

# UMA ANÁLISE DAS APLICAÇÕES ATUAIS E FUTURAS DO PROCESSAMENTO DE IMAGEM POR INTELIGÊNCIA ARTIFICIAL EM REGISTROS DE ARMADILHAS FOTOGRÁFICAS

Isabela de Sá Leal<sup>1</sup>; Liliani Marília Tiepolo<sup>2</sup>

## GT 1 – Análise Ambiental, Sustentabilidade e Conservação

### Resumo

O uso de armadilhas fotográficas (CTs) tem transformado a ecologia e a conservação, permitindo o monitoramento não invasivo de espécies e *habitats*. Este artigo apresenta uma análise dos avanços recentes na aplicação de inteligência artificial (AI) para o processamento de imagens obtidas por CTs, destacando abordagens inovadoras e seus impactos. A análise foi conduzida a partir de 68 artigos selecionados através da metodologia PICO na base de dados Scopus, organizados em agrupamentos temáticos a partir de um dendrograma gerado por *clustering* hierárquico UPGMA. Entre os resultados, destaca-se a crescente adoção de *deep learning* e métodos como *transfer learning* e *lifelong learning* para aprimorar a identificação de espécies e indivíduos. Também foram identificadas inovações no uso de CTs adaptadas a grupos taxonômicos específicos, como o Insect Detect DIY para insetos, e ferramentas de código aberto, como o BearID, que facilitam o monitoramento comportamental e a conservação. Outro ponto relevante é a importância de *datasets* abertos para viabilizar o treinamento de modelos robustos em projetos menores. Apesar das limitações, como desbalanceamento de dados e desafios na padronização de *benchmarks*, o uso de AI reduziu significativamente o tempo de processamento de imagens e permitiu análises mais abrangentes, incluindo para espécies ameaçadas e *habitats* sensíveis. Este artigo conclui que, para maximizar o impacto dessas ferramentas, é necessário um esforço interdisciplinar que integre avanços tecnológicos, conservação prática e considerações com o uso de recursos que vão além da praticidade, considerando também as pessoas envolvidas no processo.

**Palavras-chave:** Tecnologias de monitoramento; *machine learning*; tecnologias de conservação; biodiversidade; ciências ambientais.

---

<sup>1</sup> Bacharel em Ciências Ambientais; Universidade Federal do Paraná - Setor Litoral; Matinhos, Paraná, Brasil. E-mail: [isabela.leal@ufpr.br](mailto:isabela.leal@ufpr.br) | ORCID: <https://orcid.org/0000-0002-3756-2838>

<sup>2</sup> Doutora em Ciências Biológicas; Universidade Federal do Paraná - Setor Litoral; Matinhos, Paraná, Brasil. E-mail: [liliani@ufpr.br](mailto:liliani@ufpr.br) | ORCID: <https://orcid.org/0000-0002-4488-2768>

## 1 INTRODUÇÃO

O monitoramento da biodiversidade tem enfrentado desafios crescentes devido a pressões antropogênicas, com muitas espécies se tornando cada vez mais difíceis de registrar e monitorar (ADAM *et al.*, 2021; WÄGELE *et al.*, 2022). Os esforços de gerenciamento e conservação da vida selvagem dependem da coleta oportuna e precisa de dados, mas os métodos tradicionais de monitoramento podem ser caros e trabalhosos (SMITH *et al.*, 2024). As armadilhas fotográficas (*Camera trap* – CT) surgiram como uma ferramenta vital para lidar com esses desafios, permitindo que pesquisadores monitorem espécies em áreas remotas por períodos prolongados sem a necessidade de presença humana constante (OLIVER *et al.*, 2023). Por isso, as CTs agora são comumente implementadas para monitorar espécies invasoras e nativas, formando a espinha dorsal de muitas iniciativas de monitoramento ecológico (NOROUZZADEH *et al.*, 2018; SMITH *et al.*, 2024).

Apesar de seus benefícios, os sistemas de CT apresentam seu próprio conjunto de desafios logísticos. Seu gerenciamento requer tempo e trabalho consideráveis para manter o equipamento, recuperar dados e, crucialmente, processar imagens coletadas (BÖHNER *et al.*, 2023). Esse fluxo de trabalho, em especial a análise dos grandes volumes de registros – majoritariamente vazios devido à captação da movimentação de folhas pelos sensores de movimento – cria um gargalo no processamento de dados. Uma vez que informações são essenciais para apoiar a tomada de decisões em conservação, longos intervalos entre a coleta dos dados e a geração de recomendações utilizáveis podem agravar os desvios já existentes entre a pesquisa e a ação efetiva (FENNEL *et al.*, 2022).

A inteligência artificial (*Artificial intelligence* – AI) tem transformado diversas práticas nos últimos anos, inclusive a maneira que registros de animais são processados (NAKAGAWA *et al.*, 2023). Com os avanços no aprendizado de máquina (*Machine learning*) e visão computacional (*Computer vision*), os sistemas de AI agora podem identificar espécies em imagens de forma autônoma com níveis crescentes de precisão (NOROUZZADEH *et al.*, 2018). A aplicação da AI neste contexto geralmente envolve o treinamento de redes neurais convolucionais (*Convolutional neural network* – CNNs) ou outros algoritmos de aprendizado de máquina em grandes conjuntos de dados para reconhecer padrões específicos de espécies, permitindo a classificação rápida de imagens com intervenção humana extremamente reduzida (NAKAGAWA *et al.*, 2023). Tais

capacidades não apenas aumentam a eficiência do processamento de imagens de CT, mas também abrem novas possibilidades para dimensionar esforços de conservação, permitindo que conjuntos de dados maiores e mais complexos sejam gerenciados de forma mais eficaz.

