



UNIVERSIDADE FEDERAL DO AMAPÁ
PRÓ-REITORIA DE GRADUAÇÃO
DEPARTAMENTO DE MEIO AMBIENTE E DESENVOLVIMENTO
CURSO DE BACHARELADO EM CIÊNCIAS AMBIENTAIS

ANTONIO CARVALHO DE OLIVEIRA NETO

**AVALIAÇÃO DE REDES NEURAIS CONVOLUCIONAIS NO MONITORAMENTO
DE FAUNA URBANA NA UNIVERSIDADE FEDERAL DO AMAPÁ CAMPUS
MARCO ZERO: Desafios da automação em ambiente de transição amazônico**

MACAPÁ-AP

2026

ANTONIO CARVALHO DE OLIVEIRA NETO

**AVALIAÇÃO DE REDES NEURAIAS CONVOLUCIONAIS NO MONITORAMENTO
DE FAUNA URBANA NA UNIVERSIDADE FEDERAL DO AMAPÁ CAMPUS
MARCO ZERO: Desafios da automação em ambiente de transição amazônico**

Trabalho de Conclusão de Curso apresentado
ao Colegiado do Curso de Bacharelado em
Ciências Ambientais da Universidade Federal
do Amapá, como requisito necessário para a
obtenção do título de Bacharel em Ciências
Ambientais

Orientador (a): Darren Norris

MACAPÁ-AP

2026

Dados Internacionais de Catalogação na Publicação (CIP)
Biblioteca Central/UNIFAP-Macapá-AP
Elaborado por Cristina Fernandes – CRB-2 / 1569

Oliveira Neto, Antonio Carvalho de.
O48a Avaliação de redes neurais convolucionais e monitoramento de fauna urbana na Universidade Federal do Amapá campus Marco Zero Desafios da automação em ambiente de transição amazônico / Antonio Carvalho de Oliveira Neto. - Macapá, 2026.
1 recurso eletrônico.
45 f.

Trabalho de Conclusão de Curso (Graduação) - UNIFAP, Coordenação do Curso de Ciências Ambientais, Macapá, 2026.
Orientador: Darren Norris.

Modo de acesso: World Wide Web.
Formato de arquivo: Portable Document Format (PDF).

1. Monitoramento de animais. 2. Redes neurais convolucionais. 3. Saúde Única. I. Norris, Darren, orientador. II. UNIFAP. III. Título.

CDD 23. ed. – 363.7

OLIVEIRA NETO, Antonio Carvalho de. **Avaliação de redes neurais convolucionais e monitoramento de fauna urbana na Universidade Federal do Amapá campus Marco Zero Desafios da automação em ambiente de transição amazônico.** Orientador: Darren Norris. 2026. 45 f. Trabalho de Conclusão de Curso (Graduação) - Ciências Ambientais. UNIFAP, Macapá, 2026.

ANTONIO CARVALHO DE OLIVEIRA NETO

**AVALIAÇÃO DE REDES NEURAIIS CONVOLUCIONAIS NO MONITORAMENTO
DE FAUNA URBANA NA UNIVERSIDADE FEDERAL DO AMAPÁ CAMPUS
MARCO ZERO: Desafios da automação em ambiente de transição amazônico**

BANCA EXAMINADORA

Prof. Dr. Darren Norris – UNIFAP
Orientador

Profa. Ma. Elizandra de Matos Cardoso
Membro avaliador

Prof. Dr. José Leonardo Lima Magalhães
Membro avaliador

MACAPÁ-AP

2026

Dedico este trabalho a todos aqueles que permanecem na incógnita para seu próprio bem.

AGRADECIMENTOS

Agradeço aos meus avós, Maria Pereira de Oliveira e Antonio Carvalho de Oliveira, por serem meu porto seguro. À minha avó, pela proteção e fé inabalável nos momentos difíceis; ao meu avô, pelo amor incondicional e por garantir as condições para que eu me dedicasse integralmente aos estudos.

À minha família, por uma criação focada na educação que me ensinou o valor da observação como ferramenta de aprendizado.

À Deise Cristina Vale, minha professora de artes e grande impulsionadora da educação amapaense. Obrigado por não me deixar na caverna e sim me guiar até a universidade pública. Você é incrível.

Ao "Grupo de Apoio", Cauã Cristian, Idelmir Junior, Milena Martins e Laíza Fortaleza que esteve comigo desde o início. Aos meus melhores amigos de longa data, João Monteiro e Adrianny Karollinny, por oito anos de caminhada, e ao Ausate Guimarães, pela parceria e pela eterna competição.

À Jéssica Caroline, que transcende o papel de fonoaudióloga e terapeuta para se tornar uma grande amiga.

Aos amigos que a universidade me deu, em especial ao pessoal da Biologia e do Laboratório de Herpetologia: Agatha Soares, Brendha Amanajás, Maria Eduarda, Gabriela Borges, Heitor Xavier, Marcella Carvalho, Julia Ponciano, Maykon Balieiro, Thiago Gama e Clarisse Farias. Um agradecimento especial à Ketry Oliveira, pelo apoio e escuta nas jogatinas noturnas.

À Isabel Machado Rodrigues, por ter sido uma grande fonte de foco e entretenimento essenciais, especialmente durante a pandemia. Obrigado pela maior comunidade brasileira de leitores e por proporcionar, através do Discord, a comunidade mais acolhedora que conheci.

Ao meu orientador, Darren Norris, pela confiança ao me conduzir nesta jornada de conclusão de curso.

Por fim, à Universidade Federal do Amapá (UNIFAP) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pelo suporte institucional e pelo incentivo à pesquisa científica.

“Enquanto eu tiver perguntas e não houver
resposta continuarei a escrever”
- Clarice Lispector

RESUMO

O monitoramento de animais errantes em áreas urbanas é um componente estratégico para a Saúde Única, visando o controle de zoonoses e a mitigação de impactos sobre a biodiversidade nativa. No entanto, a análise manual de grandes volumes de dados provenientes de armadilhas fotográficas constitui um gargalo metodológico. Este estudo teve como objetivo desenvolver e avaliar o desempenho de um protótipo de *Deep Learning*, baseado na arquitetura ResNet-50, para a classificação automatizada de fauna no *campus* Marco Zero da Universidade Federal do Amapá, comparando-o aos modelos consolidados DeepFaune e AddaxAI. Foram coletadas 19.190 imagens em um ambiente urbano amazônico. O protótipo foi implementado via ecossistema *Torch for R* com técnica de *fine-tuning*. Os resultados revelaram uma acurácia global de 29,99% e um índice Kappa de 0,0981 para o protótipo, enquanto os modelos DeepFaune e AddaxAI atingiram patamares de ~65% de acurácia. A análise evidenciou que o baixo desempenho decorre do desvio de domínio e do efeito *Terra Incognita*, agravados pela densidade da vegetação e pela perda de descritores cromáticos em registros noturnos. Além do viés tecnológico, o estudo identificou uma pressão antrópica significativa, com 16,68% de registros de cães (*Canis lupus familiaris*) e gatos (*Felis catus*) domésticos. Conclui-se que, no cenário atual, a automação plena da vigilância ambiental na UNIFAP é inviável, sendo a classificação manual por especialistas uma etapa obrigatória e indispensável para garantir a fidedignidade dos dados, posicionando a inteligência artificial como uma ferramenta de triagem preliminar.

Palavras-chave: Monitoramento de animais; Redes neurais convolucionais; Saúde Única.

ABSTRACT

The monitoring of stray animals in urban areas is a strategic component of One Health, aiming at zoonosis control and the mitigation of impacts on native biodiversity. However, manual analysis of large volumes of data from camera traps constitutes a methodological bottleneck. This study aimed to develop and evaluate the performance of a Deep Learning prototype, based on the ResNet-50 architecture, for the automated classification of fauna at the Marco Zero *campus* of the Federal University of Amapá (UNIFAP), comparing it to the established DeepFaune and AddaxAI models. A total of 19,190 images were collected in an Amazonian urban environment. The prototype was implemented via the *Torch for R* ecosystem using fine-tuning techniques. Results revealed a global accuracy of 29.99% and a Kappa index of 0.0981 for the prototype, while the DeepFaune and AddaxAI models reached accuracy levels of ~65%. The analysis evidenced that the low performance stems from domain shift and the *Terra Incognita* effect, exacerbated by vegetation density and the loss of chromatic descriptors in nocturnal (infrared) records. In addition to the technological bias, the study identified significant anthropogenic pressure, with 16.68% of records consisting of domestic dogs (*Canis lupus familiaris*) and cats (*Felis catus*). It is concluded that, in the current scenario, the full automation of environmental surveillance at UNIFAP is unfeasible, and manual classification by specialists remains a mandatory and indispensable step to ensure data reliability, positioning artificial intelligence as a preliminary screening tool.

Keywords: animal monitoring; convolutional neural networks; One Health.

