

RECONHECIMENTO E CLASSIFICAÇÃO DE ESPÉCIES DE PEIXES UTILIZANDO REDES NEURAS CONVOLUCIONAIS

Mateus Silveira Peruchi¹, Rodrigo Machado², Merisandra Côrtes de Mattos³

Resumo: O aumento no consumo de alimentos provenientes de ambientes aquáticos é acompanhado por desafios ambientais e técnicos. Este aumento, impulsionado pelo crescimento populacional e urbanização, demanda uma variedade maior de alimentos. No entanto, essa crescente demanda apresenta consequências, como a sobrepesca. Um dos desafios é a identificação das espécies marinhas que são afetadas pelas atividades humanas, o que é crucial para diversas áreas, mas que se mostra complexa mesmo para especialistas, devido à ampla diversidade fenotípica e à variação morfológica sutil entre diferentes espécies, o que exige conhecimento em taxonomia e ecologia marinha. Portanto, esta pesquisa tem como objetivo analisar o desempenho dos modelos de redes neurais profundas *ResNet-50* e *AlexNet* no desafio de classificação das espécies de peixes, seguindo cinco fases principais: levantamento bibliográfico, construção da base de imagens, desenvolvimento dos modelos de redes neurais convolucionais, treinamento e teste dos modelos, e análise dos resultados. Além disso, a pesquisa apresenta uma arquitetura modificada, baseada na estrutura básica da *AlexNet*, com o objetivo de melhorar a generalização do modelo para dados não vistos. Os resultados obtidos demonstram uma superioridade do modelo de rede neural *ResNet-50* ao modelo *AlexNet*, atingindo uma acurácia de 85% em seus melhores cenários, enquanto a *AlexNet* alcançou 68%. No entanto, a estrutura modificada da *AlexNet* foi capaz de superar essa superioridade, apresentando uma acurácia de 92% em seu melhor cenário de teste.

Palavras-chave: Visão computacional; Aprendizado profundo; Redes neurais profundas; ResNet-50; AlexNet; Arhynchobatidae; Rhinobatidae; Squatinidae.

¹Curso de Ciência da Computação, Grupo de Pesquisa em Inteligência Artificial Aplicada, Universidade do Extremo Sul Catarinense (Unesc), Criciúma - Santa Catarina - Brasil. mateusperuchi@unesc.net

²Coorientador, Curso de Ciências Biológicas, Universidade do Extremo Sul Catarinense (Unesc), Criciúma - Santa Catarina - Brasil. rodrigomachado@unesc.net

³Orientadora, Curso de Ciência da Computação, Grupo de Pesquisa em Inteligência Artificial Aplicada, Universidade do Extremo Sul Catarinense (Unesc), Criciúma - Santa Catarina - Brasil. mem@unesc.net

ABSTRACT: The increase in consumption of food from aquatic environments is accompanied by environmental and technical challenges. This rise, driven by population growth and urbanization, demands a greater variety of food. However, this growing demand presents consequences such as over-fishing. One of the challenges is identifying marine species affected by human activities, crucial for various areas but complex even for experts due to the wide phenotypic diversity and subtle morphological variation among different species, requiring knowledge in taxonomy and marine ecology. Therefore, this research aims to analyze the performance of deep neural network models ResNet-50 and AlexNet in the challenge of classifying the following fish species: *Atlantoraja castelnaui*, *Atlantoraja cyclophora*, *Rioraja agassizi*, *Pseudobatos horkelii*, *Squatina argentina*, *Squatina guggenheim*, and *Squatina occulta*, following five main phases: literature review, image database construction, development of convolutional neural network models, training and testing of models, and results analysis. Additionally, the research presents a modified architecture, based on the basic structure of AlexNet, aiming to improve the model's generalization for unseen data. The results demonstrate the superiority of the ResNet-50 neural network model over the AlexNet model, achieving an accuracy of 85% in its best scenarios, while AlexNet reached 68%. However, the modified structure of AlexNet was able to surpass this superiority, presenting an accuracy of 92% in its best test scenario.

Keywords: Computer vision; Deep learning; Deep neural networks; ResNet-50; AlexNet; Arhynchobatidae; Rhinobatidae; Squatinidae.

1 INTRODUÇÃO

Observa-se um notável crescimento no consumo de alimentos provenientes do meio aquático. Dados indicam que até 2030 se espera um aumento de 24 milhões de toneladas na quantidade de alimentos aquáticos destinados ao consumo humano, em comparação com os números de 2020 (FAO, 2022). Esse crescimento é resultado de uma série de fatores, incluindo o aumento da renda e urbanização em diversas regiões do mundo. À medida que a população se torna mais urbana e a renda das pessoas aumenta, há uma demanda crescente por uma maior variedade de alimentos consumidos, além disso, investimentos estão sendo feitos na melhoria da saúde, nutrição e alimentação, o que também impulsiona o consumo de alimentos aquáticos (FAO, 2022).

Diante desse cenário, enfrenta-se uma série de impactos ambientais significativos na tentativa de suprir as demandas do consumo global de alimentos aquáticos. O crescimento contínuo da população e o aumento do consumo podem ter diversas implicações, as quais pode-se citar a sobrepesca (exploração excessiva de recursos pesqueiros), sendo uma das causas responsáveis pela captura não intencional (conhecida como captura acidental) de peixes indesejados (Sumaila; Tai, 2020). Neste contexto, nos últimos 40 anos vem sendo observado o colapso de vários estoques naturais de peixes em todo o mundo (Pauly; Zeller, 2016), como consequência da sobrepesca de estoques importantes (Pauly; Zeller, 2017), do impacto das atividades pesqueiras nos ecossistemas, do aumento do esforço de pesca e da falta de uma governança adequado no setor pesqueiro (Pauly; Zeller, 2003).

No entanto, a identificação das espécies se torna um desafio. Primordialmente, os peixes marinhos exibem uma diversidade em termos de cores, tamanhos e formas. Em diversas espécies, a considerável variabilidade na plasticidade fenotípica e nas características morfológicas utilizadas para distinguir grupos distintos pode ser tão sutil durante várias fases de desenvolvimento que a identificação das espécies baseada unicamente em traços morfológicos torna-se uma tarefa desafiadora, mesmo para especialistas experientes (Zhang; Hanner, 2012). Além disso, a identificação de peixes marinhos demanda não apenas conhecimento em taxonomia e sistemática, mas também compreensão da ecologia marinha, biogeografia e gestão pesqueira (Ward; Hanner; Hebert, 2009).

A classificação e identificação de peixes não se limita à taxonomia, também desempenha um papel fundamental em várias áreas de pesquisa e aplicação prática. Além de contribuir para estudos taxonômicos, a identificação de espécies de peixes é uma ferramenta essencial em investigações pesqueiras, avaliação de reservas naturais, rastreamento de ingredientes alimentares e medicamentos (Bingpeng et al., 2018). Além das áreas de atuação mencionadas, a capacidade de identificar espécies de peixes desempenha um papel crucial na pesquisa de conservação. Isso é especialmente evidente na realização de investigações sobre populações de espécies ameaçadas de extinção (Banan; Nasiri; Taheri-Garavand, 2020).