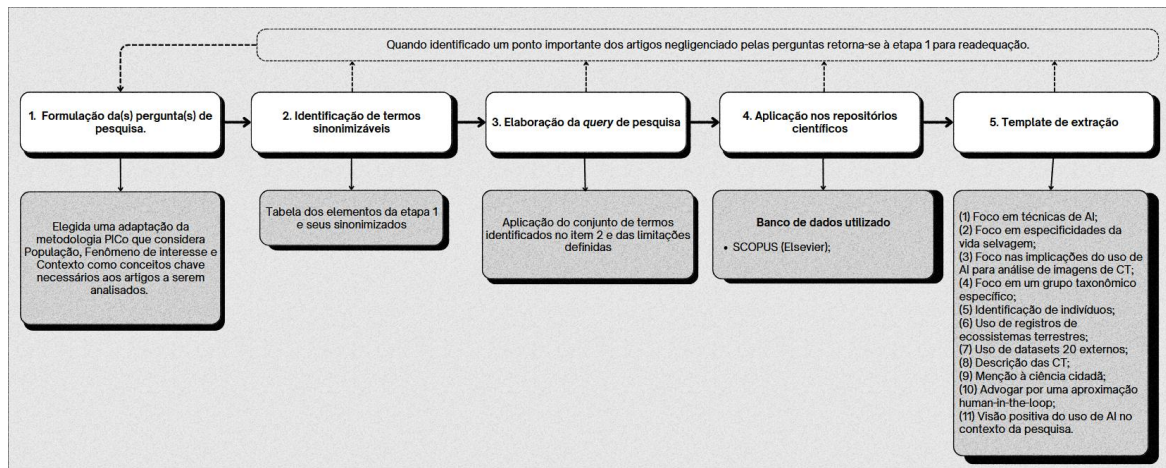
Entretanto, para que os modelos de AI alcancem alto desempenho, é essencial contar com grandes volumes de dados rotulados, um recurso escasso especialmente no caso de espécies raras ou ameaçadas (SHAHINFAR *et al.*, 2020). Fatores ambientais, como variações na iluminação, presença de vegetação e ângulo das câmeras, também introduzem ruídos significativos, exigindo que os algoritmos sejam suficientemente robustos para manter a acurácia (ZHANG *et al.*, 2023). Assim, embora o uso de AI em dados de CT seja um campo promissor e em rápida expansão, ainda enfrenta diversos desafios técnicos e conceituais.

Diante disso, esta pesquisa visa mapear e avaliar os estudos existentes sobre a aplicação de inteligência artificial no processamento de dados de armadilhas fotográficas. Especificamente, busca-se identificar a demografia da produção científica na área, principais tendências, desafios enfrentados e perspectivas futuras. O trabalho está estruturado nas seguintes seções: **Metodologia**, que descreve as etapas do levantamento bibliográfico, extração e análise dos dados; **Resultados e Discussão**, que apresenta os achados de 68 artigos analisados e sintetiza as recomendações e oportunidades identificadas; e, por fim, a **Conclusão**, que retoma os principais pontos e propõe caminhos para pesquisas futuras.

## 2 METODOLOGIA

Para a elaboração deste estudo, foi adotado um método estruturado de levantamento e análise de literatura científica, com base no procedimento de Hussein *et al.* (2022), que analisaram estudos de visão computacional e aprendizado de máquina aplicados à classificação de imagens de espécimes de herbário. O fluxo completo das etapas adotadas neste trabalho está representado na Figura 1, abaixo:

Figura 1 — Fluxo metodológico da pesquisa



Fonte: Elaborado pelas autoras (2025)

Para localizar os artigos é necessária a formulação de uma *query* de pesquisa, que por sua vez resulta da formulação de uma pergunta de pesquisa. Para isto, foi utilizado o *framework* PICO (*Population, phenomena of interest e context*), que se trata de uma adaptação qualitativa da metodologia PICO (*Population, intervention, comparison, outcome*), uma das mais utilizadas para revisões sistemáticas da medicina (HOSSEINI *et al.*, 2024).

A partir da estrutura proposta por PICO, a pergunta elaborada foi: “Como estudos que utilizam **armadilhas fotográficas** (contexto) para monitorar a **vida selvagem** (população), são afetados pelo uso de **inteligência artificial para classificação de imagens** (fenômeno de interesse)?”

A partir da pergunta de pesquisa, são identificadas as palavras-chave – no caso “armadilhas fotográficas”, “vida selvagem”, “inteligência artificial” e “classificação de imagens”. A fim de garantir a abrangência de todos os artigos de interesse, foram selecionados termos-sinônimo, descritos no Quadro 1. Estes não necessariamente têm o mesmo significado no geral, mas sim remetem à mesma ideia no contexto da pesquisa.

Quadro 1 — Termos sinonimizados na *query*

População (P)	Fenômeno de interesse (I)		Contexto (Co)
Wildlife	Artificial Intelligence	Image classification	Camera trapping
Biodiversity	Deep learning	Individual identification	Camera trap
Fauna	Convolutional neural network	Taxa identification	Trail cam
Biological diversity	Deep neural network	Species identification	Remote camera
		Specie identification	

Fonte: Elaborado pelas autoras (2025)

Para esta pesquisa, foi decidido que não haveria limite de intervalo de tempo, uma vez que é um campo de pesquisa relativamente novo. No entanto, os tipos de publicação foram limitados a artigos em estágio final de publicação, e que estivessem em inglês ou português.

A partir de todas estas considerações, a *query* resultante é:

```
TITLE-ABS-KEY("Camera trapping" OR "Camera trap" OR "Trail cam" OR Remote camera) AND (TITLE-ABS-KEY("Artificial Intelligence" OR "Deep learning" OR "Convolutional neural network" OR "Deep neural network")) AND TITLE-ABS-KEY("Wildlife" OR "biodiversity" OR "wildlife" OR "fauna") AND ALL ("image 18 classification" OR "individual identification" OR "Taxa identification" OR "Species identification" OR "Specie identification") AND (LIMIT-TO (LANGUAGE , "English") OR LIMIT-TO (LANGUAGE , "Portuguese")) AND (LIMIT-TO (DOCTYPE, "ar")) AND (LIMIT-TO (PUBSTAGE , "final"))
```

A *query* foi aplicada na base de dados *Scopus*, no mês de agosto de 2024, e deu um retorno de 75 artigos. Cada um foi analisado individualmente para inclusão ou não na pesquisa, e sete foram eliminados por não se adequarem ao tema, restando 68 publicações.

Para a etapa de análise, foi elaborado um template de extração de dados com onze critérios previamente definidos, sendo eles: (1) Foco em técnicas de AI; (2) Foco em especificidades da vida selvagem; (3) Foco nas implicações do uso de AI para análise de imagens de CT; (4) Foco em um grupo taxonômico específico; (5) Identificação de

indivíduos; (6) Uso de registros de ecossistemas terrestres; (7) Uso de *datasets* 20 externos; (8) Descrição das CT; (9) Menção à ciência cidadã; (10) Advogar por uma aproximação *human-in-the-loop*; (11) Visão positiva do uso de AI no contexto da pesquisa. Cada artigo foi avaliado em relação a esses aspectos, sendo atribuídos valores binários: 1, quando o critério estava presente, e 0, quando ausente<sup>3</sup>.

A fim de identificar *clusters* de similaridade, essa tabela foi processada no *software* de análise estatística Past, versão 4.03, através de *hierarchical clustering*, utilizando o índice de similaridade Jaccard. Na *hierarchical clustering* subconjuntos de pontos de dados são mesclados ou divididos determinando a distância entre eles, usando uma medida chamada métrica de ligação (EZUGWU *et al.*, 2022). Uma dessas métricas é a de UPGMA (*Unweighted Pair Group Method with Arithmetic mean*), que produz um dendrograma a partir de uma matriz de distância através de um agrupamento sequencial (THEODORIDIS & KOUTROUMBAS, 2008).