SUMÁRIO

| | |
|--|-----------|
| 1 INTRODUÇÃO..... | 10 |
| 2 REFERENCIAL TEÓRICO..... | 13 |
| 2.1 SAÚDE PÚBLICA E MEIO AMBIENTE..... | 13 |
| 2.2 INTELIGÊNCIA ARTIFICIAL COMO FERRAMENTA DE MONITORAMENTO | 14 |
| 2.3 VISÃO COMPUTACIONAL EM ECOLOGIA: O DESAFIO DO DESVIO DE DOMÍNIO.. | 16 |
| 2.4 PARADIGMAS ANÁLOGO E DIGITAL NO MONITORAMENTO DE FAUNA... | 17 |
| 3 OBJETIVOS..... | 19 |
| 3.1 OBJETIVO GERAL..... | 19 |
| 3.2 OBJETIVOS ESPECÍFICOS..... | 19 |
| 4 MATERIAL E MÉTODOS..... | 20 |
| 4.1 ÁREA DE ESTUDO..... | 20 |
| 4.2 COLETA DE DADOS..... | 20 |
| 4.3 CLASSIFICAÇÃO MANUAL..... | 21 |
| 4.4 DESENVOLVIMENTO DO MODELO DE CLASSIFICAÇÃO..... | 22 |
| 4.4.1 Banco de dados..... | 22 |
| 4.4.2 Configuração e treinamento do classificador..... | 23 |
| 4.5 COMPARAÇÃO COM MODELOS DE REFERÊNCIA..... | 23 |
| 4.6 AVALIAÇÃO DE DESEMPENHO E ANÁLISE ESTATÍSTICA..... | 24 |
| 5 RESULTADOS E DISCUSSÕES..... | 25 |
| 6 CONCLUSÃO..... | 32 |
| REFERÊNCIAS..... | 33 |
| APÊNDICE..... | 38 |
| APÊNDICE A - CÓDIGO DE TREINAMENTO E VALIDAÇÃO..... | 38 |
| APÊNDICE B - MOSAICO DE FOTOS DAS INSTALAÇÕES DAS ARMADILHAS DE CÂMERA..... | 44 |
| APÊNDICE C - MOSAICO DE FOTOS DOS DADOS DAS ARMADILHAS DE CÂMERA.... | 45 |

1 INTRODUÇÃO

Fatores socioambientais contemporâneos têm promovido um aumento na interação entre seres humanos e animais em situação de rua. Entre esses animais, os cães (*Canis lupus familiaris*) e os gatos (*Felis catus*) são os mais vistos em áreas urbanas. Essa interação com os animais errantes manifesta-se em um complexo espectro de comportamentos que variam desde a aproximação até a dependência direta de recursos fornecidos por humanos, como oferta de alimentos e abrigo. Contudo, tais interações podem resultar em problemas de saúde pública, como as zoonoses.

As zoonoses são doenças infecciosas transmitidas naturalmente entre os animais e os seres humanos (OMS, 2020). Essas doenças ocorrem mais facilmente em áreas urbanas, onde o contato ser humano, animal e meio ambiente ocorre intimamente. Dessa maneira, a moderna abordagem da Saúde Única (SU), cujo princípio se baseia na qualidade de vida entre os ecossistemas é indissociável e interdependente (BRASIL, 2025a).

Tradicionalmente, o planejamento urbano tem foco no desenvolvimento de espaços para as necessidades humanas que são frequentemente ignoradas pela gestão da fauna ou tratando-a como uma externalidade a ser controlada (Baima, 2024). Dessa forma, os animais em situação de rua ao atuarem como reservatórios de patógenos e contaminantes do solo urbano, exemplificam a tríade da SU, onde se demonstra a necessidade da vigilância e manejo do planejamento urbano (Maia *et al.*, 2025).

Sob essa ótica, um planejamento urbano depende da coexistência equilibrada entre todas as espécies que o habitam para que haja a coexistência saudável. Para que isso ocorra, o monitoramento preciso das populações de animais errantes deixa de ser uma ferramenta reativa de controle e se torna um componente estratégico de um planejamento urbano inteligente (Von Essen; Allen, 2016).

A efetivação desse monitoramento estratégico esbarra na limitação do método tradicional de identificação visual, que são, em geral, de baixa escalabilidade, intensivos em mão de obra e suscetíveis a vieses do observador (Choo *et al.*, 2020). A superação desse gargalo metodológico é, portanto, um passo crucial para transformar o planejamento urbano em uma prática verdadeiramente informada por dados. É neste cenário que a Inteligência Artificial (IA) emerge como força para o avanço tecnológico do monitoramento de animais.

Atualmente, a convolução de imagem está cada vez mais avançada e diversos modelos de identificação de imagem foram criados para realizar essas análises, tais como o DeepFaune

(DF), que utiliza o Deep Learning (DL) para convolucionar imagens e extrair informações dela para identificar o que está presente na paisagem pelo classificador de imagem MegaDetector (MD).

O MD é um modelo de DL especializado na detecção de objetos em imagens de vida selvagem. Sua principal função é atuar como um filtro inicial, identificando e localizando a presença de animais e objetos, o que permite descartar automaticamente imagens vazias que costumam sobrecarregar os bancos de dados (Leorna; Brinkman, 2022). No ecossistema de ferramentas atuais, o MD serve de base para o DF, um software desenvolvido por pesquisadores franceses do *Centre National de la Recherche Scientifique* (CNRS) (Rigoudy *et al.*, 2023). Enquanto o MD localiza o objeto na paisagem, o DF utiliza Redes Neurais Convolucionais (RNC) para classificar qual espécie está presente, otimizando drasticamente o tempo de análise do pesquisador.

Além dessas ferramentas, a literatura aponta o surgimento de diversos outros modelos que auxiliam na supervisão de animais em áreas urbanas como: as arquiteturas de detecção em tempo real YOLO (*You Only Look Once*), e modelos de classificação de alto desempenho, como as famílias ResNet e EfficientNet; esses modelos podem ser adaptados para o monitoramento de fauna sinantrópica em áreas urbanas (Jiang *et al.*, 2022; Tan; Le, 2020).

Diante do exposto, este trabalho tem como propósito a busca de um modelo de convolução de imagem que utiliza do atual estado da arte da identificação por DL, para que auxilie no monitoramento das espécies presente nas áreas urbanas e melhore a saúde do ecossistema. Já que, por sua vez, a saúde humana, animal e ambiental estão intrinsecamente conectadas e são interdependentes (Soares, 2020). Um exemplo clássico ocorre quando a saúde da população animal negligenciada impacta diretamente a contaminação do ambiente e oferece risco de doenças para a população humana (Miranda, 2018).

No Brasil, enfrenta-se um significativo desafio da saúde pública relacionado às zoonoses, com uma média de 27.811 casos notificados anualmente entre 2007 e 2023 (BRASIL, 2025b). Nesse cenário, estudos apontam que a região norte do país se destaca negativamente, registrando a maior taxa de incidência, com 53,84 casos por 100 mil habitantes. O estado do Amapá figura como uma das áreas mais críticas, possuindo a segunda maior taxa de incidência do Brasil, com 76,86 casos por 100 mil habitantes (BRASIL, 2025b). Dessa forma, essa alta incidência pode ser atribuída a uma complexa interação de fatores socioeconômicos, ambientais e estruturais. Dentro desse meio, condições como vulnerabilidade social, as barreiras geográficas de acesso à saúde e transformações como

desmatamento, favorecem a proliferação de vetores. Essa análise é corroborada por pesquisas que apontam que a pobreza, a precariedade no saneamento básico e o contato constante com animais silvestres são os fatores que potencializam a disseminação dessas doenças (Soares; Aragão; Silva, 2024).

Diante da ineficácia do monitoramento manual, este estudo teve como objetivo investigar a eficácia das arquiteturas de redes neurais convolucionais na predição de animais de fauna sinantrópica em ambientes de transição urbano-florestal amazônico.

Para tanto, parte-se da hipótese de que o modelo desenvolvido apresentará uma taxa de acerto de forte em relação à classificação manual e um desempenho de acurácia próxima ou equivalente aos modelos consolidados na literatura, como o DeepFaune e o AddaxAI ao ser aplicado às particularidades ambientais do contexto amazônico.

2 REFERENCIAL TEÓRICO

2.1 SAÚDE PÚBLICA E MEIO AMBIENTE

A conexão entre os animais de rua e a saúde pública é demonstrada ao se analisar os helmintos zoonóticos como o *Ancylostoma spp.* e o *Toxocara canis* no ser humano como um hospedeiro acidental. As larvas desses parasitas no hospedeiro acidental não conseguem completar seu ciclo de vida e migram pelo corpo causando síndromes conhecidas como Larva Migrans (Santarém; Giuffrida; Zanin, 2004). Em outro caso, quando as larvas de *Ancylostoma spp.*, ao penetrarem na pele humana a partir do solo contaminado, causam a larva migrans cutânea, popularmente conhecida como “bicho geográfico” (Rodrigues; Ferreira; Souza, 2023). Esta condição é caracterizada por lesões serpiginosas na pele que geram coceira intensa, representando a zoonose parasitária de maior ocorrência em diversas regiões do Brasil (Galvão; Maciel; Assis, 2021).

Adicionalmente, de uma forma ainda mais grave, a ingestão acidental de ovos de *Toxocara canis* presentes no ambiente leva à toxocaríase humana. As larvas deste parasita podem migrar para os órgãos internos, causando a larva migrans visceral, um quadro sistêmico com sintomas como febre e hepatomegalia. Quando uma larva atinge o olho, pode causar a larva migrans ocular, um quadro clínico severo com risco de estrabismo, uveíte e até mesmo cegueira (Felix, 2020).