Com o avanço tecnológico recente, a visão computacional vem sendo amplamente utilizada na classificação de espécies (Li et al., 2023), devido à eficácia das redes neurais convolucionais na resolução de desa-

fios de visão computacional, como a classificação de imagens e detecção de objetos (Khalil et al., 2022). As Redes Neurais Convolucionais (RNC), são um tipo de modelos de aprendizado profundo que se destacam pelo uso de neurônios especializados em operações de convolução, aplicadas hierarquicamente aos dados de entrada (Khalil et al., 2022). O processo de aprendizado nas RNC é facilitado pela combinação de várias camadas, cada uma com funções específicas. Estas camadas englobam a camada de convolução, camada de *pooling*, camada de ativação e, camada totalmente conectada. Essas camadas gradualmente refinam a imagem original, camada por camada, até atingirem a representação final das características necessárias para a tarefa em questão (Zhang et al., 2022).

Dentro do contexto mencionado, os modelos de redes neurais convolucionais *ResNet-50* e *AlexNet* são reconhecidos pelos seus desempenho em classificação de imagens. A arquitetura inovadora da *ResNet-50*, que incorpora conexões residuais, para lidar com o problema do desaparecimento do gradiente e a degradação da rede, permitem que o conhecimento da camada anterior possa ser transferido para as camadas subsequentes (Polat; Güngen, 2021), permitindo assim que a rede tenha dezenas ou até centenas de camadas. Por sua vez, a *AlexNet* construída em uma arquitetura composta por um total de 60 milhões de parâmetros e uma rede neural que abriga 650.000 neurônios (Noh, 2021), se destaca pelo uso de estratégias diferentes, como o uso de Unidades Lineares Retificadas (ReLUs), que proporcionam um treinamento mais rápido do modelo, e a aplicação de *pooling* sobreposto, o que ajuda a mitigar o risco de *overfitting* neste modelo (Hueso et al., 2022).

Mediante o exposto, esta pesquisa visa avaliar o desempenho dos modelos de redes neurais *ResNet-50* e *AlexNet*, submetidos ao desafio de classificação das espécies de peixes, compreendendo seus respectivos resultados, por meio da análise das métricas de avaliação pertinentes ao problema de classificação, a fim de demonstrar o potencial dos modelos aplicados ao contexto mencionado, contribuindo de forma significativa para a identificação das espécies de peixes. Além disso, a pesquisa apresenta uma arquitetura modificada da *AlexNet*, na qual são incorporadas técnicas adicionais para melhorar a generalização do modelo para dados não vistos. Essa pesquisa se relaciona com os Objetivos de Desenvolvimento Sustentável (ODS) da Agenda 2030 da ONU, em especial com o ODS14, relacionado à conservação e uso sustentável dos oceanos, dos mares e dos recursos marinhos para o desenvolvimento sustentável (IPEA, 2015).

2 TRABALHOS CORRELATOS

Na literatura, existem diferentes trabalhos relacionados a modelos de redes neurais convolucionais aplicados à classificação das espécies de peixes. Dentre eles, pode-se citar o estudo de Iqbal et al. (2021), que utilizou uma abordagem baseada em redes neurais convolucionais para a classificação de espécies com foco especial em variedades criadas em tanques. Eles empregaram uma versão simplificada da *AlexNet*, reduzindo a quantidade de parâmetros e o consumo de memória. Os modelos foram treinados com o conjunto de dados de peixes *QUT*, composto por 3.960 imagens de diversos ambientes, e testados com o conjunto *LifeClef2015*, que possui cerca de 20.000 imagens. O modelo proposto pelos autores alcançou uma precisão de 90,48% nos dados de teste, superando a precisão da *AlexNet*, que foi de 86,65%. No entanto, não conseguiu superar a precisão do modelo *VGGNet* durante a validação e nos testes. Isso se deve ao fato de que os modelos *VGGNet* são redes neurais com um maior número de camadas.

Kuswantori et al. (2023) apresentaram um projeto com uma abordagem para detecção e classificação automatizada de peixes, destinada a sistemas de triagem na indústria pesqueira. Os autores propuseram um modelo utilizando o algoritmo *YOLO* para reconhecimento e *YOLOv4-Tiny* com diferentes técnicas para análise e comparação. Para os conjuntos de dados, foram adotados dois métodos de geração de imagens. O primeiro consistiu em utilizar imagens estáticas de cada classe de peixe, enquanto o segundo método envolveu a extração de imagens a partir de vídeos. Os algoritmos apresentaram resultados superiores a 90% de acurácia. O *YOLOv4* com técnicas de rotulação convencionais atingiu 97,18% de acurácia no primeiro teste e 91,23% no segundo. Já o *YOLOv4-Tiny* apresentou 94,37% no primeiro teste e 90,06% de acurácia no segundo teste com vídeo. O *YOLOv4-Tiny* com LM obteve 91,89% no primeiro teste e 92,98% no segundo, e o modelo proposto alcançou 98,63% e 97,66%, respectivamente

Prasetyo et al. (2022) propuseram uma melhoria na arquitetura da *VGGNet* para classificação das espécies de peixes. Os autores utilizaram a combinação dos recursos de baixo nível do bloco inicial com recursos de alto nível do último bloco, resultando na *MLR-VGGNet*. Essa nova arquitetura substituiu o quinto bloco por componentes como *Multi-Level Residual*, *Convolução Assimétrica*, *Normalização de Lote* e recursos residuais.

Utilizando os conjuntos de dados *Fish-gres* e *Fish4-knowledge*, totalizando aproximadamente 30.000 imagens, a *MLR-VGGNet* foi comparada com outras arquiteturas de CNNs, incluindo *Inception V3*, *ResNet50* e *Xception*. Os resultados de precisão nos dados de teste foram: *MLR-VGG16* (98,46% e 96,25%), *MLR-VGG19* (97,84% e 97,09%), *VGG16* (89,83% e 82,44%), *VGG19* (87,51% e 88,07%), *Inception V3* (93,22% e 85,66%), *ResNet50* (97,84% e 88,12%) e *Xception* (93,53% e 83,70%) para os conjuntos de dados *Fish-gres* e *Fish4-knowledge*, respectivamente.

Robillard et al. (2023), apresentaram dois modelos de visão computacional para a classificação automatizada de peixes amazônicos, visando o uso em sistemas de triagem na indústria pesqueira. No primeiro modelo eles utilizaram a arquitetura *U-Net* baseada na *ResNet-34* e criaram manualmente máscaras para um subconjunto de imagens. Essas máscaras foram usadas como conjunto de treinamento para treinar a *U-Net*. O segundo modelo, responsável pela classificação de imagens de peixes amazônicos em níveis de gênero, foi construído com base na arquitetura *ResNet-101*. Para treinamento e teste dos modelos, o conjunto de dados foi dividido aleatoriamente em 80% dos dados para treinamento e 20% para teste. O modelo *U-Net* de mascaramento obteve um sucesso na segmentação de 97,23% das imagens, enquanto o classificador a nível de gênero alcançou uma precisão de 97,99% na previsão dos dados de testes.