### 3 RESULTADOS E DISCUSSÃO

O artigo mais antigo dos analisados é “*Animal Detection from Highly Cluttered Natural Scenes Using Spatiotemporal Object Region Proposals and Patch Verification*”, de Zhang *et al.* (2016). À exceção do ano seguinte (2017), que não teve publicações na área, todos os anos posteriores cresceram ou se mantiveram na quantidade de publicações, como pode ser visto no Gráfico 1. A partir de 2018, observa-se uma expansão significativa no número de estudos, culminando em 15 publicações apenas nos oito primeiros meses de 2024.

---

<sup>3</sup> O modelo completo de extração, com a matriz artigo-critério, encontra-se disponível no link: <https://sites.google.com/view/slr-iaia/dados-complementares>.

Gráfico 1 — Quantidade de publicações por ano.




Fonte: Elaborado pelas autoras (2025).

Um aumento particularmente significativo é observado entre 2020 e 2021, quando o número de publicações passou de seis para 11. Esse crescimento pode estar relacionado, em parte, ao impacto da pandemia de COVID-19. Durante esse período, muitos pesquisadores redirecionaram seus esforços para atividades que podiam ser realizadas remotamente, como a análise de dados já coletados e revisão de metodologias (HEO *et al.*, 2022).

A revista com mais publicações foi a *Ecological Informatics*, com 19 artigos, um volume significativamente superior ao das demais. Ela é seguida de *Methods in Ecology and Evolution*, com sete artigos. *Animals* e *Ecology and Evolution* são as seguintes, com cinco artigos cada. As revistas com mais de dois artigos publicados estão ilustradas no Gráfico 2, abaixo.

Gráfico 2 — Quantidade de publicações por revista científica.



Fonte: Elaborado pelas autoras (2025).

Complementarmente, cerca de 82% dos artigos analisados são de acesso aberto, o que ressalta a relevância da democratização do conhecimento científico, promovendo maior disseminação de metodologias e ampliando o alcance dessas pesquisas, especialmente em contextos de recursos limitados. Essa acessibilidade favorece colaborações globais e acelera o impacto prático das inovações tecnológicas no monitoramento da biodiversidade (NAKAGAWA *et al.*, 2018; RADIG *et al.*, 2024).

Juntos, os 68 artigos analisados têm 2489 citações, com uma média impressionante de 36,6 citações por trabalho, evidenciando o impacto significativo da área na comunidade científica. Os três artigos mais citados destacam o papel central de abordagens baseadas em *machine learning* para a classificação de espécies em imagens de armadilhas fotográficas.

O mais citado foi “*Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning*”, de Norouzzadeh *et al.* (2018), com 694 citações e com FWCI (*Field Weighted Citation Impact*) de 17,22. Este artigo demonstra a aplicação de redes neurais convolucionais profundas (*deep convolutional neural networks*) na análise de grandes volumes de imagens. Utilizando o *dataset Snapshot Serengeti*, composto por 3,2 milhões de imagens, o estudo alcançou uma precisão superior a 93,8% na identificação de 48 espécies, com possibilidade de automação de até 99,3% dos dados com 96,6% de acurácia, equiparando-se ao desempenho de equipes humanas. Além da eficiência técnica, o trabalho evidencia a

economia de mais de 17.000 horas de trabalho manual, destacando os ganhos de escala e a viabilidade de transformar áreas como ecologia e biologia da conservação em ciências baseadas em grandes volumes de dados (*big data*).

Entretanto, os autores também reconhecem limitações e áreas para melhorias, como os vieses inerentes à AI, que devem ser mitigados para garantir resultados confiáveis. O artigo explora o potencial do *transfer learning*, permitindo que pequenos projetos de armadilhas fotográficas, com conjuntos de dados limitados, se beneficiem de redes treinadas em grandes bases públicas, como o *Snapshot Serengeti*. Além disso, o estudo sugere caminhos futuros promissores, como o uso de sistemas híbridos que combinam AI com equipes humanas e ciência cidadã; práticas de aprendizado ativo (*active learning*) para refinar continuamente os modelos; e a criação de soluções para lidar com imagens contendo múltiplas espécies.

O segundo artigo mais citado, “*Machine learning to classify animal species in camera trap images: Applications in ecology*”, de Tabak *et al.* (2019) tem 293 citações e um FWCI 16,13. Ele utiliza uma CNN de arquitetura ResNet-18 e um conjunto de mais de 3,3 milhões de imagens, o modelo alcançou uma precisão de 97,6%, a maior registrada até então, e demonstrou eficiência tanto em imagens diurnas quanto noturnas. Além disso, o modelo provou ser adaptável, com validações fora do conjunto de treinamento, alcançando 82% de precisão em imagens de ungulados no Canadá e 94% na distinção de imagens vazias em um conjunto de dados da Tanzânia. Essa abordagem permite a integração de classificações automáticas em estudos ecológicos, promovendo monitoramentos mais extensos e de longo prazo, especialmente úteis para espécies sensíveis ou invasoras. A capacidade de treinar novos modelos também assegura a escalabilidade e aplicabilidade da ferramenta em estudos futuros.


Por fim, o terceiro artigo mais citado, “*Identifying animal species in camera trap images using deep learning and citizen science*”, (217 citações e FWC de 12,73) destaca a combinação de aprendizado profundo e ciência cidadã como uma solução eficiente para os desafios impostos pela crescente quantidade de dados gerados por armadilhas fotográficas. Segundo seus autores, Willi *et al.* (2019) o uso de CNNs demonstrou alta acurácia na classificação de imagens de espécies, humanos, veículos e imagens vazias, alcançando entre 88,7% e 92,7% de precisão para espécies específicas e até 98% para imagens vazias. O uso de *transfer learning* aumentou a acurácia em até 10,3% em projetos com conjuntos de dados menores, ampliando o potencial de aplicação de modelos treinados em bases maiores. Além disso, a exclusão de previsões de baixa confiança

elevou as acurácias dos modelos ao nível dos cientistas cidadãos. Quando combinadas, as CNN e as classificações de voluntários reduziram o esforço humano em 43%, sem comprometer a precisão, em experimentos conduzidos no Zooniverse. O estudo ilustra como a integração entre tecnologia e participação pública não apenas acelera o processamento de grandes volumes de imagens, mas também endereça a dificuldade de encontrar voluntários suficientes para atender à crescente demanda por análise de dados.

As abordagens híbridas do 1º e 3º artigos demonstram como a ciência cidadã e AI podem se complementar, otimizando o monitoramento da biodiversidade e aumentando a eficiência dos estudos ecológicos. O uso de CNNs foi presente nos três estudos.