Dessa forma, o elo entre o animal portador e o ser humano é quase sempre estabelecido pelo ambiente, que atua como uma ponte de transmissão e reservatório para os agentes parasitários. O ciclo se inicia quando as larvas dos animais infectados são eliminadas por meio das fezes, onde milhares de ovos microscópicos de helmintos são depositados no solo. Contudo, esses ovos não são imediatamente infectantes; eles necessitam de um período de maturação no solo, que funciona como uma incubadora sob condições adequadas de umidade, temperatura e sombreamento. A notável resistência desses ovos, especialmente os de *Toxocara spp.*, permite que permaneçam viáveis no ambiente por meses ou até anos, assim transformando praças, parques e caixas de areia em reservatórios de contaminação de longo prazo (Leite, 2013).

De forma geral, essa contaminação ocorre pela geofagia, que é a prática de comer substâncias terrestres. Comumente, essa prática ocorre em crianças assim, representando um dos principais padrões de comportamento que trazem risco à saúde; ações como essa facilitam a ingestão acidental dos ovos de helmintos (Peruca; Langoni; Lucheis, 2009). Continuamente,

o contato da pele com o solo permite a penetração ativa de larvas, como as da larva migrans cutânea. Este ciclo de transmissão ilustra perfeitamente a tríade da SU, onde a saúde do animal determina a contaminação do ambiente, que, por sua vez, se torna o veículo de infecção para o ser humano.

A alta frequência desses agentes em populações de animais errantes é amplamente documentada na literatura. Em cães, estudos demonstram elevada prevalência de *Toxocara canis* e *Ancylostoma caninum*, além de protozoários como a *Giardia spp.* (Dias *et al.*, 2023; Khan *et al.*, 2020; Ugalde *et al.*, 2023). De forma similar, outra perspectiva mostra que parasitas como *Ancylostoma spp.*, *Toxocara spp.* e *Giardia spp.* são frequentemente detectados em gatos errantes. (Rodrigues; Ferreira; Souza, 2023; Silva *et al.*, 2023).

2.2 INTELIGÊNCIA ARTIFICIAL COMO FERRAMENTA DE MONITORAMENTO

Contextualmente, a jornada da IA iniciou-se formalmente em meados do século XX, através de marcos teóricos como o Teste de Turing e a conferência de Dartmouth em 1956, onde o termo IA foi criado (Barbosa; Bezerra, 2021). A trajetória da área foi caracterizada por períodos de grande otimismo, seguido pelos invernos da IA, onde o progresso desacelerou devido a limitações computacionais e teóricas (Cozman; Neri, 2021).

No século XXI, testemunha-se um crescimento exponencial impulsionado pelo aumento massivo no volume de dados, pelo desenvolvimento de hardware e processamento paralelo, como as Unidades de Processamento Gráfico (GPU), que trouxeram diversos avanços algorítmicos por ter milhões de unidades de processamento, diferente da Unidade Central de Processamento (CPU) que foi projetada para tarefas complexas sequenciais (Silva Neto; Bonacelli; Pacheco, 2020). Foi essa convergência de fatores que tornou viáveis as aplicações práticas de reconhecimento de padrões em imagens em larga escala com capacidade para o monitoramento de fauna por meio de visão computacional.

Através desse novo estilo de processamento utilizando as GPUs, a IA consolidou-se como uma das mais transformadoras áreas da ciência da computação contemporânea, redefinindo as fronteiras da tecnologia e suas aplicações em múltiplos domínios, desde a indústria 4.0 até a pesquisa acadêmica. Sua capacidade de processar vastas quantidades de dados e identificar padrões complexos permitiu avanços que antes eram considerados inatingíveis. No campo das ciências ambientais, a IA emerge como uma ferramenta de potencial imensurável, oferecendo novas metodologias para o monitoramento da

biodiversidade, análise de ecossistemas e gestão de recursos naturais (Castro; Vetorazo, 2025; Oliveira; Santos; Ferreira, 2024).

Dessa forma, entende-se como IA um campo da ciência da computação dedicado à criação de agentes inteligentes, que são sistemas capazes de perceber seu ambiente e executar ações para maximizar suas chances de sucesso em um determinado objetivo. A função dela é de executar processos de um dispositivo eletrônico que funcione e mimetize a complexidade da capacidade do pensamento humano (Barbosa; Portes, 2023).

A IA pode ser categorizada em duas vertentes: a IA Geral (Artificial General Intelligence), que busca replicar a totalidade da inteligência humana, e a IA Restrita (Narrow AI), que se concentra na execução de tarefas específicas com alta performance (Zohuri; Rahmani, 2023). O sistema de identificação de fauna é um exemplo de IA restrita, projetado com o propósito específico de classificar imagens de animais, demonstrando expertise em um domínio limitado, mas com alta precisão e eficiência.

Em seu cerne, estão os conceitos de algoritmo e modelo. Um algoritmo pode ser entendido como o procedimento ou a receita, um conjunto de regras e processos matemáticos utilizados para aprender a partir dos dados (Ludermir, 2021). Por sua vez, o modelo é o resultado desse processo de aprendizagem; é a estrutura de dados e parâmetros que encapsula o conhecimento adquirido e replicado a qualquer momento.

Por exemplo, em uma tarefa de classificação de imagens, o algoritmo de treinamento analisa milhares de fotos de cães e gatos para aprender a distingui-los, e o modelo resultante é o artefato computacional que pode, efetivamente, receber uma nova imagem e classificá-la como "cão" ou "gato" (Bezerra, 2016). A escolha do algoritmo correto é fundamental para a construção de um modelo robusto e preciso.

A IA abrange diversas abordagens, sendo o *Machine learning* (ML), uma das mais proeminentes. Em vez de ser explicitamente programado, um sistema de ML utiliza algoritmos para analisar dados, aprender com eles e, então, fazer uma determinação ou predição sobre algo (Bezerra, 2016).

Dentro do ML, surgiu o *deep learning* (DL), uma subárea inspirada na estrutura e função do cérebro humano através de redes neurais artificiais com múltiplas camadas, conhecidas como redes neurais profundas. A principal vantagem do DL, especialmente para tarefas de visão computacional, é sua capacidade de aprender automaticamente representações hierárquicas de dados (Hosaki; Ribeiro, 2021).

Em uma tarefa de identificação de animais, as primeiras camadas da rede podem aprender a reconhecer características simples, como bordas e cores, enquanto camadas mais profundas aprendem a compor essas características para identificar partes complexas, como olhos, orelhas e, finalmente, o animal inteiro (Norouzzadeh *et al.*, 2018). Esta capacidade torna o Deep Learning a abordagem estado da arte para o desenvolvimento de identificadores de fauna baseados em imagens.

O otimismo e o rápido avanço da IA na última década não são infundados. O surgimento deles é uma consequência direta da união de três elementos-chave: o acesso a vastas quantidades de dados (Big Data), a evolução do hardware de processamento de alto desempenho, notadamente as GPUs, e os progressos nos algoritmos de *Deep Learning*. (Sichman, 2021). Esse processo democratizou o acesso a tecnologias de IA poderosas, permitindo que pesquisadores e cientistas ambientais desenvolvam soluções sofisticadas para problemas complexos.

A viabilidade de criar um identificador de fauna preciso e automatizado, é um reflexo direto desse momento tecnológico que a sociedade está passando, transformando uma tarefa que antes exigiria intensa mão de obra manual em um processo escalável e eficiente, com potencial para revolucionar o monitoramento ambiental e o planejamento urbano.

2.3 VISÃO COMPUTACIONAL EM ECOLOGIA: O DESAFIO DO DESVIO DE DOMÍNIO

A aplicação de RNC na identificação de fauna enfrenta um obstáculo teórico crítico conhecido como Desvio de Domínio (*Domain Shift*). Este fenômeno ocorre quando a distribuição estatística de treino difere significativamente dos dados encontrados no ambiente real de aplicação, resultando numa queda drástica de performance do classificador (Tabak *et al.*, 2019). Segundo Weinstein (2018), esta lacuna entre aprendizado e aplicação real é um dos maiores entraves à autonomia total dos sistemas de monitorização biológica.

A problemática é aprofundada pelo efeito *Terra incognita*, descrito por Beery; Van Horn; Perona (2018). Os autores demonstram que as RNCs tendem a memorizar correlações espúrias entre o animal e o fundo estático das imagens. Desta forma, o modelo não aprende apenas a morfologia da espécie, mas sim o cenário onde ela está inserida. Quando este modelo é levado para um novo local com padrões de solo e vegetações distintas, como o *campus* da

UNIFAP, a rede falha em generalizar o conhecimento, pois o fundo já não corresponde ao padrão aprendido durante o treino.

Além disso, a complexidade estrutural das florestas tropicais impõe desafios adicionais que bases de dados curadas na internet ou em outras paisagens não contemplam. Whytock et al. (2021) salientam que a densidade de vegetação, as variações de luminosidade sob o dossel e a frequente oclusão parcial dos espécimes dificulta a extração de características essenciais pela arquitetura ResNet. Enquanto modelos treinados em ambientes controlados priorizam imagens de animais centralizados em destaque, os dados de armadilhas fotográficas reais frequentemente registram apenas fragmentos do animal em movimento, exacerbando a taxa de falsos negativos (Schneider *et al.*, 2018).