Santos e Gonçalves (2019), propõem uma abordagem baseada em redes neurais convolucionais, para o reconhecimento de diferentes espécies de peixes encontradas no ecossistema do Pantanal. Os autores utilizaram os modelos *VGG16*, *VGG19*, *ResNet-50*, *InceptionV3*, modificando suas camadas finais para se adequar ao problema. O conjunto de dados utilizados foi composto por 68 espécies de peixes, que foram agrupadas em 10 ordens e 21 famílias de acordo com sua classificação taxonômica. Os modelos *VGG16*, *VGG19*, *ResNet-50*, *InceptionV3*, em suas arquiteturas originais alcançaram acurácias de 79%, 81,5%, 82,8% e 85,5%, respectivamente. O modelo *InceptionV3* que obteve o melhor resultado em acurácia, foi avaliado no conjunto de teste, a fim de classificar a ordem, a família e as espécies de peixes. Na classificação das famílias das espécies, o modelo apresentou uma acurácia de 93,8% e uma precisão de 90%. Além disso, na tarefa de classificação das espécies, o modelo demonstrou uma acurácia de 87,3% e uma precisão de 86,3%. O quadro 1 mostra os trabalhos correlatos a esta pesquisa.

Quadro 1. Trabalhos correlatos a esta pesquisa.

Trabalho	Modelos	Linguagem	Resultados	Métrica
Iqbal et al. (2021)	VGGNet16, VGGNet19, AlexNet	Tensorflow	VGG16: 89,97%; VGG19: 91,24%; AlexNet: 86,65%; Modelo proposto: 90,48%;	Precisão
Kuswantori et al. (2023)	YOLOv4-Tiny, YOLOv4	Python	YOLOv4-Tiny: 90,06% e 94,37%; YOLOv4: 97,18% e 91,23%; YOLOv4 + LM: 91,89% e 92,98%; Modelo proposto: 98,63% e 97,66%;	Acurácia
Prasetyo et al. (2022)	VGG16, VGG19, Inception V3, ResNet50, Xception	Python e Google Colaboratory	VGG16: 89,83% e 82,44% VGG19: 87,51% e 88,07% ResNet-50: 97,84% e 88,12% InceptionV3: 93,22% e 85,66% Xception: 93,53% e 83,70% MLR-VGG16: 98,46% e 96,25% MLR-VGG19: 97,84% e 97,09%	Precisão
Robillard et al. (2023)	U-Net, ResNet-101	PyTorch	U-NET: 97,23%; ResNet-101: 97,99%;	Precisão
Santos e Gonçalves (2019)	VGG16, VGG19, ResNet-50, InceptionV3	Python	VGG16: 79,9%; VGG19: 81,5%; ResNet-50: 82,8%; Inception: 85,5%; Modelo proposto: 86,3%;	Precisão

Fonte: Do autor (2024).

3 MATERIAIS E MÉTODOS

Esta pesquisa compreende a aplicação das redes neurais convolucionais na classificação das espécies de peixes, avaliando seus respectivos resultados baseado nas métricas de avaliação pertinentes ao problema de classificação. Para isso, empregou-se dois modelos de redes neurais convolucionais, além de um modelo proposto, em uma base de dados composta por sete espécie de peixe.

A abordagem da pesquisa é descrita como quantitativa, sendo quanto à natureza aplicada e de base tecnológica, visto que gera conhecimento relacionado à análise do uso de algoritmos de aprendizado profundo aplicados aos domínios da biologia marinha. Em relação aos objetivos da pesquisa, caracteriza-se como descritiva, pois proporciona novas abordagens sobre uma realidade já compreendida (Nunes; Nascimento;

Luz, 2016), delimitando-se métodos, modelos e teorias para a coleta e análise dos dados (Triviños, 2011). No que diz respeito aos procedimentos, compreende uma pesquisa bibliográfica e experimental, visto que envolve a aplicação e avaliação prática dos algoritmos de aprendizado profundo na classificação das espécies de peixes, incluindo a manipulação de variáveis, observação dos resultados obtidos e de seus efeitos sobre o objeto de estudo (Wazlawick, 2021).

A figura 1 representa o fluxo das etapas da pesquisa, destacando cinco fases centrais e interligadas, as quais se complementaram para atingir o objetivo proposto. Essas etapas englobam desde o levantamento bibliográfico, que se realizou uma revisão da literatura existente relacionada ao tema da pesquisa, até a construção da base de imagens, que envolveu a compilação e organização das imagens necessárias para a pesquisa. Em seguida, ocorreu o desenvolvimento dos modelos de redes neurais convolucionais, que posteriormente, foram submetidos a processos de treinamento e testes, bem como o ajuste para otimizar seu desempenho na tarefa de classificação das espécies de peixes. Por fim, os resultados dos testes foram analisados e interpretados a fim de avaliar a eficácia dos modelos desenvolvidos.

Figura 1. Etapas de desenvolvimento da pesquisa.



Fonte: Do autor (2024).

3.1 BASE DE IMAGENS DE PEIXE

A base de imagens utilizada nesta pesquisa compreende sete espécies de peixes de três famílias, comumente encontradas no sul do Brasil, no qual apresentam semelhanças morfológicas entre as espécies

de cada família. A base foi construída com imagens disponibilizadas pelas seguintes plataformas de ciência: *FishBase*, *Shark References*, *BOLD Systems v3* e *IUCN Red List of Threatened Species*. Além das plataformas mencionadas, a pesquisa conta com a parceria do Centro Nacional de Pesquisa e Conservação da Biodiversidade Marinha do Sudeste e Sul (CEPSUL), que disponibilizou imagens de algumas das espécies presentes na base. A tabela 2 mostra os dados da base de imagens.

Tabela 2. Espécies presentes na base de imagens. VU - *Vulnerable*; EN = *Endangered*; CR = *Critically Endangered*

Família	Espécie	IUCN Red List	Red List Brasil	Número de imagens
<i>Arhynchobatidae</i>	<i>Atlantoraja castelnaui</i>	CR	EN	39
<i>Arhynchobatidae</i>	<i>Atlantoraja cyclophora</i>	EN	VU	70
<i>Arhynchobatidae</i>	<i>Rioraja agassizi</i>	VU	VU	34
<i>Rhinobatidae</i>	<i>Pseudobatos horkelii</i>	CR	CR	54
<i>Squatinae</i>	<i>Squatina argentina</i>	CR	CR	8
<i>Squatinae</i>	<i>Squatina guggenheim</i>	EN	CR	23
<i>Squatinae</i>	<i>Squatina occulta</i>	CR	CR	13
Total de imagens:				241

Fonte: Do autor (2024).