Um total de 37 países têm instituições com os autores dos artigos vinculados, com os dez melhores colocados expressos no Gráfico 3. O país com mais instituições foi os Estados Unidos, com 19 trabalhos (cerca de 27.5%). Seguiram China (15), Reino Unido (14), Alemanha (11) e África do Sul (8). Observa-se forte presença de países do Norte Global, enquanto 8 dos 10 primeiros colocados. Contudo, destaca-se o fato de que a soma das contribuições dos países do Sul Global, que inclui China, África do Sul, Brasil entre outros, corresponde a mais da metade das publicações (38, ou 55%). Essa participação crescente reflete um engajamento cada vez maior de instituições e pesquisadores de regiões historicamente marginalizadas em campos de inovação tecnológica, como o uso de AI em estudos ecológicos.

Gráfico 3 – Quantidade de publicações por países das afiliações vinculadas



Fonte: Elaborado pelas autoras (2025)

Quanto aos resultados do dendrograma de similaridade, as categorias com maior quantidade de positivos foram as de uso de registros de ecossistemas terrestres e visão positiva do uso de AI no contexto da pesquisa – ambas com 66 artigos, seguidas de “foco em técnicas de AI”, com 54 artigos. 31 artigos trouxeram algum tipo de descrição das CT utilizadas, e houveram 27 que trabalharam com grupos taxonômicos específicos. Tanto a categoria de uso de *datasets* externos quanto a de foco em vida selvagem contaram com 26 artigos. Por fim, as categorias com menos artigos relacionados foram implicações (11); ciência cidadã (11); advogar por uma aproximação *human-in-the-loop* (9) e identificação de indivíduos (8).

Os resultados da tabela feita para elaboração do dendrograma de similaridade indicam uma tendência clara em relação ao foco da maioria dos artigos analisados, com ênfase no uso de registros de ecossistemas terrestres (66 artigos) e na visão positiva sobre a aplicação de AI no contexto da pesquisa ecológica (66 artigos). Essas categorias, seguidas por um número considerável de publicações voltadas para técnicas de AI (54 artigos), refletem a crescente aceitação e adoção dessa tecnologia, particularmente de redes neurais convolucionais, como uma ferramenta de análise de dados ecológicos.

Além disso, categorias com menos publicações, como ciência cidadã (11 artigos), mostram que, apesar da popularidade dos artigos de Norouzzadeh *et al.* (2018) e Willi *et al.* (2019) ainda existem desafios significativos na integração de práticas híbridas e interdisciplinares. O fato de que apenas nove artigos abordam aproximações "*human-in-the-loop*" (ou seja, combinações de AI com interação humana) e que apenas 11 artigos exploram as implicações práticas da AI para a pesquisa ecológica sugere que, embora o uso de AI seja amplamente promovido, sua implementação prática em contextos mais amplos ainda está em uma fase inicial. Essa lacuna entre o uso de tecnologias avançadas e sua aplicação colaborativa em campo revela um espaço fértil para futuras pesquisas, especialmente considerando as possibilidades demonstradas pelos artigos analisados, que destacam como abordagens híbridas entre AI e participação humana podem otimizar o monitoramento da biodiversidade e melhorar a eficiência dos estudos ecológicos.

Os *clusters* de similaridade resultantes destes valores podem ser vistos na Figura 2, abaixo. Os títulos dos trabalhos correspondentes aos números da figura estão relacionados no Anexo 2. A tabela geral, resultante do template de extração, pode ser acessada no Anexo 3.



Quadro 2 — Critérios de cada *cluster* de similaridade

	A	B	C	D	E
Foco em técnicas de inteligência artificial	-	Sim	Sim	Sim	Sim
Foco em especificidades da WL	Não	Não	Não	Sim	Sim
Foco nas implicações do uso de AI para análise de imagens de CT	-	Não	Não	Não	Não
Foco em um grupo taxonômico específico	-	Não	Não	Sim	Sim
Identificação de indivíduos	Não	Não	Não	Sim	Não
Uso de registros de ecossistemas terrestres	Sim	Sim	Sim	Sim	Sim
Uso de <i>datasets</i> externos	Não	Sim	Não	Não	Não
Descrição das CT	-	Não	Não	Sim	Sim
Menção ao uso de ciência cidadã	Não	Não	Não	Não	Não
Advogar por uma aproximação <i>human-in-the-loop</i>	Sim	Não	Não	Não	Não
Visão positiva do uso de AI no contexto da pesquisa.	Não	Sim	Sim	Sim	Sim

Fonte: as autoras (2025)

A análise do dendrograma de similaridade revela não apenas as tendências gerais das publicações sobre o uso de AI na pesquisa ecológica, mas também a existência de agrupamentos bem definidos que refletem diferentes abordagens e ênfases nos estudos analisados. Enquanto as categorias mais representativas incluem o uso de registros de ecossistemas terrestres e uma visão positiva do uso da IA, os agrupamentos específicos destacados no dendrograma oferecem uma visão mais detalhada sobre como essas tendências se distribuem entre os artigos.

A partir do dendrograma, emergem três grandes grupos –  $\Omega$ ,  $\alpha$  e  $\beta$  – que, além de revelar nuances nas abordagens metodológicas e conceituais dos estudos, fornecem subsídios para a compreensão das dinâmicas entre as áreas mais especializadas e aquelas de caráter mais interdisciplinar. Cada um dos grupos, assim como os *clusters* que os compõem (A, B, C, D e E), traz contribuições específicas que ajudam a mapear as lacunas e os potenciais de aplicação da AI em estudos ecológicos, conforme detalhado a seguir.

### 3.1 $\Omega$ : MISCELÂNEA

O agrupamento Ômega, apresenta-se como um conjunto mais heterogêneo e distinto em relação aos demais, e a ausência de *clusters* de similaridade (diferente de Alfa e Beta) dentro deste agrupamento reforça sua natureza deviante, reunindo artigos que questionam ou exploram aspectos não centrais ou vão além dos convencionais no uso da AI em pesquisas ecológicas.

Os dois artigos de menor similaridade aos demais são “*Lost in the ashes? Broadscale passive monitoring provides limited insight into the impacts of Australia's megafires on biodiversity*” (LIVERY *et al.*, 2024) e “*The Smart Forest Conundrum: Contextualizing Pitfalls of Sensors and AI in Conservation Science for Tropical Forests*” (SARKAR *et al.*, 2021). Eles são os que, em oposição aos demais, questionam a real efetividade do uso de tecnologias de inteligência artificial no contexto da pesquisa – desta forma, contribuem para um contraponto necessário em um campo predominantemente otimista, estimulando um debate mais equilibrado sobre os desafios técnicos e éticos envolvidos.

