paulista. São Vicente-SP, Brasil
[3]Alfamar Ambiental, Rio de Janeiro-RJ, Brasil.

E-mail: bpdecarli@yahoo.com.br

Resumo: O presente estudo tem como objetivo desenvolver um algoritmo para reconhecimento de imagens de organismos planctônicos. Para isso, utilizou-se *datasets* com imagens de organismos para treino e teste do algoritimo KNN (k-nearest neighbors). Verificou-se percentuais de acurácia semelhantes a análise tradicional realizada por não especialistas, contribuindo com uma ferramenta alternativa nas análises ecológicas.
Palavras-chave: Inteligência artificial; Plâncton; Qualidade Ambiental; Reconhecimento de imagens; Aprendizado de Máquina.

Development of a K-Nearest Neighbors algorithm for image-based classification of plankton organisms

Abstract: This study aimed to develop a k-nearest neighbors (KNN)-based algorithm for the automated recognition of planktonic organisms from digital images. Image datasets were used to train and evaluate the classifier, and its performance was assessed based on classification accuracy. The KNN approach achieved accuracy rates comparable to those obtained through conventional image identification by non-specialist observers, suggesting its potential as an alternative computational tool for plankton ecological analyses**.**
Keywords: Artificial Intelligence; Plankton; Environmental Quality; Image Recognition; Machine Learning.

Introdução

Algoritmos são constituídos de um conjunto de etapas que servem para auxiliar na resolução de problemas de diversas categorias. O KNN (K-Nearest Neighbors) é um classificador simples capaz de rotular cada elemento de um conjunto de dados a partir da distância destes em relação aos seus vizinhos mais próximos em um conjunto de dados semelhante treinado previamente. Ainda, neste algoritmo pode ser utilizados diversas métricas de distância, como a Euclidiana e de Manhattan por exemplo [1].

A comunidade do plâncton é constituída de animais/vegetais/bactérias com pouca ou nenhuma locomoção na coluna d'água, de tamanhos microscópicos até grande porte, sendo considerada importante elo na teia alimentar e também bioindicadores em ambientes aquáticos [2]. Esse grupo de organismos é utilizado tradicionalmente por órgãos ambientais para avaliar o status da qualidade ambiental de ambientes marinhos e dulcícolas.

Diante disso é fundamental integrar áreas distintas como inteligência artificial, aprendizado de máquina (*machine learning*) e ecologia para o desenvolvimento de protótipos, softwares, algoritmos e novas técnicas computacionais para avançar na área de ciências biológicas. Iniciativas como esta é de extrema relevância pois contribui na criação de um banco de dados de imagens digitais com auxílio de especialistas e automatização de processos analíticos o que é crucial para monitoramentos ambientais. Além disso, este estudo contribuirá com pesquisas sobre plâncton que utilizam equipamentos como Zooscan e Video Plankton Recorder (VPR) por exemplo [3].

Objetivos

O presente estudo tem como objetivo desenvolver um algoritmo para reconhecimento de imagens de organismos planctônicos.

Material e Métodos

Para este estudo foi utilizado a linguagem R para o desenvolvimento do fluxograma bem como o algoritmo. Foram utilizadas bibliotecas como magick e class relacionadas a processamento e classificação de imagens [4]. Foram utilizadas imagens obtidas de microscopia ótica de organismos planctônicos de água doce (n=113) que possuíam padrão de dimensão de 2560 x 1536 pixels e 96 dpi (dots per inch).

Após a transformação em matriz numérica, os dados foram comparados com o algoritimo KNN utilizando a distância euclidiana, que calcula a distância em linha reta do ponto em questão e outro ponto, além da acurácia, sensibilidade e precisão. Para a validação experimental, o *dataset* foi dividido na proporção de 70% para treinamento do algoritmo k-NN (k=1,3,5) e 30% para teste, garantindo a independência entre as amostras de avaliação e de treino.

Resultados

Os resultados estão descritos na matriz de confusão e fluxogramas representados nas Tabela 1 e Figura 2. O teste realizado resultou em uma acurácia média de 62%. A distribuição da matriz de confusão demonstra que a classe *Ceratium* (dinoflagelado) apresentou maior número de acertos que o classificador principalmente quando k = 3.