Devido ao número limitado de imagens e à variabilidade insuficiente para capturar todas as características e condições possíveis, aplicaram-se técnicas de pré-processamento para aumentar a robustez da base. Essas técnicas melhoram a generalização do modelo, introduzindo variações como mudanças de rotação, escalonamento etc., tornando o modelo mais adequado a condições reais variadas. Para isso, foi utilizado o ambiente do *Google Colaboratory*, linguagem de programação *Python* e a biblioteca *Numpy* com a classe *cv2*.

A primeira técnica foi o redimensionamento das imagens para os tamanhos considerados ideais para cada um dos modelos de redes neurais empregados, os quais foram de 224 x 224 *pixels* para o *ResNet-50* e de 227 x 227 *pixels* para o *AlexNet*. A segunda técnica consistiu no zoom aleatório em diferentes partes das imagens, com fatores de zoom de 1.2, 1.5 e 1.7, resultando em várias versões das imagens com diferentes níveis de zoom.

¹FishBase: <https://www.fishbase.se/search.php>

²Shark References: <https://www.shark-references.com/>

³BOLD Systems v3: <https://v3.boldsystems.org/>

⁴IUCN Red List of Threatened Species: <https://www.iucnredlist.org/>

A terceira técnica foi o espelhamento das imagens, gerando uma segunda imagem invertida a partir da imagem original. Por fim, aplicou-se a técnica de rotação, resultando em diferentes imagens com ângulos de 90, 180 e 270 graus. Essas técnicas foram implementadas com o objetivo de aumentar o conjunto de imagens. Após a aplicação dessas técnicas, algumas imagens foram validadas manualmente para garantir a qualidade do conjunto de imagens e como resultado, a base de imagens foi expandida para 2.399 imagens.

3.2 DESENVOLVIMENTO DOS MODELOS DE REDES NEURAI CONVOLUCIONAIS

No processo de desenvolvimento das redes neurais convolucionais, foram utilizadas a linguagem de programação *Python* e o ambiente de desenvolvimento fornecido pelo *Google Colaboratory* nas seguintes versões 3.10.12 e 0.0.1a2, respectivamente. Além disso, foram empregadas algumas bibliotecas de aprendizado profundo para elaborar as arquiteturas dos modelos.

3.2.1 ResNet-50

O modelo *ResNet-50* apresenta uma arquitetura composta por um total de 50 camadas, das quais 49 são convolucionais distribuídas em cinco blocos distintos, seguidos por uma camada totalmente conectada na saída da rede neural. Estes blocos são notáveis por suas conexões de atalho, que abordam questões como o desaparecimento do gradiente e a degradação da rede (Wu et al., 2023). Tais conexões permitem a transferência eficiente de conhecimento da camada anterior para as subsequentes, solucionando esses problemas comuns em CNNs (Polat; Gungen, 2021).

Para o desenvolvimento dessa arquitetura se fez necessário o uso de várias classes disponibilizadas pela biblioteca *Keras*, incluindo *layers*, *convD2*, *BatchNormalization*, *Activation*, *MaxPooling2D*, *AveragePooling2D* e *Dense*, que compõem a estrutura original deste modelo. A arquitetura básica foi preservada, com exceção da camada totalmente conectada final, que foi ajustada para corresponder ao número de classes na base de imagens em análise, composta por sete espécies.

Para o treinamento e teste do modelo, foi utilizada a classe *Optimizers* da biblioteca *Keras*, para fazer a alteração dos HiperParâmetros. O otimizador *SDG* foi utilizado e definido com uma taxa de aprendizado

⁴Versão premium da plataforma Google Colaboratory.

de 0.01. Essa taxa permite uma aprendizagem mais rápida, mantendo a estabilidade do treinamento, e a função de perda *categorical crossentropy*, escolhida para lidar com problemas de multiclases, visando promover uma melhor generalização do modelo para a classificação de novos exemplos.

3.2.2 AlexNet

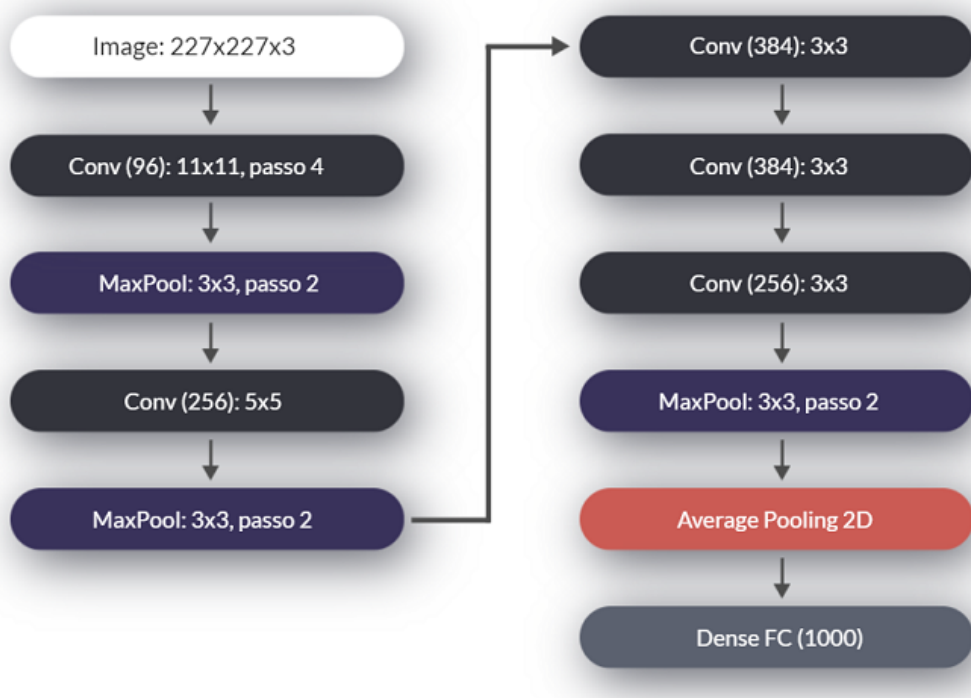
O modelo *AlexNet* é construído com base em uma arquitetura de rede neural convolucional de propagação direta (Hueso et al., 2022), composta por um total de oito camadas, das quais cinco são convolucionais e três são camadas totalmente conectadas. O *AlexNet* adota estratégias, como o uso de unidades lineares retificadas (*ReLU*s), que facilitam o treinamento mais rápido do modelo, e a aplicação de *pooling* sobreposto, o que ajuda a mitigar o risco de *overfitting* neste modelo (Hueso et al., 2022).

Na implementação do *AlexNet*, foram utilizadas várias classes do *Keras* para construir a arquitetura deste modelo, seguindo uma abordagem semelhante à *ResNet-50*. No entanto, diferentemente da *ResNet-50*, a camada *AveragePooling2D* não foi incluída, pois não faz parte da arquitetura original da *AlexNet*. A arquitetura básica foi preservada, com exceção da camada totalmente conectada final, que foi ajustada para corresponder ao número de classes na base de imagens em análise, composta por sete espécies. Por fim, seguindo a mesma abordagem utilizada na *ResNet-50*, os hiperparâmetros foram ajustados de forma semelhante. O otimizador definido foi o SGD com uma taxa de aprendizado de 0,01 e a função de perda *categorical crossentropy*.