Sarkar *et al.* (2021) apresenta uma análise crítica e reflexiva sobre o uso de tecnologias inteligentes, como sensores e IA, no contexto da conservação de florestas tropicais. Por meio de uma revisão bibliográfica e estudo de casos, os autores estruturam a discussão em torno de três questões centrais: os impactos dessas tecnologias na pesquisa científica em conservação; os atores que impulsionam este movimento tecnológico; e as implicações para os *stakeholders* tradicionais da conservação, incluindo comunidades locais, pesquisadores e governos. Os autores questionam por que investir em sistemas tecnológicos caros quando as comunidades locais – que vivem e interagem diretamente com o ecossistema – poderiam ser engajadas para desempenhar esse papel. Além de reduzir custos, essa alternativa valorizaria o conhecimento local e promoveria um modelo de conservação mais justo e colaborativo.

Já Lavery *et al.* (2024), ao analisar os efeitos dos mega-incêndios na Austrália durante o verão de 2019–2020, apontaram que grandes volumes de dados não resolvem desafios fundamentais de desenho e análise de programas de monitoramento. Eles enfatizam a importância de abordagens sob medida, análises progressivas e refinamento metodológico, argumentando que programas bem-sucedidos dependem de objetivos claros, integração com estratégias de manejo e planejamento estatístico robusto desde as fases iniciais. Assim, o estudo serve como um alerta para evitar uma dependência

excessiva de tecnologias emergentes sem considerar suas limitações e contexto de aplicação.

Outro elemento singular de  $\Omega$  é a inclusão dos únicos artigos focados em ecossistemas aquáticos, “*Assessing the Image Concept Drift at the OBSEA Coastal Underwater Cabled Observatory*” e “*Using machine vision to estimate fish length from images using regional convolutional neural networks*” – que compõe o segundo par com menos grau de similaridade aos demais. A especificidade desses estudos em ecossistemas sub-representados amplia a perspectiva sobre as aplicações da AI, ao mesmo tempo em que evidencia uma lacuna nos esforços de pesquisa voltados para ambientes não terrestres.

Adicionalmente, a presença de dois dos artigos mais citados (“*Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning*” e “*Identifying animal species in camera trap images using deep learning and citizen science*”) ressalta a relevância do agrupamento  $\Omega$ . Esses estudos estabeleceram parâmetros metodológicos e aplicações amplamente reconhecidas, mas sua localização neste grupo indica que, em termos de similaridade conceitual, eles se distanciam dos outros artigos em suas abordagens.

Um ponto que estes dois artigos abordam, e é central nas publicações de Adam *et al.* (2021) e Jansen *et al.* (2024) – também do grupo Ômega – é a ciência cidadã. Para Jansen *et al.* (2024), ela se apresenta como uma ferramenta essencial para engajar o público geral em um processo colaborativo de classificação de imagens provenientes de armadilhas fotográficas, exemplificado no projeto WildLIVE! realizado na Bolívia. Neste projeto, mais de 850 participantes contribuíram com cerca de 9.000 horas de trabalho voluntário, classificando imagens com categorias predefinidas, anotando espécies e identificando indivíduos. A abordagem priorizou o aprendizado mútuo, integrando sentimentos de engajamento emocional e motivação intelectual dos participantes. Além disso, os dados gerados serviram como um recurso para a criação de *datasets* rotulados, fundamentais para o treinamento de algoritmos de ML. Jansen *et al.* (2024) destacam ainda que o sucesso da iniciativa se baseou em estratégias como exposição midiática, criação de conexões emocionais e visibilidade em portais públicos de ciência cidadã, reforçando seu impacto tanto na conservação quanto na promoção da educação e da comunicação científica.

Adam *et al.* (2021) corroboram ao propor que a integração de dados provenientes de plataformas globais de ciência cidadã, como SciStarter e Zooniverse, com sistemas analíticos pode não apenas auxiliar na re-identificação de indivíduos em estudos populacionais e ecológicos, mas também exportar automaticamente informações para bancos de dados de fauna e plataformas internacionais de ciência cidadã. Essa abordagem permite que o público geral participe ativamente de iniciativas científicas, contribuindo tanto com o fornecimento de dados quanto com a validação de informações, promovendo avanços significativos em pesquisas de longo prazo e aumentando a acessibilidade e a aplicabilidade dos resultados no contexto global.

Por fim, a notável concentração de publicações recentes (27% de 2024) dentro do agrupamento  $\Omega$  reflete um interesse emergente e diversificado em explorar perspectivas alternativas ou críticas, sugerindo que este grupo pode representar um núcleo de inovação e contestação dentro do campo. Essa característica destaca a importância de revisitar regularmente as categorias estabelecidas para integrar novos desafios e questionamentos que surgem com o avanço das tecnologias e a ampliação de seus contextos de aplicação.

### 3.2 $\alpha$ : TÉCNICAS DE AI

A categoria Alfa destacou-se pelo foco técnico em inteligência artificial aplicada ao processamento de dados exclusivamente terrestres, refletindo um alinhamento claro com o objetivo de desenvolver e aprimorar métodos para análise de imagens de armadilhas fotográficas. Cinco de seus 30 artigos (aprox. 17%) são do ano de 2024.

Sendo o maior grupo, com 30 artigos, Alfa demonstra sua relevância ao agregar o maior *cluster*, B, com 9 artigos, que se diferencia do segundo maior *cluster*, C, pela incorporação de *datasets* externos. Essa ênfase no uso de bases de dados já consolidadas evidencia um esforço em criar modelos robustos por meio da diversificação e ampliação dos conjuntos de treinamento, como ilustrado no Quadro 3, onde Snapshot Serengeti se destaca como o *dataset* mais utilizado.

Quadro 3: *Datasets* utilizados em cada trabalho.

Número artigo	Artigo	Datasets
1	<i>“How many images do I need?” Understanding how sample size per class affects deep learning model performance metrics for balanced designs in autonomous wildlife monitoring</i>	Snapshot Australia, Snapshot Serengeti, Snapshot Wisconsin.
2	<i>A deep active learning system for species identification and counting in camera trap images</i>	Snapshot Serengeti, eMammal Machine Learning, North American Camera Trap Images (NACTI), Caltech Camera Traps.
9	<i>Active and Incremental Learning with Weak Supervision</i>	PASCAL VOC dataset
10	<i>Adaptive image processing embedding to make the ecological tasks of deep learning more robust on camera traps images</i>	North American Camera Trap Images (NACTI)
12	<i>An integrated wildlife recognition model based on multi-branch aggregation and squeeze-and-excitation network</i>	Snapshot Serengeti (SS) + dataset próprio
26	<i>Bag of tricks for long-tail visual recognition of animal species in camera-trap images</i>	Snapshot Serengeti, Caltech Camera Traps, WCS Camera Traps, Wellington Camera Traps.
28	<i>Class incremental learning for wildlife biodiversity monitoring in camera trap images</i>	Subset of Snapshot Serengeti (SS)
32	<i>Domain-Aware Neural Architecture Search for Classifying Animals in Camera Trap Images</i>	North American Camera Trap Images, i.e., NACTI; Missouri Camera Trap Images, i.e., MCTI
43	<i>Improved Wildlife Recognition through Fusing Camera Trap Images and Temporal Metadata</i>	Camdeboo dataset; Subset of the Snapshot Serengeti dataset; Snapshot Mountain Zebra dataset (part of the Snapshot Safari network).