Tabela 1. Matriz de confusão da classificação das imagens e métricas.

Classe Real	Qtd. Teste	Acertos (VP)	Erros (FN)	Falsos Alarmes (FP)	Rejeição Correta (VN)	Sensibilidade (%)	Acurácia (%)	Precisão (%)
ceratium	6	2	4	3	12	33%	67%	40%
diatom	5	1	4	4	12	20%	62%	20%
kelli	5	1	4	5	11	20%	57%	17%
kera	5	1	4	4	12	20%	62%	20%
TOTAL	21	5	16	16	-	-	-	-

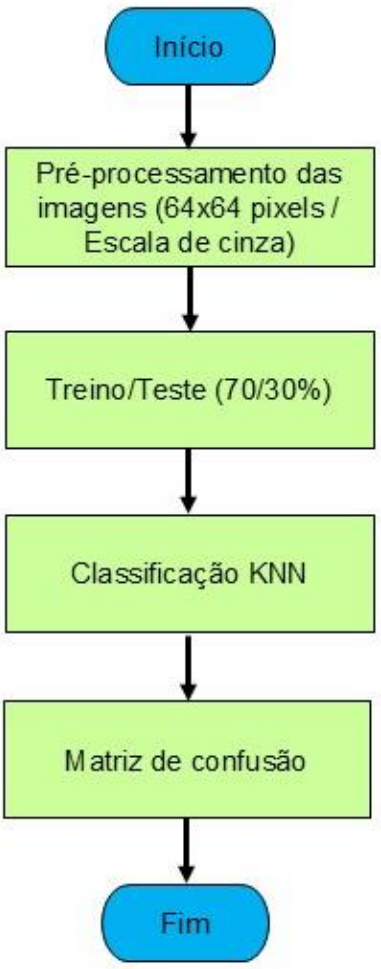

Figura 1. Fluxograma da sequência de etapas (algoritmos) envolvidas no processo de reconhecimento de imagens de organismos planctônicos.

Discussão

Algumas iniciativas já foram realizadas para desenvolver um sistema automatizado para identificação de organismos planctônicos. Em análise comparativa, a taxa de acerto do sistema PlanktoVision (95%) situa-se no mesmo patamar da classificação realizada por especialistas rotineiros (84–95%) e supera substancialmente o desempenho de técnicos não rotineiros (67–83%) validando a robustez da abordagem automatizada [4]. No presente estudo, o alto índice de falsos negativos (FN = 16) evidencia que vetores em escala de cinza e resolução 64 x 64 pixels são insuficientes para separar adequadamente as variações morfológicas desses organismos planctônicos.

Conclusões

O algoritimo proposto mostrou valores de acurácia próximos da classificação realizada por profissionais técnicos não especializados, demonstrando ser uma alternativa e complemento viável nas análises de comunidades em monitoramentos ambientais. Com o aumento da quantidade de imagens no banco de dados (treino e teste) e melhoria também na qualidade será possível uma melhor classificação de organismos planctônicos baseado em reconhecimento de imagens.

Agradecimentos: A segunda autora gostaria de agradecer o apoio dado pela Agência de Fomento CAPES (proc. 88887.176417/2025-00) durante o desenvolvimento deste estudo).

Referências

1. Passos RP, Silio LF, Lima BN, Oliveira JRL, Pereira AA, Martins GC, et al. Aplicação do classificador K-nearest neighbors (KNN) na área da saúde: relação cintura-quadril e pressão arterial. Rev CPAQV. 2021;13(2). doi:10.36692/v13n2-18.
2. De-Carli BP, Cardoso-Silva S, Manzi A, Moschini-Carlos V, Pompêo M. Zooplankton functional diversity in subtropical reservoirs of distinct trophic states (São Paulo state, Brazil). Environ Sci Pollut Res Int. 2024;31(24):35779-35788. doi:10.1007/s11356-024-33621-2.
3. Schulze K, Tillich UM, Dandekar T, Frohme M. PlanktoVision—an automated analysis system for the identification of phytoplankton. BMC Bioinformatics. 2013;14:115. doi:10.1186/1471-2105-14-115.
4. R Core Team. R: A language and environment for statistical computing [software]. Vienna (AT): R Foundation for Statistical Computing; 2026. doi:10.32614/R.manuals.