3.2.3 Modelo proposto

O modelo proposto consiste em uma versão modificada do *AlexNet*. A arquitetura original do *AlexNet* apresenta um total de oito camadas, incluindo três camadas totalmente conectadas no final. A nova versão apresenta uma estrutura menor, mas ainda baseada na *AlexNet*, com um total de sete camadas. As cinco camadas convolucionais da arquitetura original foram mantidas, onde a principal modificação está nas camadas totalmente conectadas. Duas das três camadas totalmente conectadas foram substituídas por uma camada de *GlobalAveragePooling2D*, restando apenas uma camada totalmente conectada no final da rede neural, onde a mesma também foi ajustada para corresponder o número de classes presentes na base de imagens, composta por sete espécies. A Figura 2 ilustra a arquitetura proposta.

Figura 2. Arquitetura do *AlexNet* modificada.



Fonte: Do autor (2024).

As camadas totalmente conectadas na *AlexNet* original recebem entradas de todas as unidades da camada anterior, combinando as características individuais extraídas pelas camadas convolucionais para a classificação final. Em contraste, a camada *GlobalAveragePooling2D* reduz a dimensionalidade dos mapas de características ao calcular a média de cada mapa, analisando a imagem como um todo. Essa estratégia adotada visa melhorar a capacidade de generalização do modelo em dados não vistos anteriormente, já que a camada *GlobalAveragePooling2D* considera a imagem de forma completa.

Por fim, seguindo a mesma abordagem utilizada nos modelos anteriores, os hiperparâmetros foram ajustados de forma semelhante. O otimizador definido foi o SGD com uma taxa de aprendizado de 0,01 e a função de perda *categorical_crossentropy*.

3.3 TREINAMENTO E TESTES

O treinamento dos modelos foi realizado em seis diferentes cenários, que incluíram a manipulação do tamanho do lote (*Batch Size*) e número de épocas (*Epoch*), no qual, para cada cenário, os modelos foram executados um total de 11 vezes para realização de testes estatísticos.

Todos os experimentos foram executados em uma máquina virtual disponibilizada pelo *Google Colaboratory*, equipada com as seguintes especificações: Processador Intel(R) Xeon(R) CPU @ 2.00GHz, Sistema Operacional Linux, Placa de vídeo Tesla V100-SXM2-40GB e 80GB de memória RAM.

Inicialmente, as imagens foram divididas em uma proporção de 80/20, onde 80% das imagens se caracterizaram para treinamento e 20% para testes, em números, 1919 imagens para treinamento e 480 imagens para testes. Antes de iniciar o treinamento dos modelos, foi essencial realizar a rotulação dos dados utilizando a técnica conhecida como *one-hot encoding*.

Nessa técnica, cada rótulo é transformado em um vetor binário que apenas um elemento é igual a 1 e todos os outros são 0. Essa representação binária indica a classe da imagem de forma distinta e adequada para o processo de treinamento dos modelos. Ambos os conjuntos de imagens, de treinamento e de teste, passaram por esse processo para garantir que as classes fossem devidamente identificadas durante o treinamento e a avaliação dos modelos. Após a rotulação das imagens, os modelos foram submetidos a testes variando o tamanho do lote e o número de épocas, conforme a Tabela 3.

Tabela 3. Treinamentos e testes realizados com os modelos.

Cenário	Modelo	Época (<i>Epocha</i>)	Tamanho do Lote (<i>Batch Size</i>)
1	<i>ResNet-50, AlexNet, AlexNet modificado</i>	100	64
2	<i>ResNet-50, AlexNet, AlexNet modificado</i>	100	96
3	<i>ResNet-50, AlexNet, AlexNet modificado</i>	100	128
4	<i>ResNet-50, AlexNet, AlexNet modificado</i>	130	64
5	<i>ResNet-50, AlexNet, AlexNet modificado</i>	130	96
6	<i>ResNet-50, AlexNet, AlexNet modificado</i>	130	128

Fonte: Do autor (2024).

Durante a fase de teste, os modelos foram avaliados com uma parte reservada do conjunto de imagens para verificar seu desempenho em dados não vistos. Métricas como Acurácia que mede a proporção de previsões corretas, o *Recall* que indica a capacidade do modelo em identificar exemplos relevantes, a Precisão que representa a proporção das previsões

corretas entre os exemplos identificados como positivos e o *F1-Score* que representa uma medida balanceada entre precisão e *recall*, foram utilizadas para medir diferentes aspectos do desempenho do modelo.

4 RESULTADOS E DISCUSSÃO

Após a realização dos testes, os resultados dos modelos de redes neurais convolucionais em cada métrica e execução foram analisados estatisticamente para comparar suas performances. Primeiramente, foi realizado o teste de *Shapiro-Wilk* para verificar a normalidade dos dados. Para dados com distribuição normal, aplicou-se o teste *ANOVA* para a comparação das médias. Caso contrário, utilizou-se o teste de *Kruskal-Wallis*. A tabela 4 apresenta os resultados estatísticos da métrica Acurácia.

Tabela 4. Resultados dos testes estatísticos com a métrica Acurácia.

Modelo (Média ± DP) N = 11				
	RESNET-50	ALEXNET	ALEXNET-MODIFICADA	Valor-P
Época 100				
Lote				
64	0,8027 ± 0,0856 ^a	0,6818 ± 0,0172 ^b	0,8082 ± 0,2438 ^a	0,001†
96	0,8500 ± 0,0297 ^a	0,6773 ± 0,0257 ^b	0,8436 ± 0,0914 ^a	<0,001††
128	0,7452 ± 0,856	0,6755 ± 0,0181	0,7427 ± 0,2145	0,121††
Valor-P	0,175††	0,761††	0,276†	
Época 130				
Lote				
64	0,8345 ± 0,0406 ^a	0,6864 ± 0,0262 ^b	0,9282 ± 0,0189 ^c	<0,001††
96	0,8355 ± 0,0406 ^a	0,6673 ± 0,0237 ^b	0,8218 ± 0,2397 ^a	<0,001††
128	0,8018 ± 0,0506 ^a	0,6773 ± 0,0195 ^b	0,8464 ± 0,0951 ^a	<0,001††
Valor-P	0,112††	0,175††	0,094†	

†Valor obtido após aplicação do teste H de *Kruskal Wallis*. ††Valor obtido após aplicação do teste *ANOVA* de uma via.

a, b Letras distintas representam diferenças significativas após aplicação do *Post hoc* teste de *Dunn* ($p \leq 0,05$).

d, e Letras distintas representam diferenças significativas após aplicação do *Post hoc* teste de *Games-Howell* ($p \leq 0,05$).

g, h, i Letras distintas representam diferenças significativas após aplicação do *Post hoc* teste de *Tukey* ($p \leq 0,05$).

Fonte: Do autor (2024).