Fonte: As autoras (2025).

A partir disto, é possível inferir a essencialidade de *datasets* abertos para o avanço de pesquisas que utilizam aprendizado profundo, especialmente em áreas como o monitoramento de fauna por armadilhas fotográficas. Conforme destacado por Norouzzadeh *et al.* (2018), o aprendizado profundo apresenta melhor desempenho quando aplicado a conjuntos de dados amplos, com milhões de imagens rotuladas (*labeled data*). No entanto, muitos projetos de armadilhas fotográficas, particularmente os de menor escala, enfrentam dificuldades para criar seus próprios grandes *datasets* devido a restrições de recursos ou tempo.

Nesse contexto, *datasets* públicos amplos, como o Snapshot Serengeti, desempenham um papel crucial ao possibilitar o uso de *transfer learning*. Essa abordagem permite que redes neurais sejam inicialmente treinadas em grandes *datasets* públicos e, posteriormente, refinadas em *datasets* menores e específicos do projeto, potencializando a aplicabilidade e eficácia do aprendizado profundo mesmo em estudos com recursos limitados. Assim, a promoção e o uso de *datasets* abertos não só democratizam o acesso às tecnologias de ponta, mas também ampliam o alcance e o impacto das pesquisas ecológicas e conservacionistas.

Outras perspectivas relevantes para o aprimoramento do uso de armadilhas fotográficas e inteligência artificial aparecem na categoria “encaminhamentos” do *cluster B*. Uma delas destaca que a automação na extração de informações não apenas otimiza projetos existentes, mas também impulsiona a expansão de redes maiores dessas ferramentas. O uso de detectores pré-treinados simplifica a abordagem inicial, mas ajustes adicionais, como a inclusão de *bounding boxes* no processo de rotulagem, podem melhorar significativamente o desempenho dos modelos (NOROUZZADEH *et al.*, 2021).

Outra perspectiva aborda o desafio da sub-representação de espécies raras ou ameaçadas no treinamento de modelos de reconhecimento automático, devido à escassez de exemplos em *datasets* desbalanceados. Para mitigar esse problema, foi proposto o método *Square-root Sampling Branch* (SSB), que utiliza uma abordagem multi-ramificada para melhorar a precisão no reconhecimento de classes minoritárias (*tail classes*), preservando a performance das classes majoritárias (*head classes*). Apesar dos avanços, os resultados indicam a necessidade de métodos mais robustos para lidar com distribuições desbalanceadas, especialmente para pequenos *datasets*. Sugere-se explorar abordagens como *few-shot learning*, amostragem progressiva e métodos como *Remix*

para futuros aprimoramentos, além de reforçar a importância da padronização de *benchmarks* e a adoção de boas práticas no pré-processamento e treinamento de modelos (CUNHA *et al.*, 2023).

O *cluster C*, embora menor, com sete artigos, abriga tanto o artigo mais antigo da amostra, publicado em 2017, quanto o segundo mais citado, que explora o uso de *machine learning* na classificação de espécies animais. Esses trabalhos indicam a consolidação de abordagens baseadas em aprendizado profundo no período estudado e sua contínua evolução para desafios mais específicos e complexos.

Seus encaminhamentos incluem pontos levantados por Tabak *et al.* (2019) que – apesar de ser voltado a espécies da América do Norte – oferece flexibilidade para pesquisadores que estudam outras espécies, ao possibilitar a remoção de imagens sem animais antes da classificação manual, reduzindo a carga de trabalho dos ecologistas e facilitando estudos mais longos e abrangentes.

Já Fennel *et al.* (2022) argumentam que o modelo de detecção de objetos MegaDetector acelera a classificação de imagens de armadilhas fotográficas, especialmente na identificação de atividades humanas, uma aplicação relevante para a ecologia recreativa. A eficiência no processamento de grandes volumes de dados, como os gerados por estudos sobre os impactos da atividade humana na vida selvagem, é crucial para reduzir o tempo entre a coleta de dados e a tomada de decisões de conservação. O modelo MegaDetector também facilita o anonimato de imagens humanas antes do processamento, protegendo a privacidade.

Ambos os estudos (assim como todos os demais do *cluster*) sugerem que, ao integrar essas ferramentas nos fluxos de trabalho existentes, seria possível acelerar as pesquisas e aplicações, ajudando a superar os gargalos de dados e proporcionando resultados mais rápidos e precisos (FENNEL *et al.*, 2022).

### 3.3 $\beta$ : INTERDISCIPLINARES

Por fim, Beta reúne os trabalhos que analisaram dados terrestres e consideraram especificidades de grupos taxonômicos de níveis variados.  $\beta$  é o grupo com mais artigos de 2024: seis (~ 26%), de seu total de 26 artigos. Este grupo teve dois *clusters* destacados: D e E.

O *cluster D* reúne quatro artigos que lidaram com identificação de indivíduos dentro de uma mesma espécie. As espécies trabalhadas foram: urso pardo (*Ursus arctos*);

cervo-sika (*Cervus nippon*); takin (duas subespécies de *Budorcas taxicolor*) e abutre real (*Torgos tracheliotus*). Outros trabalhos de Beta também lidaram com identificação de indivíduos dentro de um mesmo táxon, sendo eles o tigre-siberiano (*Panthera tigris tigris*); Elefantes (espécies *Loxodonta cyclotis* e *Elephas maximus*) e grandes primatas (*Pan troglodytes* e *Gorilla gorilla*); e dois artigos trabalharam com múltiplas espécies de felinos com pelagem de demarcações distinguíveis.

A pesquisa com o BearID, de Clapham *et al.* (2020) demonstra o potencial do reconhecimento facial baseado em *deep learning* para espécies com marcas pouco distintas, como o urso pardo. Com uma precisão média de 0,98 na detecção facial e 83,9% na identificação individual, o estudo sugere que a expansão de conjuntos de treinamento e o monitoramento longitudinal podem aumentar a robustez do modelo, embora desafios como o impacto de mudanças na idade e tamanho corporal sobre a acurácia ainda precisem ser enfrentados. Além disso, a combinação do BearID com armadilhas fotográficas poderia viabilizar estudos mais detalhados sobre padrões de atividade e uma abordagem econômica para monitoramento populacional, com implicações diretas na gestão de paisagens e estratégias de conservação.