Desta forma, a literatura indica que a baixa acurácia em novos domínios não é necessariamente um erro de execução técnica, mas uma evidência da sensibilidade dos algoritmos a mudança de contexto ambiental. Como apontado por Torney et al. (2019), a transição de modelos de IA para ecossistemas complexos exige um processo de adaptação de domínio ou um volume massivo de dados locais, sem os quais a promessa de IA esbarra na realidade da variabilidade biológica e geográfica.

2.4 PARADIGMAS ANÁLOGO E DIGITAL NO MONITORAMENTO DE FAUNA

O monitoramento de populações faunísticas é uma pedra angular para a pesquisa em ecologia e para a formulação de estratégias de conservação. Tradicionalmente, esse monitoramento dependia de métodos diretos, muitas vezes invasivos e de alto custo (Silveira; Jácomo; Diniz-Filho, 2003). Contudo, o avanço de tecnologias de sensoriamento remoto, como as armadilhas fotográficas, revolucionou a coleta de dados em campo, gerando um volume de informação sem precedentes (Burton *et al.*, 2015).

As armadilhas fotográficas consolidaram-se como um dos principais métodos não invasivos para o estudo da fauna silvestre e urbana. Estes dispositivos, equipados com sensores de movimento e infravermelho, permitem o registro contínuo de animais em seus habitats com mínima perturbação (Wearn; Paul, 2017). A aplicação dessa tecnologia possibilitou avanços significativos no conhecimento sobre a distribuição de espécies, padrões de atividade nictemeral, comportamento e interações ecológicas.

Os dados obtidos por essa ferramenta são fundamentais para a aplicação de modelos de ocupação, estimativas de densidade populacional e estudos sobre a ecologia de paisagens

(Burton *et al.*, 2015). O sucesso e a popularização do método, contudo, resultaram em um desafio analítico: o processamento de bancos de dados que frequentemente contêm milhões de registros fotográficos, exigindo uma capacidade de análise que ultrapassa a viabilidade do processamento manual (Norouzzadeh *et al.*, 2018).

O método de classificação analógico, ou manual, consiste na inspeção visual de cada imagem por um pesquisador, que realiza a triagem e a identificação das espécies registradas. Embora permita uma análise detalhada para interpretar comportamentos complexos ou identificar indivíduos com marcas naturais, sua aplicação em larga escala é limitada por ser um processo extremamente intensivo em tempo e recursos humanos, representando o principal gargalo em projetos de monitoramento (Norouzzadeh *et al.*, 2018). Além da baixa escalabilidade, a classificação humana está sujeita a vieses e fadiga acumulada, o que pode introduzir erros sistemáticos e comprometer a robustez das análises estatísticas e a subsequente tomada de decisão em manejo (Johansson *et al.*, 2020).

Para superar esses desafios, a comunidade científica tem consolidado o uso de métodos automáticos baseados em DL, notadamente nas RNCs. Conforme demonstrado por Norouzzadeh *et al.* (2018) e Tabak *et al.* (2019), esses sistemas processam fluxos massivos de imagens de forma autônoma e padronizada, aprendendo a extrair características visuais que distinguem uma espécie da outra com alta precisão (Krizhevsky; Sutskever; Hinton, 2017). Na prática, o identificador automatizado atua como um sistema que recebe imagens brutas e retorna classificações precisas (ex: "cão", "gato" ou "vazio"), acelerando drasticamente a triagem e garantindo um nível de objetividade inalcançável pela análise humana.

3 OBJETIVOS

3.1 OBJETIVO GERAL

Desenvolver e avaliar o desempenho de um modelo de aprendizagem profundo, baseado na arquitetura ResNet-50 para a classificação automatizada de cães e gatos errantes, utilizando registros de armadilhas fotográficas coletadas no Campus Marco Zero da Universidade Federal do Amapá.

3.2 OBJETIVOS ESPECÍFICOS

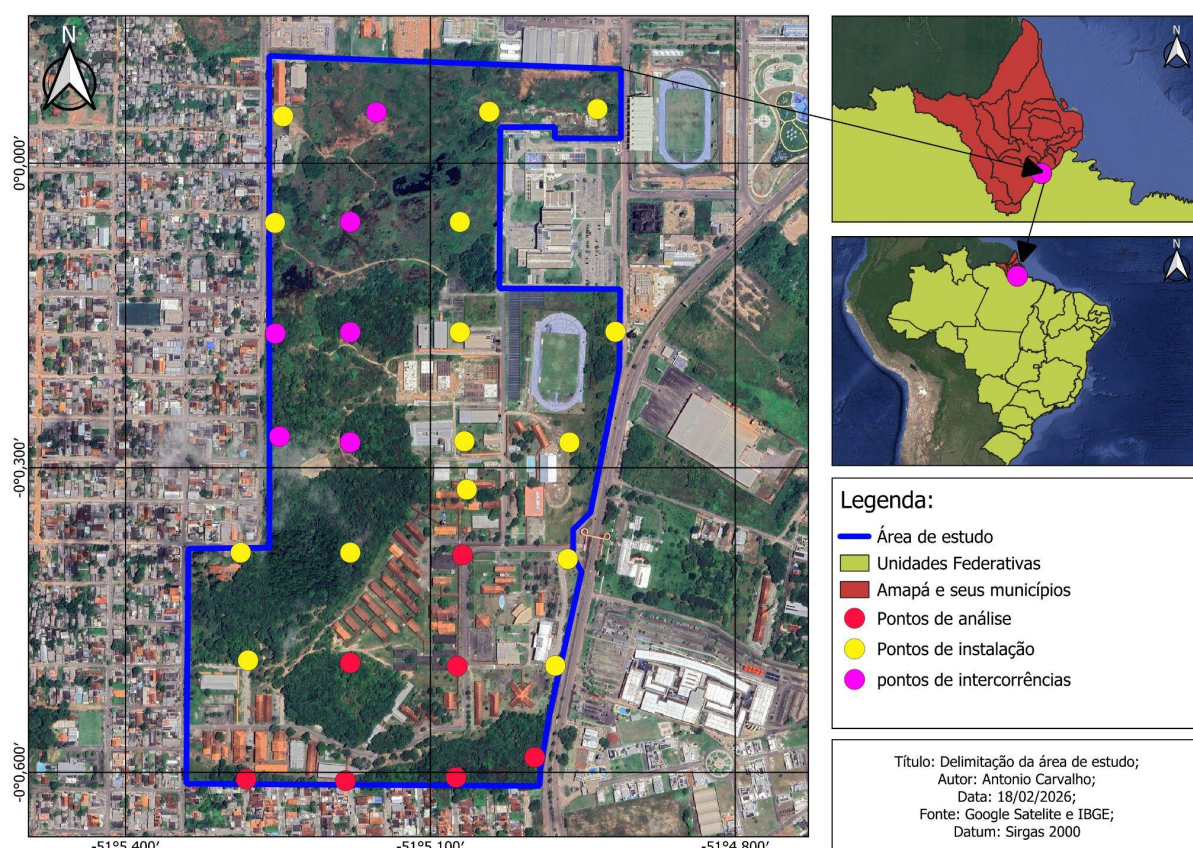
- Estruturar um banco de dados diversificado composto por imagens de repositórios públicos e registros locais, padronizando-os para o treinamento de um classificador de 8 classes.
- Implementar o ajuste fino (*fine-tuning*) na arquitetura ResNet-50 por meio do ecossistema *Torch for R*, otimizando os parâmetros do modelo para a realidade ambiental do Campus Marco Zero da UNIFAP.
- Comparar o desempenho do protótipo desenvolvido em relação aos modelos consolidados DeepFaune e AddaxAI, utilizando métricas de acurácia, índice *kappa*, *F1-Score*, além da aplicação do Teste de McNemar para comparação estatística entre os modelos.
- Analisar a aplicabilidade do monitoramento automatizado como ferramenta de vigilância em Saúde Única, com foco na dinâmica populacional de cães e gatos em áreas de transição urbano-rural.

4 MATERIAL E MÉTODOS

4.1 ÁREA DE ESTUDO

O estudo foi conduzido no *campus* Marco Zero da Universidade Federal do Amapá (UNIFAP), localizado na zona sul do município de Macapá, AP (Mapa 1). A área de estudo situa-se em uma zona urbana, caracterizando-se por uma matriz de paisagem heterogênea que integra fragmentos de floresta tropical, áreas de solo exposto e estruturas urbanas. Devido a essa composição, o *campus* universitário atua como um espelho da transição urbana da cidade, favorecendo a interação entre fauna silvestre e doméstica.

Mapa 1. Delimitação da área de estudo com a localização de armadilhas no Campus Marco Zero da UNIFAP com pontos de instalação, análise e intercorrências.



Fonte: O autor (2026).

4.2 COLETA DE DADOS

A amostragem foi realizada por meio de 14 armadilhas fotográficas, cujos pontos foram distribuídos de forma uniforme pela área de estudo. Essa estratégia visou garantir que

as capturas fossem espacialmente homogêneas, permitindo a normalização dos dados e assegurando que a amostragem fosse representativa de todo o território. Esses pontos integram o esforço amostral completo durante o cronograma de 60 dias de monitoramento contínuo por ponto, totalizando 840 armadilhas-dia de captura. Contudo, durante a execução do projeto, intercorrências em campo resultaram na perda de seis armadilhas: 3 unidades foram danificadas por incêndios na vegetação local no período de estiagem, 2 unidades foram subtraídas por furto e 1 apresentou arquivos corrompidos. Consequentemente, o esforço amostral efetivo foi reajustado para as análises subsequentes (480 armadilhas-dia).