Na Tabela 4, foi analisada a métrica acurácia em dois cenários: uma com época de 100 e outra de 130. No primeiro cenário, ao analisar por coluna, observa-se que todos os valores de P foram maiores que 0,05. Isso indica que, para o mesmo modelo, a variação do tamanho do lote não interfere na acurácia. No entanto, ao analisar as diferenças entre os modelos por linha, verifica-se que, nos dois primeiros lotes (64 e 96), os valores de P foram menores que 0,05, o que indica diferenças significativas entre os modelos nesses lotes. Para identificar quais modelos apresentaram diferenças, foi aplicado o teste de *Post Hoc*. Esse teste mostrou que, nos lotes de 64 e 96, os modelos *AlexNet* modificado e *ResNet-50* são significativamente melhores que o *AlexNet* original. No entanto, não foram constatadas diferenças significativas entre o *AlexNet* modificado e o *ResNet-50*. No lote de 128, os modelos não apresentaram diferenças significativas entre si.

No segundo cenário, também foi observado que a variação do tamanho do lote, para o mesmo modelo, não interfere na acurácia. No entanto, ao analisar as diferenças entre os modelos, verifica-se que houve diferenças significativas em todos os lotes. No primeiro lote (64), todos os modelos apresentaram diferenças significativas entre si. Nesse caso, através do teste de *Post Roc*, foi possível evidenciar que o modelo *AlexNet* modificado teve o melhor desempenho, com uma acurácia de 92%. Nos demais lotes (96 e 128), tanto o modelo *AlexNet* modificado quanto o *ResNet-50* apresentaram desempenhos melhores do que o modelo *AlexNet* original. Contudo, entre o *AlexNet* modificado e o *ResNet-50*, não foram encontradas diferenças significativas.

Na tabela 5, apresentam-se os resultados estatísticos para a métrica Precisão. Assim como na métrica Acurácia, no cenário com 100 épocas, observa-se que a variação do tamanho do lote também não interferiu na precisão quando comparado os lotes para o mesmo modelo. Comparando os modelos entre si, a variação do lote mostrou diferenças significativas, indicando que os modelos *ResNet-50* e *AlexNet* modificado são melhores que o *AlexNet* original em todos os cenários de 100 épocas.

No cenário com 130 épocas, os resultados são semelhantes ao primeiro cenário. No entanto, é importante destacar que, para os lotes de tamanho 64 e 128, todos os modelos apresentaram diferenças entre si. Portanto é possível evidenciar que, no lote 64, o modelo *AlexNet* modificado alcançou a maior precisão de 93%, enquanto no lote 128, o *AlexNet* modificado também obteve a maior precisão de 87%, seguido pelo *ResNet-50* com 84% e 82%, respectivamente.

Tabela 5. Resultados dos testes estatísticos com a métrica Precisão.

Modelo (Média ± DP) N = 11				
	RESNET-50	ALEXNET	ALEXNET-MODIFICADA	Valor-P
Época 100				
Lote				
64	0,8400 ± 0,0372 ^a	0,6882 ± 0,1601 ^b	0,8318 ± 0,1985 ^a	0,001†
96	0,8600 ± 0,0245 ^d	0,6818 ± 0,0279 ^e	0,8618 ± 0,0763 ^d	<0,001††
128	0,8227 ± 0,0657 ^d	0,6818 ± 0,0178 ^e	0,8155 ± 0,1103 ^d	<0,001††
Valor-P	0,189††	0,721††	0,316†	
Época 130				
Lote				
64	0,8482 ± 0,0279 ^g	0,6873 ± 0,0249 ^h	0,9300 ± 0,0161 ⁱ	<0,001††
96	0,8445 ± 0,0324 ^a	0,6736 ± 0,0258 ^b	0,8345 ± 0,2511 ^a	<0,001†
128	0,8227 ± 0,0390 ^d	0,6827 ± 0,0210 ^e	0,8745 ± 0,0625 ^f	<0,001††
Valor-P	0,172††	0,409††	0,103†	

†Valor obtido após aplicação do teste H de *Kruskal Wallis*. ††Valor obtido após aplicação do teste *ANOVA* de uma via.

a, b Letras distintas representam diferenças significativas após aplicação do *Post hoc* teste de *Dunn* ($p \leq 0,05$).

d, e, f Letras distintas representam diferenças significativas após aplicação do *Post hoc* teste de *Games-Howell* ($p \leq 0,05$).

g, h, i Letras distintas representam diferenças significativas após aplicação do *Post hoc* teste de *Tukey* ($p \leq 0,05$).

Fonte: Do autor (2024).

Seguindo a mesma abordagem, a tabela 6 apresenta os resultados da métrica *Recall*. De forma similar à métrica Precisão, observa-se que no primeiro cenário com 100 épocas, a variação de lote não interfere no *Recall* quando comparado com o mesmo modelo. No entanto, ao comparar os modelos entre si, nos lotes 64 e 96, foram encontradas diferenças significativas, indicando que os modelos *AlexNet* modificado e *ResNet-50* superam o desempenho do *AlexNet* original, já no lote 128, não foram encontradas diferenças significativas entre os modelos.

No segundo cenário, semelhante ao primeiro, a variação do lote também não interferiu no *Recall* quando comparado para o mesmo modelo. Porém, ao comparar os modelos entre si, todos os cenários revelaram diferenças significativas, seguindo a mesma tendência observada na acurácia. A exceção ocorreu apenas no lote 64, onde todos os modelos apresenta-

ram diferenças, com a *AlexNet* modificada alcançando uma taxa de *Recall* de 92%, seguida pelo *ResNet-50* com 83%. Nos demais cenários, as diferenças destacam que os modelos *AlexNet* modificados e o *ResNet-50* superaram o desempenho do *AlexNet* original.

Tabela 6. Resultados dos testes estatísticos com a métrica *Recall*.

Modelo (Média ± DP) N = 11				
	RESNET-50	ALEXNET	ALEXNET-MODIFICADA	Valor-P
Época 100				
Lote				
64	0,8336 ± 0,0406 ^a	0,6818 ± 0,0172 ^b	0,8082 ± 0,2438 ^a	0,001†
96	0,8500 ± 0,0297 ^d	0,6773 ± 0,0257 ^e	0,8436 ± 0,0914 ^d	<0,001††
128	0,8027 ± 0,856	0,6755 ± 0,0181	0,7427 ± 0,2145	0,121††
Valor-P	0,194††	0,761††	0,276†	
Época 130				
Lote				
64	0,8345 ± 0,0406 ^g	0,6864 ± 0,0262 ^h	0,9282 ± 0,0189 ⁱ	<0,001††
96	0,8355 ± 0,0305 ^a	0,6673 ± 0,0237 ^b	0,8218 ± 0,2397 ^a	<0,001†
128	0,8018 ± 0,0506 ^d	0,6773 ± 0,0195 ^e	0,8464 ± 0,0951 ^d	<0,001††
Valor-P	0,112††	0,175††	0,094†	

†Valor obtido após aplicação do teste H de *Kruskal Wallis*. ††Valor obtido após aplicação do teste *ANOVA* de uma via.

a, b Letras distintas representam diferenças significativas após aplicação do *Post hoc* teste de *Dunn* ($p \leq 0,05$).

d, e Letras distintas representam diferenças significativas após aplicação do *Post hoc* teste de *Games-Howell* ($p \leq 0,05$).

g, h, i Letras distintas representam diferenças significativas após aplicação do *Post hoc* teste de *Tukey* ($p \leq 0,05$).