No caso do cervo-sika, a integração de CNNs com máquinas de vetores de suporte (*Support Vector Machines* - SVM) demonstrou a eficácia dessa combinação na classificação de indivíduos, aproveitando a capacidade das SVMs de lidar com padrões lineares e não-lineares. Entretanto, o estudo destaca limitações na representatividade dos dados e a necessidade de expandir as populações amostradas. Sugestões como o uso de veículos aéreos não tripulados (UAVs) para capturar imagens complementares representam oportunidades promissoras para ampliar a aplicabilidade dos métodos desenvolvidos (SHARMA *et al.*, 2024).

Já o trabalho com duas subespécies de takin no Himalaia Oriental enfatiza a importância de avaliações ecológicas que considerem tanto pressões climáticas quanto fatores humanos na sobrevivência de espécies. O estudo reforça a necessidade de estratégias de conservação baseadas em dados populacionais robustos, com potencial para apoiar políticas públicas frente às mudanças climáticas e pressões antropogênicas (WANG *et al.*, 2024).

Por fim, o desenvolvimento de sistemas semi-automatizados para identificação de animais marcados (*tagged animals*), representa uma alternativa à identificação individual

que não utilize traços físicos dos animais, mas sim a leitura e identificação automatizada de *tags* colocadas por ecólogos em procedimentos e monitoramento. Apesar de testar a metodologia proposta com abutres, o trabalho pode ser aplicado a qualquer taxa que tenha uma estrutura de demarcação similar (SANTANGELI, 2022).

Complementarmente, um outro trabalho de Beta, de Bodesheim *et al.* (2022), destaca a relevância do aprendizado ativo (*active learning*) em modelos de reconhecimento aplicados ao monitoramento de longo prazo. A estratégia de *uncertainty sampling*, em particular, identifica imagens em que o modelo apresenta maior incerteza sobre suas previsões, solicitando a intervenção de especialistas para resolver ambiguidades. Esse processo, aliado ao conceito de *lifelong learning* e ao uso de um especialista no ciclo de aprendizado (*human-in-the-loop*), possibilita a atualização contínua do modelo, garantindo maior precisão ao longo do tempo, enquanto reduz o esforço humano necessário para a rotulagem. Tal abordagem é especialmente valiosa em estudos de monitoramento contínuo, onde fluxos de novos dados requerem soluções adaptativas para aprimorar a eficiência e a eficácia dos modelos.

Já **E** é o maior *cluster* deste grupo – com sete artigos – e conta com todos os aspectos iguais de **D** com exceção de não trabalhar com identificação de indivíduos. Os táxons trabalhados por este *cluster* foram pequenos mamíferos; herpetofauna; aves silvestres; carneiro selvagem (*Ovis canadensis*); insetos e grou-comum (*Grus grus*).

Apesar de armadilhas fotográficas serem tipicamente utilizadas para grandes e médios mamíferos, Sittinger *et al.* (2024), Binta *et al.* (2023) e Böhner *et al.* (2023) demonstraram abordagens diferenciadas ao utilizar CT adaptadas aos grupos focais. Sittinger *et al.* (2024) propôs a *Insect Detect*, uma armadilha fotográfica projetada para monitoramento automatizado e não invasivo de insetos, que utiliza componentes de *hardware* de baixo custo combinados com *software* de código aberto, em que modelos de aprendizado profundo rastreia, em tempo real, insetos pousando em uma plataforma de flor artificial. Além disso, a armadilha, alimentada por energia solar, demonstrou resistência a condições extremas de temperatura e umidade, permitindo o monitoramento autônomo durante toda uma estação.

Trabalhos como os de Binta *et al.* (2023) e Böhner *et al.* (2023) também apresentaram variações interessantes de instalação das armadilhas fotográficas a fim de melhorar os registros e, desta forma, facilitar o processo de identificação automatizada por AI. Estas variações que levam em conta peculiaridades de grupos atípicos são de

importante destaque ao lidar com a questão apontada por Nakagawa *et al.* (2023) de que a maior parte dos estudos de *machine learning* com imagens de vida selvagem são para grupos carismáticos – grandes mamíferos taxonomicamente próximos dos seres humanos (*taxonomic bias*).

Este *cluster* destaca-se pela amplitude taxonômica abordada, refletindo uma tendência crescente de se aplicar tecnologias de identificação em uma gama mais diversificada de grupos biológicos. Um artigo particularmente relevante de 2024, “*Benchmarking wild bird detection in complex forest scenes*” (SONG *et al.*, 2024), apresenta um elevado Fator de Impacto (FWCI de 9,12), indicando a relevância e a qualidade da pesquisa que aborda a detecção de aves selvagens em ambientes florestais complexos. Essa abordagem pioneira e de alto impacto sublinha a importância do uso de tecnologias avançadas para a análise de biodiversidade, especialmente em ecossistemas visualmente complexos.

Em conjunto, os *clusters D* e *E* do grupo Beta mostram uma crescente valorização do monitoramento de espécies e indivíduos em diferentes contextos ecológicos e taxonômicos, evidenciando a aplicação de métodos cada vez mais refinados, como a identificação de padrões e características individuais, além de refletir a expansão do uso de sensores e AI para uma maior diversidade de grupos biológicos. Esses resultados sugerem que a interdisciplinaridade e a inovação tecnológica estão se consolidando como tendências-chave nos estudos ecológicos contemporâneos.

## 4 CONCLUSÃO

Este estudo revisou os avanços recentes no uso de inteligência artificial aplicada ao processamento de imagens geradas por armadilhas fotográficas, destacando seu potencial para transformar a pesquisa em biodiversidade e conservação. Apesar das vantagens tecnológicas, como a redução no tempo de processamento e a ampliação da abrangência analítica, os desafios persistem, incluindo o desbalanceamento de dados, a falta de padronização em *benchmarks* e a necessidade de ferramentas mais acessíveis para projetos menores. Além disso, observou-se uma lacuna em ecossistemas aquáticos e a importância de maior colaboração internacional, especialmente para incluir vozes e dados de regiões do Sul Global.

Conclui-se que maximizar o impacto das ferramentas de inteligência artificial e armadilhas fotográficas requer um esforço interdisciplinar que integre avanços tecnológicos, práticas de conservação e um enfoque nas pessoas envolvidas no processo, indo além de soluções técnicas para promover uma ciência mais inclusiva e colaborativa. Neste contexto, a adoção dos princípios FAIR (*Findable, Accessible, Interoperable, Reusable*) desempenha um papel central. Este conjunto de diretrizes de compartilhamento promove que os dados sejam facilmente encontrados, acessíveis, interoperáveis entre diferentes sistemas e reutilizáveis em novos estudos, oferecendo uma base sólida para avanços científicos mais eficientes e colaborativos.