Os dispositivos utilizados foram das marcas Bushnell Aggressor e Mini 301, configurados para operar ininterruptamente e acionados por sensores passivos de movimento e calor (PIR). A cada detecção, as câmeras foram programadas para registrar uma sequência de três imagens, com um intervalo de 15 segundos entre disparos sucessivos. Durante o período de amostragem, os equipamentos passaram por manutenções periódicas semanais, que incluíram limpeza, troca de baterias e substituição dos cartões de memória, conforme a necessidade.

Por se tratar de um método de amostragem não invasivo, sem contato direto com os animais e sem a identificação de seres humanos nas imagens, este estudo não exigiu submissão ao comitê de ética. O protocolo de captura priorizou a preservação da anonimidade dos transeuntes e a observação indireta da fauna.

4.3 CLASSIFICAÇÃO MANUAL

A classificação manual das imagens foi realizada através do software *Timelapse* (v. 2.5.0.1). Para a estruturação do banco de dados, definiu-se um conjunto de variáveis categóricas (booleanas) e quantitativas. As variáveis booleanas registraram a presença ou ausência de: (a) Fauna / presença geral; (b) cão doméstico; (c) gato doméstico; (d) humano; e (e) veículos. para a análise quantitativa e de qualidade, foram adotadas as seguintes métricas: abundância: Contagem individual de cães e gatos por registro. Qualidade da imagem: com escala de valores de 1 a 5, sendo 1 para imagens com severa perda de foco ou ruído, e 5 para alta definição. Qualidade do objeto: com escala de valores de 1 a 5, avaliando a visibilidade da espécie, sendo 1 para animais cortados ou com desfoque de movimento e 5 para animais inteiramente visíveis e nítidos.

4.4 DESENVOLVIMENTO DO MODELO DE CLASSIFICAÇÃO

O modelo de classificação foi implementado na linguagem R (v. 4.5.2), utilizando o ambiente de desenvolvimento integral RStudio (v. 2025.09.2, Posit Software, PBC). A arquitetura computacional baseou-se no ecossistema *Torch for R*, com o auxílio dos pacotes *Torch*, *Torch Vision* para processamento de visão computacional e *Magick* para manipulação avançada de imagens.

Neste estudo optou-se pela arquitetura ResNet-50 (*Residual Network*), selecionada por sua eficiência em mitigar o problema do gradiente evanescente através de conexões residuais, permitindo um aprendizado profundo com 50 camadas neurais. O método empregado foi o ajuste fino, onde pesos pré-treinados no conjunto de dados *imageNet* foram adaptados para a realidade deste estudo.

Adicionalmente, utilizou-se a inteligência artificial generativa Gemini (Google) como ferramenta de suporte à programação, auxiliando na otimização de scripts e na automação de rotinas de pré-processamento de dados.

4.4.1 Banco de dados

Para o processamento dos dados para o treinamento, foram extraídas de repositórios da comunidade Kaggle, sendo elas: (a) *200 bird species with 11,788 images* (Ailurophile, 2020); (b) *Cat and Dog* (Schubert, 2018); (c) *Car and Bike* (DeepNets, 2023); (d) *Human Detection Dataset* (Konstantin Verner, 2022); (e) *Rodents* (Itunu, 2025); (f) *Human dataset* (Elmenshawii, 2024). Optou-se pelo uso de bancos de dados exógenos (Kaggle) para o treinamento devido à escassez inicial de dados rotulados locais, assumindo-se o risco de enviesamento por divergência de domínio visual. Foi utilizado um banco de dados próprio de imagens da paisagem da UNIFAP com as imagens das armadilhas de câmera para construir a classe fundo.

Todas as imagens foram padronizadas com a resolução de 224x224 pixels, com três canais de cor (Vermelho, verde e azul). O modelo foi treinado para a distinção de oito classes: (a) cão; (b) gato; (c) humano; (d) carro; (e) moto ; (f) pássaro; (g) roedores; e (h) fundo.

No desenho experimental para cada classe, utilizou-se um conjunto de 4.000 imagens, totalizando 32.000 amostras. A base de dados foi dividida aleatoriamente em duas frações:

80% para treinamento e 20% para validação, permitindo o monitoramento de acurácia e a prevenção de sobreajuste (*overfitting*) durante o processo.

4.4.2 Configuração e treinamento do classificador

Para assegurar a reprodutibilidade rigorosa do experimento, estabeleceu-se a semente aleatória (*seed*) 19, aplicada de forma consistente tanto ao ambiente global do software R quanto às operações internas do pacote *torch* (Falbel; Luraschi, 2025). Antes do início do treinamento, as imagens foram submetidas a um pré-processamento robusto por meio de uma sequência de transformações que garantiu a conversão para o espaço de cores RGB e o redimensionamento obrigatório para a dimensão de 224x224 pixels, padrão exigido pela arquitetura ResNet-50 (He et al., 2016). Adicionalmente, aplicou-se a normalização dos tensores utilizando a média [0.485, 0.456, 0.406] e o desvio padrão [0.229, 0.224, 0.225], alinhando os dados de entrada com os parâmetros da base *ImageNet* (Russakovsky et al., 2015). O conjunto de treinamento foi submetido a um embaralhamento (*shuffling*) sistemático a cada época para mitigar o viés de ordem e prevenir o *overfitting*, enquanto o conjunto de validação permaneceu estático para servir como gabarito de desempenho e generalização.

O processo de otimização foi conduzido através do algoritmo Adam (*Adaptive Moment Estimation*), configurado com uma taxa de aprendizado fixa de 0,001. O treinamento utilizou um tamanho de lote de 16 imagens, valor selecionado para equilibrar a estabilidade do gradiente com os limites de memória computacional do ambiente de execução. Como função de custo, aplicou-se a Entropia Cruzada, métrica fundamental para problemas de classificação multi classe que quantifica a discrepância entre as probabilidades previstas e os rótulos reais. A estratégia baseou-se em ajuste fino, onde os pesos originais da ResNet-50 foram congelados, permitindo que apenas a nova camada linear de saída, ajustada para as 8 classes do estudo, fosse submetida ao ajuste fino. O modelo foi executado ao longo de 10 épocas de treinamento, permitindo o ajuste iterativo dos pesos sinápticos e a estabilização da perda.

4.5 COMPARAÇÃO COM MODELOS DE REFERÊNCIA

Para fins de validação, as imagens obtidas foram submetidas a dois modelos consolidados na literatura: o DeepFaune e o AddaxAI. O DeepFaune, integrado ao

MegaDetector (v5), foi utilizado com um limiar de confiança (*threshold*) de 0,8. As predições foram compatibilizadas com o protótipo proposto agrupando "carro" e "motocicleta" como a classe veículos, e "micromammal" como equivalente a classe roedores. Complementarmente, utilizou-se o AddaxAI, que implementa o modelo SpeciesNet (Google), também sob um *threshold* de 0,8.

4.6 AVALIAÇÃO DE DESEMPENHO E ANÁLISE ESTATÍSTICA

Para a validação do desempenho dos modelos e comparação entre as predições automáticas e a classificação manual, foram aplicadas métricas de performance e testes estatísticos de concordância e significância. Para isso, foi calculada a Acurácia Global para determinar a taxa geral de acerto das predições. Em seguida, utilizou-se o Índice *Kappa de Cohen* visando mensurar o nível de concordância entre os modelos automáticos e o classificador humano, corrigindo a probabilidade de acertos ao acaso. Para uma análise detalhada do equilíbrio entre precisão e sensibilidade, utilizou-se o F1-Score (Ponderado); esta métrica permite obter a média harmônica entre os dois indicadores, ajustando o cálculo conforme a proporcionalidade de amostras em cada classe, garantindo equidade na avaliação de classes desbalanceadas.

A comparação pareada entre o classificador proposto e os modelos de referência (DeepFaune e AddaxAI) foi realizada por meio do Teste de McNemar, com o objetivo de determinar se as diferenças de performance são estatisticamente significativas ($p < 0,05$), focando especificamente nas divergências de erro entre os algoritmos. Por fim, os resultados foram compilados em Matrizes de Confusão, permitindo a identificação visual e diagnóstica das classes com maior índice de erro ou sobreposição taxonômica.

5 RESULTADOS E DISCUSSÕES

Das 14 armadilhas fotográficas inicialmente instaladas no *campus* Marco Zero da UNIFAP, oito unidades operaram plenamente durante o período amostral, totalizando, assim, 480 armadilhas-dia. No total, foram obtidas 19.190 imagens. A classificação manual revelou que a presença de cães e gatos domésticos soma um total de 16,68% da presença total das imagens (13,56% de cães e 3,12% de gatos), 16,08% de outras espécies, 4,30% de veículos, 21,45% das imagens são vazias. Por fim, 41,49% das imagens são compostas por humanos (Tabela 1).