Fonte: Do autor (2024).

Na tabela 7, é possível observar os resultados do F1-Score, indicando que no primeiro cenário com 100 épocas, a variação dos lotes não afetou o desempenho quando comparado dentro do mesmo modelo. Diferenças significativas foram observadas apenas ao comparar os modelos entre si, especificamente nos lotes 64 e 96, onde os modelos *AlexNet* modificado e *ResNet-50* superaram o desempenho do *AlexNet* original. No lote 128, não foram identificadas diferenças entre os modelos.

No segundo cenário com 130 épocas, o tamanho do lote não influenciou o desempenho dentro do mesmo modelo. Comparando os mo-

delos entre si, todos os tamanhos de lotes mostraram diferenças significativas. No lote 64, o *AlexNet* modificado teve o maior desempenho com um F1-Score médio de 92%, seguido pelo *ResNet-50* com 83%. Nos demais lotes, as diferenças surgiram apenas na comparação do *AlexNet* original com os outros modelos, destacando que o *AlexNet* modificado e o *ResNet-50* foram superiores ao *AlexNet* original. Entre os modelos *ResNet-50* e *AlexNet* modificado, não houve diferenças significativas.

Tabela 7. Resultados dos testes estatísticos com a métrica *F1-Score*.

Modelo (Média ± DP) N = 11				
	RESNET-50	ALEXNET	ALEXNET-MODIFICADA	Valor-P
Época 100				
Lote				
64	0,8309 ± 0,0453 ^a	0,6773 ± 0,0168 ^b	0,7909 ± 0,2794 ^a	0,001†
96	0,8491 ± 0,0321 ^d	0,6736 ± 0,0269 ^e	0,8409 ± 0,0930 ^d	<0,001††
128	0,8027 ± 0,0856	0,6718 ± 0,0172	0,7318 ± 0,2287	0,133††
Valor-P	0,175††	0,824†††	0,295†	
Época 130				
Lote				
64	0,8327 ± 0,0398 ^g	0,6782 ± 0,0264 ^h	0,9282 ± 0,0189 ⁱ	<0,001††
96	0,8327 ± 0,0323 ^a	0,6645 ± 0,0251 ^b	0,8145 ± 0,2607 ^a	<0,001††
128	0,8009 ± 0,0501 ^d	0,6718 ± 0,0218 ^e	0,8436 ± 0,0979 ^d	<0,001††
Valor-P	0,132†††	0,436†††	0,094†	

†Valor obtido após aplicação do teste H de *Kruskal Wallis*. ††Valor obtido após aplicação do teste *ANOVA* de uma via.

a, b Letras distintas representam diferenças significativas após aplicação do *Post hoc* teste de *Dunn* ($p \leq 0,05$).

d, e Letras distintas representam diferenças significativas após aplicação do *Post hoc* teste de *Games-Howell* ($p \leq 0,05$).

g, h, i Letras distintas representam diferenças significativas após aplicação do *Post hoc* teste de *Tukey* ($p \leq 0,05$).

Fonte: Do autor (2024).

Contudo, ao comparar os diferentes cenários, destaca-se que o modelo *AlexNet* modificado, quando aplicado ao longo de 130 épocas com um tamanho de lote de 64, demonstra o melhor desempenho entre os modelos na tarefa de classificação das espécies de peixes. Na tabela 8 a seguir, são apresentados os resultados alcançados pelo modelo *AlexNet* modificado neste cenário específico, seguido pelos outros modelos avalia-

dos nesta pesquisa.


Tabela 8. Resultados dos modelos no cenário de 130 épocas com tamanho de lote 64.

Modelo	Acurácia	Precisão	Recall	F1-Score
<i>AlexNet</i>	0,6864	0,6873	0,6864	0,6782
<i>ResNet-50</i>	0,8345	0,8482	0,8345	0,8327
<i>AlexNet</i> Modificado	0,9282	0,9300	0,9282	0,9282

Fonte: Do autor (2024)

Ao revisar a matriz de confusão resultante da *AlexNet* modificada, é possível verificar que o modelo apresentou uma alta taxa de acertos para espécies individuais, sendo sua maior taxa de erro ao classificar a espécie *Atlantoraja cyclophora*, com acerto em 129 imagens e erro em oito.

Figura 3. Matriz de confusão *AlexNet* modificada.



Fonte: Do autor (2024).

Os resultados obtidos pelos modelos de redes neurais convolucionais *ResNet-50* e *AlexNet*, considerando seus melhores cenários, apresentaram resultados inferiores em métricas como acurácia, precisão, *recall*

e *F1-Score*, quando comparados com trabalhos correlatos. Uma possível explicação para essa diferença pode estar relacionado ao conjuntos de dados e nas espécies abordadas em cada pesquisa. No entanto, quando comparamos o modelo *AlexNet* modificado, é possível constatar uma vantagem em relação aos modelos propostos pelos autores Lqbal et al. (2023) e Santos e Gonçalves (2019). As demais pesquisas, tanto o modelo proposto quanto os modelos *ResNet-50* e *AlexNet* apresentaram resultados inferiores.

5 CONCLUSÃO

Esta pesquisa teve como objetivo implementar e analisar os modelos de redes neurais convolucionais *ResNet-50* e *AlexNet* na classificação de sete espécies de peixes comumente encontradas ao sul do Brasil. Adicionalmente, a pesquisa apresentou uma arquitetura modificada, na qual consiste em uma versão adaptada da *AlexNet*, visando melhorar a generalização do modelo *AlexNet* para dados não vistos.

Após o desenvolvimento dos modelos, deu-se início à etapa de treinamento e testes, na qual os modelos foram treinados e avaliados em seis cenários distintos, variando o número de épocas e o tamanho do lote. Os resultados revelaram uma predominância do modelo *ResNet-50* em praticamente todos os cenários em comparação com a arquitetura original da *AlexNet*. Essa superioridade da *ResNet-50* destaca a eficácia de arquiteturas mais avançadas na classificação de imagens complexas, como as de espécies de peixes. No entanto, com a adaptação na estrutura da *AlexNet*, foi possível atenuar essa superioridade, resultando em diversos cenários onde os modelos *AlexNet* modificado e *ResNet-50* não apresentaram diferenças significativas. Entretanto, no cenário com tamanho de lote 64 e ao longo de 130 épocas, foi possível superar esse equilíbrio e a predominância da *ResNet-50*, resultando em um modelo com uma acurácia de 92% sendo assim, possível constatar que o modelo *AlexNet* modificado obteve o melhor desempenho na classificação das espécies de peixes.