Além disso, iniciativas como a ciência cidadã e a disponibilização de *datasets* abertos são destacadas como ferramentas transformadoras. Elas não apenas democratizam o acesso à ciência, mas também reforçam o engajamento público, a transparência e a qualidade dos dados gerados.

Por fim, o trabalho reforça a necessidade de superar desafios técnicos e metodológicos, como o desbalanceamento de dados e a falta de padronização, enquanto aponta para um futuro promissor desde que uma sinergia entre inovação tecnológica, ações conservacionistas e uma abordagem ética que considere o bem-estar da seres humanos e não-humanos.

## Referências

- ADAM, M. *et al.* The role of Citizen Science and deep learning in camera trapping. **Sustainability**, v. 13, n. 18, p. 10287, 2021.
- BINTA, S. I. *et al.* Animal species recognition with deep convolutional neural networks from ecological camera trap images. **Animals: an open access journal from MDPI**, v. 13, n. 9, 2023.
- BODESHEIM, P. *et al.* Pre-trained models are not enough: active and lifelong learning is important for long-term visual monitoring of mammals in biodiversity research— Individual identification and attribute prediction with image features from deep neural networks and decoupled decision models applied to elephants and great apes. **Zeitschrift für Säugetierkunde [Mammalian biology]**, v. 102, n. 3, p. 875–897, 2022.
- BÖHNER, H. *et al.* A semi-automatic workflow to process images from small mammal camera traps. **Ecological informatics**, v. 76, n. 102150, p. 102150, 2023.
- CLAPHAM, M. *et al.* Automated facial recognition for wildlife that lack unique markings: A deep learning approach for brown bears. **Ecology and evolution**, v. 10, n. 23, p. 12883–12892, 2020.
- CUNHA, F.; DOS SANTOS, E. M.; COLONNA, J. G. Bag of tricks for long-tail visual recognition of animal species in camera-trap images. **Ecological informatics**, v. 76, n. 102060, p. 102060, 2023.
- EZUGWU, A. E. *et al.* A comprehensive survey of clustering algorithms: State-of-the-art machine learning applications, taxonomy, challenges, and future research prospects. **Engineering applications of artificial intelligence**, v. 110, n. 104743, p. 104743, 2022.
- FENNELL, M.; BEIRNE, C.; BURTON, A. C. Use of object detection in camera trap image identification: Assessing a method to rapidly and accurately classify human and animal detections for research and application in recreation ecology. **Global ecology and conservation**, v. 35, n. e02104, p. e02104, 2022.
- HEO, S. *et al.* Impacts of the COVID-19 pandemic on scientists’ productivity in science, technology, engineering, mathematics (STEM), and medicine fields. **Humanities & social sciences communications**, v. 9, n. 1, p. 434, 2022.
- HOSSEINI, M.-S. *et al.* Formulating research questions for evidence-based studies. **Journal of Medicine, Surgery, and Public Health**, v. 2, n. 100046, p. 100046, 2024.
- HUSSEIN, B. R. *et al.* Applications of computer vision and machine learning techniques for digitized herbarium specimens: A systematic literature review. **Ecological informatics**, v. 69, n. 101641, p. 101641, 2022.
- JANSEN, M. *et al.* Engaging citizen scientists in biodiversity monitoring: Insights from the WildLIVE! Project. **Citizen Science Theory and Practice**, v. 9, n. 1, p. 6, 2024.
- LAVERY, T. H. *et al.* Lost in the ashes? Broadscale passive monitoring provides limited insight into the impacts of Australia’s megafires on biodiversity. **Biological conservation**, v. 289, n. 110378, p. 110378, 2024.
- NAKAGAWA, S. *et al.* Rapid literature mapping on the recent use of machine learning for wildlife imagery. **Peer community journal**, v. 3, n. e35, 2023.

NOROUZZADEH, M. S. *et al.* Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning. **Proceedings of the National Academy of Sciences of the United States of America**, v. 115, n. 25, p. E5716–E5725, 2018.

NOROUZZADEH, M. S. *et al.* A deep active learning system for species identification and counting in camera trap images. **Methods in ecology and evolution**, v. 12, n. 1, p. 150–161, 2021.

OLIVER, R. Y. *et al.* Camera trapping expands the view into global biodiversity and its change. **Philosophical transactions of the Royal Society of London. Series B, Biological sciences**, v. 378, n. 1881, 2023.

PAST. Disponível em: <<https://past.en.lo4d.com/>>. Acesso em: 14 nov. 2024.

RADIG, B. *et al.* Automated visual large scale monitoring of faunal biodiversity. **Pattern recognition and image analysis**, v. 31, n. 3, p. 477–488, 2021.

SANTANGELI, A. *et al.* Semi-automated detection of tagged animals from camera trap images using artificial intelligence. **The Ibis**, v. 164, n. 4, p. 1123–1131, 2022.

SARKAR, D.; CHAPMAN, C. A. The smart forest conundrum: Contextualizing pitfalls of sensors and AI in conservation science for tropical forests. **Tropical conservation science**, v. 14, p. 194008292110147, 2021.

SHAHINFAR, S.; MEEK, P.; FALZON, G. “How many images do I need?” Understanding how sample size per class affects deep learning model performance metrics for balanced designs in autonomous wildlife monitoring. **Ecological informatics**, v. 57, n. 101085, p. 101085, 2020.

SHARMA, S. *et al.* Enhancing Sika deer identification: Integrating CNN-based Siamese networks with SVM classification. **Electronics**, v. 13, n. 11, p. 2067, 2024.

SITTINGER, M. *et al.* Insect detect: An open-source DIY camera trap for automated insect monitoring. **PloS one**, v. 19, n. 4, p. e0295474, 2024.

SMITH, J. *et al.* Man versus machine: cost and carbon emission savings of 4G-connected Artificial Intelligence technology for classifying species in camera trap images. **Scientific reports**, v. 14, n. 1, 2024.

TABAK, M. A. *et al.* Machine learning to classify animal species in camera trap images: Applications in ecology. **Methods in ecology and evolution**, v. 10, n. 4, p. 585–590, 2019.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. 4. ed. San Diego, CA, USA: Academic Press, 2008.

WÄGELE, J. W. *et al.* Towards a multisensor station for automated biodiversity monitoring. **Basic and applied ecology**, v. 59, p. 105–138, 2022.

ZHANG, Q. *et al.* A few-shot rare wildlife image classification method based on style migration data augmentation. **Ecological informatics**, v. 77, n. 102237, p. 102237, 2023.