Tabela 1 - Comparação entre classificação manual e predição por IA

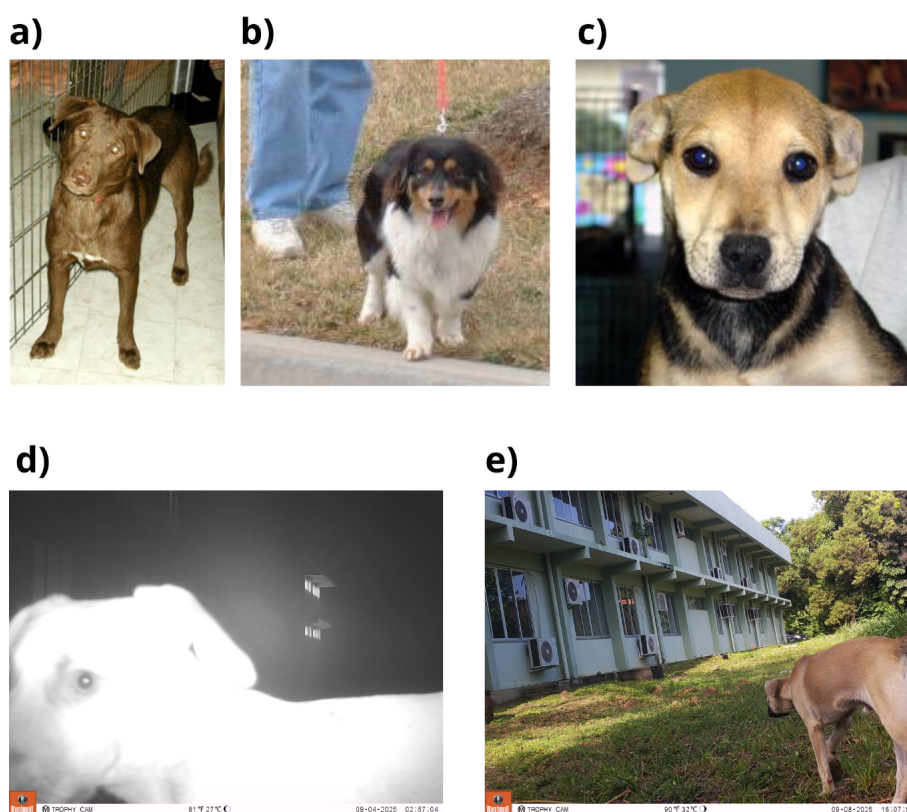
| Classe | Classificação manual | protótipo proposto | DeepFaune | AddaxAI (1) |
|---------|----------------------|--------------------|-----------|-------------|
| Cães | 2.603 | 439 | 2.719 | 965 |
| Gatos | 598 | 41 | 3.912 | 719 |
| Humanos | 7.962 | 1.544 | 6.503 | 11.215 |
| Outros | 3.085 | 429 | 558 | 6.709 |
| Vazio | 4.116 | 16.723 | 4.942 | 1.582 |
| Veículo | 826 | 14 | 556 | 642 |
| Total | 19.190 | 19.190 | 19.190 | 21.832 |

Fonte: O autor (2026).

Nota específica 1: A identificação realizada pelo software AddaxAI identifica diversas classes em uma única imagem, assim, aumentando a totalização dos dados em seus dados.

A acurácia global de 29,99% obtida pelo protótipo evidencia os desafios críticos de generalização do modelo frente à heterogeneidade da paisagem amazônica. Embora este valor supere o patamar do acaso estatístico que, em um cenário de classificação balanceada para oito classes, seria de 12,5%, o desempenho demonstra que o aprendizado de características foi insuficiente para uma aplicação autônoma robusta. Esse cenário é ratificado pelo índice Kappa de Cohen de 0,0981, que, segundo a escala de Landis e Koch (1977), classifica a concordância entre o modelo e o gabarito real como mínima ou discreta (Figura 1)

Figura 1. Demonstração de imagens de treinamento do banco de imagens do banco de dados da comunidade Kaggle (A, B e C) e da realidade do campo no *Campus* Universitário UNIFAP (D e E).



Fonte: Schubert (2018); O autor.

Este resultado confirma experimentalmente o efeito *Terra Incognita*: o modelo identifica elementos do cenário como se fossem parte da classe, perdendo sua capacidade preditiva ao ser confrontado com a vegetação densa e a iluminação variável do *campus* da UNIFAP (Beery; Van Horn; Perona, 2018). Portanto, o índice de ~30% não deve ser interpretado como uma falha de execução técnica, mas sim como a comprovação de que

modelos treinados em domínios genéricos sofrem um desvio de compreensão severo ao serem aplicados em ecossistemas tropicais de interface urbana.

Enquanto os grandes banco de dados convencionais priorizam imagens curadas com espécies estáticas, centralizadas e em ângulos favoráveis, os registros obtidos pelas armadilhas fotográficas apresentam animais em movimento, frequentemente fragmentados ou sob angulações atípicas. Essas variações morfológicas e de perspectiva, somadas ao ruído visual da vegetação densa, dificultam a extração de padrões essenciais pela rede neural, impactando o desempenho do classificador. Esse fenômeno é comum em implementações de redes residuais para fauna, onde a diversidade de poses no mundo real supera a variabilidade contida nos bancos de dados de treinamento (Norouzzadeh *et al.*, 2018).

Ao analisar a matriz de confusão do protótipo proposto, observa-se que o principal gargalo reside na alta taxa de falsos negativos (Figura 4). Por exemplo, 82% dos registros de humanos e 77% de cães foram incorretamente classificados como vazias (Figura 2).

Figura 2. Matriz de confusão do desempenho do protótipo na classificação das oito categorias de fauna e controle no *campus* Marco Zero.

Matriz de Confusão: Protótipo Proposto

| Classe Predita \ Classe Real | Humano | Cão | Gato | Veículo | Outro | Vazio |
|------------------------------|--------|------|------|---------|-------|-------|
| Humano | 1304 | 150 | 8 | 15 | 12 | 69 |
| Cão | 48 | 382 | 34 | 0 | 1 | 17 |
| Gato | 2 | 13 | 20 | 0 | 7 | 1 |
| Veículo | 2 | 0 | 0 | 12 | 0 | 0 |
| Outro | 79 | 33 | 29 | 29 | 179 | 93 |
| Vazio | 6598 | 1977 | 514 | 787 | 2917 | 3858 |

Fonte: O autor (2026)

Em contraste, o DeepFaune demonstrou alta sensibilidade para a fauna (Rigoudy *et al.*, 2023), embora tenha apresentado uma sobreposição diagnóstica entre as classes humano e gato (Figura 3).

Figura 3. Matriz de confusão do desempenho do *software* DeepFaune na classificação das categorias de fauna e controle no *campus* Marco Zero

Matriz de Confusão: DeepFaune

| Classe Preditá | Classe Real | | | | | |
|----------------|-------------|------|------|---------|-------|-------|
| | Humano | Cão | Gato | Veículo | Outro | Vazio |
| Humano | 6038 | 5 | 6 | 27 | 10 | 883 |
| Cão | 249 | 2400 | 11 | 13 | 23 | 296 |
| Gato | 877 | 22 | 566 | 281 | 1507 | 114 |
| Veículo | 157 | 0 | 0 | 264 | 3 | 115 |
| Outro | 26 | 26 | 6 | 3 | 483 | 76 |
| Vazio | 686 | 102 | 16 | 255 | 1090 | 2554 |

Fonte: O autor (2026)

Já o AddaxAI destacou-se pela consistência, apresentando a melhor distribuição de acertos entre as classes, o que justifica sua acurácia superior (Figura 4). Essas discrepâncias reforçam que, para o ambiente específico da UNIFAP, modelos genéricos pré-treinados com volumes massivos de dados (AddaxAI e DeepFaune) ainda superam o protótipo local na tarefa de separação entre objeto e plano de fundo por necessidade de banco de dados maior de imagens que representem a realidade da região.

Figura 4. Matriz de confusão do desempenho do *software* AddaxAI na classificação das categorias de fauna e controle no *campus* Marco Zero..

Matriz de Confusão: AddaxAI

| Classe Predita \ Classe Real | Humano | Cão | Gato | Veículo | Outro | Vazio |
|------------------------------|--------|------|------|---------|-------|-------|
| Humano | 5946 | 117 | 4 | 21 | 22 | 722 |
| Cão | 31 | 773 | 1 | 2 | 2 | 52 |
| Gato | 27 | 21 | 500 | 0 | 2 | 17 |
| Veículo | 98 | 6 | 0 | 260 | 4 | 14 |
| Outro | 933 | 535 | 36 | 288 | 1888 | 72 |
| Vazio | 998 | 1103 | 64 | 272 | 1198 | 3161 |

Fonte: O autor (2026)

Dessa forma, analisando a concordância entre o classificador automático e o classificador humano, descontando o acerto que ocorreria puramente ao acaso. O protótipo proposto obteve um Kappa de 0,0981. Segundo os critérios de Landis e Koch (1977), este valor representa uma concordância quase inexistente, o que indica que a baixa acurácia do protótipo é fruto de uma dificuldade sistemática em distinguir o objeto do fundo, e não de erros aleatórios. Em contrapartida, o DeepFaune (0,5302) e o AddaxAI (0,5289) apresentaram concordância moderada.