Como sugestão de pesquisas futuras tem-se a investigação de outras arquiteturas de redes neurais convolucionais para o problema de classificação das espécies de peixes; o desenvolvimento de aplicações práticas utilizando os modelos relatados nesta pesquisa; a exploração do uso de transferência de aprendizado com modelos pré-treinados, adaptando-os para a tarefa específica de classificação de espécies de peixes.

REFERÊNCIAS

BANAN, A.; NASIRI, A.; TAHERI-GARAVAND, A. Deep learning-based appearance features extraction for automated carp species identification. **Aquacultural Engineering**, v. 89, p. 102053. ISSN 0144-8609. Acessado em: 23 de junho de 2023. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0144860919302195>>.

BINGPENG, X. et al. Dna barcoding for identification of fish species in the taiwan strait. **PLoS ONE**, Public Library of Science, v. 13. ISSN 19326203. Acessado em: 11 de junho de 2023. Disponível em: <<https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0198109>>.

FAO. **The State of World Fisheries and Aquaculture 2022. Towards Blue Transformation**. Rome: [s.n.], 2022. Acessado em: 10 de junho de 2023. Disponível em: <<https://www.fao.org/3/cc0461en/online/cc0461en.htm>>.

HUESO, E. et al. A hybrid driver fatigue and distraction detection model using alexnet based on facial features. Acessado em: 08 de setembro de 2023. Disponível em: <<https://doi.org/10.3390/electronics>>.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA. **Objetivo de Desenvolvimento Sustentável 14: Vida na Água**. 2015. Acessado em: 10 de junho de 2023. Disponível em: <<https://www.ipea.gov.br/ods/ods14.html>>.

IQBAL, M. A. et al. Automatic fish species classification using deep convolutional neural networks. **Wireless Personal Communications**, Springer, v. 116, p. 1043–1053. ISSN 1572834X. Acessado em: 24 de junho de 2023. Disponível em: <<https://link.springer.com/article/10.1007/s11277-019-06634-1>>.

KHALIL, M. et al. **Machine Learning, Deep Learning and Statistical Analysis for forecasting building energy consumption — A systematic review**. Elsevier Ltd, 2022. Acessado em: 11 de agosto de 2023. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0952197622003372>>.

KUSWANTORI, A. et al. Fish detection and classification for automatic sorting system with an optimized yolo algorithm. **Applied Sciences (Switzerland)**, MDPI, v. 13. ISSN 20763417. Acessado em: 24 de setembro de 2023. Disponível em: <<https://www.mdpi.com/2076-3417/13/6/3812>>.

LI, J. et al. Deep learning for visual recognition and detection of aquatic animals: A review. **Reviews in Aquaculture**, John Wiley and Sons Inc, v. 15, n. 2, p. 409–433. Acessado em: 10 de junho de 2023. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/raq.12726>>.

NOH, S. K. Recycled clothing classification system using intelligent iot and deep learning with alexnet. **Computational Intelligence**

and Neuroscience, Hindawi Limited, v. 2021. ISSN 16875273. Acessado em: 09 de setembro de 2023. Disponível em: <<https://www.hindawi.com/journals/cin/2021/5544784/>>.

NUNES, G.; NASCIMENTO, M. C.; LUZ, M. A. Pesquisa científica: conceitos básicos. **Revista Multidisciplinar e de Psicologia**, v. 10, n. 29, p. 144–151. ISSN 1981-1179.

PAULY, D.; ZELLER, D. The global fisheries crisis as a rationale for improving the fao's database of fisheries statistics. In: _____. **From Mexico to Brazil: Central Atlantic fisheries catch trends and ecosystem models**. Canada: University of British Columbia, 2003. (Fisheries Centre Research Reports, 6), p. 1–9.

PAULY, D.; ZELLER, D. Catch reconstructions reveal that global marine fisheries catches are higher than reported and declining. **Nature Communications**, Nature Publishing Group, v. 7, n. 1, p. 10244. Disponível em: <<https://doi.org/10.1038/ncomms10244>>.

PAULY, D.; ZELLER, D. Comments on faos state of world fisheries and aquaculture (sofia 2016). **Marine Policy**, v. 77, p. 176–181. ISSN 0308-597X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0308597X16305516>>.

POLAT Özlem; GÜNGEN, C. Classification of brain tumors from mr images using deep transfer learning. **Journal of Supercomputing**, Springer, v. 77, p. 7236–7252. ISSN 15730484. Acessado em: 19 de agosto de 2023. Disponível em: <<https://link.springer.com/article/10.1007/s11227-020-03572-9>>.

PRASETYO, E.; SUCIATI, N.; FATICHAH, C. Multi-level residual network vggnet for fish species classification. **Journal of King Saud University - Computer and Information Sciences**, King Saud bin Abdulaziz University, v. 34, p. 5286–5295. ISSN 22131248. Acessado em: 13 de outubro de 2023. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1319157821001300>>.

ROBILLARD, A. J. et al. Application of a deep learning image classifier for identification of amazonian fishes. **Ecology and Evolution**, John Wiley and Sons Ltd, v. 13. ISSN 20457758. Acessado em: 01 de outubro de 2023. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1002/ece3.9987>>.

SANTOS, A. A. dos; GONÇALVES, W. N. Improving pantanal fish species recognition through taxonomic ranks in convolutional neural networks. **Ecological Informatics**, Elsevier B.V., v. 53, p. 100977. ISSN 1574-9541. Acessado em: 15 de outubro de 2023. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1574954119301001>>.

SUMAILA, U. R.; TAI, T. C. End overfishing and increase the resilience of the ocean to climate change. **Frontiers in Marine Science**, v. 7, p. 523. Acessado em: 10 de junho de 2023. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fmars.2020.00523/full>>.

TRIVIÑOS, A. N. S. **Introdução à pesquisa em ciências sociais: a pesquisa qualitativa em educação**. São Paulo: Atlas, 2011.

WARD, R. D.; HANNER, R.; HEBERT, P. D. N. The campaign to dna barcode all fishes, fish-bol. **Journal of Fish Biology**, v. 74, n. 2, p. 329–356. Acessado em: 17 de junho de 2023. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1095-8649.2008.02080.x>>.

WAZLAWICK, R. **Metodologia de pesquisa para ciência da computação**. Rio de Janeiro: LTC, 2021.

WU, D. et al. Improved resnet-50 deep learning algorithm for identifying chicken gender. **Computers and Electronics in Agriculture**, Elsevier B.V., v. 205. ISSN 01681699. Acessado em: 20 de agosto de 2023. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0168169923000108>>.

ZHANG, J.; HANNER, R. Molecular approach to the identification of fish in the south china sea. **PLoS ONE**, v. 7. ISSN 19326203. Acessado em: 19 de junho de 2023. Disponível em: <<https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0030621>>.

ZHANG, R. et al. Transfer learning for leaf small dataset using improved resnet50 network with mixed activation functions. **Forests**, MDPI, v. 13. ISSN 19994907. Acessado em: 18 de agosto de 2023. Disponível em: <<https://www.mdpi.com/1999-4907/13/12/2072>>.