Essa disparidade indica que a baixa acurácia do protótipo decorre de uma dificuldade sistemática em distinguir o objeto do fundo, problema este que é severamente agravado pelas variações de luminosidade entre os períodos diurnos e noturnos. Enquanto as imagens diurnas oferecem descritores de cor e contraste nítidos, os registros noturnos, capturados via sensores infravermelhos em tons de cinza, eliminam informações cromáticas essenciais para a rede neural. Como o protótipo foi baseado em uma arquitetura ResNet-50 pré-treinada em bases de dados predominantemente diurnas e curadas, a ausência de cor e a alteração nas texturas durante a noite dificultam a extração de padrões morfológicos da fauna, aumentando a taxa de falsos negativos.

Portanto, a superioridade do DeepFaune e do AddaxAI sugere que esses modelos possuem maior familiaridade com a aparência noturna dos animais em infravermelho, enquanto o protótipo local ainda sofre com o desvio de expertise causado pelo ciclo

nictemeral. Essa limitação reforça que, para o monitoramento contínuo na UNIFAP, é indispensável o treinamento do algoritmo com volumes equilibrados de amostras diurnas e noturnas, permitindo que a IA aprenda a identificar silhuetas e padrões térmicos independentemente da iluminação disponível

O F1-score indica que o protótipo desenvolvido apresentou baixa capacidade de discriminar as classes morfológicas em relação ao fundo das imagens (0,2453). Em contraste, os modelos AddaxAI (0,65) e DeepFaune (0,64) demonstraram maior robustez na identificação das espécies. A elevada proporção de registros de animais domésticos (16,68%) sugere uma presença significativa de pressão antrópica no campus, potencialmente associada a impactos negativos sobre a biodiversidade local (Loss; Will; Marra, 2013).

A comparação estatística via Teste de McNemar revelou diferenças significativas entre todos os pares de modelos ($p < 0.00001$). A significância neste teste sugere que as superioridades observadas não decorrem de oscilações da amostra, mas de capacidades distintas de interpretação (Dietterich, 1998). Mesmo entre os modelos performáticos, a divergência em 7.514 imagens demonstra que os algoritmos utilizam extração de características distintas para interpretar a fauna da UNIFAP, sugerindo que a complexidade do ambiente amazônico impõe limites mesmo a tecnologias globais.

A presença expressiva de cães e gatos domésticos no *campus* (16,68% dos registros) reflete uma problemática socioambiental crônica em instituições de ensino brasileiras. Como discutido por Serrano e Almeida (2019), a vasta extensão territorial e o fluxo constante de pessoas transformam os *campi* universitários em pontos críticos de descarte e abandono de animais. Além do viés tecnológico, essa predominância evidencia um cenário de desequilíbrio ecológico no *campus* Marco Zero, onde a constante presença de animais domésticos impõe um risco direto à fauna nativa identificadas neste estudo sob a classe “outros” (16,08%). Segundo Campos (2004), a circulação dessas espécies exóticas em áreas de interface urbana é um dos principais fatores de pressão sobre a biodiversidade local.

Nesse cenário, observa-se que esses animais frequentemente encontram-se camuflados pela matriz de solo exposto e vegetação rasteira da universidade. Portanto, o gargalo de acurácia de 29,99% do protótipo não representa apenas um limite computacional, mas um reflexo da própria complexidade biológica de uma zona de interface urbana. A forma como a fauna exótica se integra à paisagem amazônica desafia tanto a detecção por sensores infravermelhos quanto a classificação por redes neurais residuais, justificando a alta taxa de falsos negativos observada no modelo proposto.

Entretanto, a eficácia desta tecnologia como ferramenta de gestão é validada pelo desempenho superior dos modelos DeepFaune (64,12%) e AddaxAI (65,28%). A disparidade de resultados demonstra que, embora modelos globais já tenham consolidado que a IA pode monitorar ambientes urbanos, a automação plena na região depende da superação dos desafios de camuflagem e regionalização de dados. A integração dessas ferramentas permite que a gestão ambiental da UNIFAP converta o monitoramento passivo das armadilhas fotográficas em dados estruturados, otimizando programas de controle populacional e estratégias de conservação para mitigar os impactos sobre a fauna nativa em tempo real.

6 CONCLUSÃO

Esta pesquisa permitiu concluir que, no estágio atual de desenvolvimento tecnológico, a implementação de sistemas totalmente automatizados para o monitoramento de fauna no *campus* Marco Zero da UNIFAP é inviável, permanecendo a curadoria manual por especialistas como etapa fundamental para a validação dos dados. Os resultados demonstram que, embora o protótipo local tenha atingido uma acurácia de 29,99% e modelos consolidados como AddaxAI e DeepFaune tenham chegado a ~65%, esses valores estão significativamente abaixo do patamar de segurança (80-95%) necessário para a dispensa da curadoria técnica.

A baixa performance observada não é uma falha isolada de execução, mas uma evidência experimental de que o ambiente amazônico de interface urbana impõe desafios de desvio de domínio que as IAs globais ainda não conseguem transpor. O efeito *Terra Incognita*, agravado pela vegetação rasteira e pela transição para o monitoramento noturno em infravermelho, impede que os algoritmos operem com a precisão necessária para substituir o olhar humano. Portanto, a tecnologia de *Deep Learning* deve ser encarada, no contexto atual da UNIFAP, não como um substituto, mas como uma ferramenta de triagem preliminar que ainda exige curadoria humana integral para garantir a fidedignidade dos dados ecológicos.

Em suma, este estudo comprova que a complexidade biológica e visual da região exige a manutenção de protocolos de classificação manual. O valor científico deste trabalho reside em mapear esses limites e demonstrar que a viabilidade de automação futura em ecossistemas tropicais está condicionada ao desenvolvimento de bancos de dados locais robustos, capazes de contemplar as particularidades de camuflagem e luminosidade da fauna regional.

REFERÊNCIAS

- AILUROPHILE. **200 Bird Species with 11,788 Images**. Kaggle, , 2020. Disponível em: <<https://www.kaggle.com/datasets/veeralakrishna/200-bird-species-with-11788-images>>. Acesso em: 18 fev. 2026
- BAIMA, Stephanny Rayane Souza. Integração entre seres humanos e animais domesticáveis no planejamento urbano: uma análise no bairro J. Câmara, São José de Ribamar – MA. 2024. Monografia (Bacharelado em Arquitetura e Urbanismo). **Centro de Ciências Tecnológicas, Universidade Estadual do Maranhão**, São Luís, 2024. Disponível em: <https://repositorio.uema.br/handle/123456789/3884>. Acesso em: 23 mar. 2026.
- BARBOSA, Lucia Martins; PORTES, Luiza Alves Ferreira. A Inteligência Artificial. **Revista Tecnologia Educacional**, v. LII, p. 16–27, 2023.
- BARBOSA, Xênia de Castro; BEZERRA, Ruth Ferreira. BREVE INTRODUÇÃO À HISTÓRIA DA INTELIGÊNCIA ARTIFICIAL. **Jamaxi**, v. 4, n. 3, 2021.
- BEERY, Sara; VAN HORN, Grant; PERONA, Pietro. Recognition in Terra Incognita. *In*: FERRARI, Vittorio *et al.* (Orgs.). **Computer Vision – ECCV 2018**. Lecture Notes in Computer Science. Cham: Springer International Publishing, 2018. v. 11220 p. 472–489.
- BEZERRA, Eduardo. Introdução a aprendizagem profunda. *In*: **Tópicos em Gerenciamento de Dados e Informações**. 1. ed. [S.l.]: Ogasawara, Vaninha, 2016. p. 57–86.
- BRASIL. **Uma Só Saúde**. Governamental. Disponível em: <<https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/u/uma-so-saude>>. Acesso em: 13 set. 2025a.
- BRASIL. **Boletim Epidemiológico: Morbimortalidade por zoonoses no Brasil | 2007-2023**. Brasília/DF: Ministério da Saúde, 2025b. Disponível em: <<https://www.gov.br/saude/pt-br/centrais-de-conteudo/publicacoes/boletins/epidemiologicos/especiais/2025/boletim-epidemiologico-de-morbimortalidade-por-zoonoses-no-brasil-2007-2023-numero-especial-jul-2025.pdf>>.
- BURTON, A. Cole *et al.* REVIEW: Wildlife camera trapping: a review and recommendations for linking surveys to ecological processes. **Journal of Applied Ecology**, v. 52, n. 3, p. 675–685, 2015.
- CAMPOS, Claudia Bueno De. **Impacto de cães (Canis familiaris) e gatos (Felis catus) errantes sobre a fauna silvestre em ambiente peri-urbano**. Mestrado em Ecologia de Agroecossistemas—Piracicaba: Universidade de São Paulo, 17 dez. 2004.
- CASTRO, Claudia Pires de; VETORAZO, Helena. Inteligência artificial na pesquisa acadêmica: Transformação e conservação. *In*: **PESQUISAS EM HISTÓRIA, HUMANIDADES DIGITAIS E ENSINO: OUTROS TEMAS COMUNICACIONAIS E ABORDAGENS**. 1. ed. [S.l.]: Editora Schreiben, 2025. p. 84.
- CHOO, Yan Ru *et al.* Best practices for reporting individual identification using camera trap photographs. **Global Ecology and Conservation**, v. 24, p. e01294, 1 dez. 2020.

COZMAN, Favio G.; NERI, Hugo. O que, afinal, é Inteligência Artificial? *In: Inteligência Artificial: Avanços e Tendências*. São Paulo: Instituto de Estudos Avançados, 2021. p. 21–29.

DEEPNETS. **Car vs Bike Classification Dataset**. Kaggle, , 2023. Disponível em: <<https://www.kaggle.com/datasets/utkarshsaxenadn/car-vs-bike-classification-dataset>>. Acesso em: 18 fev. 2026

DIAS, Sara Maria Dantas da Nóbrega *et al.* *Brucella spp.* detection in blood, semen and vaginal swabs in dogs from the urban area of Cuiabá/MT, Brazil. **Ciência Rural**, v. 53, p. e20220455, 2023.

DIETTERICH, T. G. Approximate Statistical Tests for Comparing Supervised Classification Learning Algorithms. **Neural Computation**, v. 10, n. 7, p. 1895–1923, 15 set. 1998.

ELMENSII, Fares. Human Dataset. Kaggle, , 2024. Disponível em: <<https://www.kaggle.com/datasets/fareselmensii/human-dataset>>. Acesso em: 18 fev. 2026

FALBEL, Daniel; LURASCHI, Javier. torch: Tensors and Neural Networks with 'GPU' Acceleration. Versão 0.16.3. **mlverse**, 2025. Disponível em: <https://torch.mlverse.org/docs>. Acesso em: 23 mar. 2026.

FELIX, Dryellen Aparecida. *Toxocara spp.*, Larva migrans visceral e Saúde Pública: Revisão. **Pubvet**, v. 14, n. 12, 11 nov. 2020.

GALVÃO, Jonathan David Oliveira de Medeiros; MACIEL, Michelline do Vale; ASSIS, Diflúvia Santana Medeiros de. **Principais zoonoses causadas por parasitas intestinais de pequenos animais em praças públicas no Brasil: uma revisão de literatura**. Monografia de Especialização—Caicó: Universidade Federal do Rio Grande do Norte, 2021.

HE, Kaiming *et al.* Deep Residual Learning for Image Recognition. In: 2016 IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR). 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). jun. 2016. Disponível em: <<https://ieeexplore.ieee.org/document/7780459>>. Acesso em: 23 mar. 2026

HOSAKI, Gabriel Yuri Gabriel Yuri; RIBEIRO, Douglas Francisco. Deep learning: ensinando a aprender. v. 1, n. 3, 2021.

ITUNU, Olasehinde Olasehinde. **Rodents**. Kaggle, , 2025. Disponível em: <<https://www.kaggle.com/datasets/ojoolasehindeitunu/rodents>>. Acesso em: 18 fev. 2026

JIANG, Peiyuan *et al.* A Review of Yolo Algorithm Developments. **Procedia Computer Science**, The 8th International Conference on Information Technology and Quantitative Management (ITQM 2020 & 2021): Developing Global Digital Economy after COVID-19. v. 199, p. 1066–1073, 1 jan. 2022.

JOHANSSON, Örjan *et al.* Identification errors in camera-trap studies result in systematic population overestimation. **Scientific Reports**, 2020.

KHAN, W. *et al.* Gastrointestinal helminths in dog feces surrounding suburban areas of Lower Dir district, Pakistan: A public health threat. **Brazilian Journal of Biology**, v. 80, p. 511–517, 2020.

KONSTANTIN VERNER. **Human Detection Dataset**. Kaggle, , 2022. Disponível em: <<https://www.kaggle.com/datasets/constantinwerner/human-detection-dataset>>. Acesso em: 18 fev. 2026

KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey E. ImageNet classification with deep convolutional neural networks. **Communications of the ACM**, v. 60, n. 6, p. 84–90, 24 maio 2017.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159–174, mar. 1977.

LEITE, Luiz Carlos. Ocorrência de ovos de endoparasitas em amostras de fezes de cães (*Canis familiaris*, Linnaeus, 1758) coletadas em vias públicas da cidade de Guarapuava - Paraná - Brasil. v. 9, p. 619–626, 2013.

LEORNA, Scott; BRINKMAN, Todd. Human vs. machine: Detecting wildlife in camera trap images. **Ecological Informatics**, v. 72, p. 101876, 1 dez. 2022.

LOSS, Scott R.; WILL, Tom; MARRA, Peter P. The impact of free-ranging domestic cats on wildlife of the United States. **Nature Communications**, v. 4, n. 1, p. 1396, 29 jan. 2013.

LUDERMIR, Teresa Bernarda. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. **Estudos Avançados**, v. 35, p. 85–94, 2021.

MAIA, Júlia Soares Dinelli *et al.* Cuidado com Zoonoses em Cães e Gatos: Papel do SUS na Prevenção e Educação em Saúde. **Revista Pró-UniverSUS**, v. 16, n. 2, p. 34–37, 19 jul. 2025.

MIRANDA, Michele. A CONTRIBUIÇÃO DO MÉDICO VETERINÁRIO A SAÚDE ÚNICA- ONE HEALTH. **Psicologia e Saúde em debate**, v. 4, n. Suppl1, p. 34–34, 11 dez. 2018.

NOROUZZADEH, Mohammad Sadegh *et al.* Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning. **Proceedings of the National Academy of Sciences**, v. 115, n. 25, p. E5716–E5725, 19 jun. 2018.

OLIVEIRA, Paloma Viary Santana de; SANTOS, Laiza de Freitas; FERREIRA, Moacir Porto. Inteligência artificial na automação de processos industriais e seus impactos. **Revista de Economia Mackenzie**, v. 21, n. 1, p. 162–182, 18 jun. 2024.

OMS. **Zoonoses**. Disponível em: <<https://www.who.int/news-room/fact-sheets/detail/zoonoses>>. Acesso em: 13 set. 2025.

PERUCA, Luciana Cristina Baldini; LANGONI, Helio; LUCHEIS, Simone Baldini. LARVA MIGRANS VISCERAL E CUTÂNEA COMO ZOONOSES: REVISÃO DE LITERATURA. **Veterinária e Zootecnia**, v. 16, n. 4, p. 601–616, 2009.

RIGOUDY, Noa *et al.* The DeepFaune initiative: a collaborative effort towards the automatic identification of European fauna in camera trap images. **European Journal of Wildlife Research**, v. 69, n. 6, p. 113, 20 out. 2023.

RODRIGUES, Sarah Beatriz Ferreira; FERREIRA, Beatriz Ribeiro; SOUZA, Nêuton da Silva. PREVALÊNCIA DA DOENÇA DO BICHO-GEOGRÁFICO OCASIONADA PELA LARVA MIGRANS CUTÂNEA EM TRABALHADORES DA ZONA LITORÂNEA DA CAPITAL DE SÃO LUÍS MARANHÃO, BRASIL. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 9, n. 3, p. 148–158, 31 mar. 2023.

RUSSAKOVSKY, Olga *et al.* ImageNet Large Scale Visual Recognition Challenge. **International Journal of Computer Vision**, v. 115, n. 3, p. 211–252, dez. 2015.

SANTARÉM, Vamilton Alvares; GIUFFRIDA, Rogério; ZANIN, Gabriel Arantes. Larva migrans cutânea: ocorrência de casos humanos e identificação de larvas de *Ancylostoma* spp em parque público do município de Taciba, São Paulo. **Revista da Sociedade Brasileira de Medicina Tropical**, v. 37, p. 179–181, 2004.

SCHNEIDER, Stefan; TAYLOR, Graham W.; KREMER, Stefan. Deep Learning Object Detection Methods for Ecological Camera Trap Data. In: 2018 15TH CONFERENCE ON COMPUTER AND ROBOT VISION (CRV). 2018 15th Conference on Computer and Robot Vision (CRV). maio 2018. Disponível em:

<<https://ieeexplore.ieee.org/abstract/document/8575770>>. Acesso em: 17 jan. 2026

SCHUBERT, SchubertSly. **Cat and Dog**. Kaggle, , 2018. Disponível em:

<<https://www.kaggle.com/datasets/tongpython/cat-and-dog>>. Acesso em: 18 fev. 2026

SERRANO, Gean Phillipe Joaquim; ALMEIDA, Juliana Ferreira de. Cães e gatos abandonados em campi universitários / Abandoned dogs and cats on college campuses. **Brazilian Journal of Animal and Environmental Research**, v. 2, n. 4, p. 1242–1250, 1 ago. 2019.

SICHMAN, Jaime Simão. Inteligência Artificial e sociedade: avanços e riscos. **Estudos Avançados**, v. 35, n. 101, p. 37–50, abr. 2021.

SILVA NETO, Victo José da; BONACELLI, Maria Beatriz Machado; PACHECO, Carlos Américo. O Sistema Tecnológico Digital: inteligência artificial, computação em nuvem e Big Data. **Revista Brasileira de Inovação**, v. 19, p. e0200024, 2020.

SILVA, Welitânia Inácia *et al.* Endoparasites in domestic cats (*Felis catus*) in the semi-arid region of Northeast Brazil. **Revista Brasileira de Parasitologia Veterinária**, v. 32, p. e012123, 2023.

SILVEIRA, Leandro; JÁCOMO, Anah T. A.; DINIZ-FILHO, José Alexandre F. Camera trap, line transect census and track surveys: a comparative evaluation. **Biological Conservation**, v. 114, n. 3, p. 351–355, 1 dez. 2003.

SOARES, Brenno Kadalora Ferreira; ARAGÃO, Paloma Evely Nunes de; SILVA, Elís Rosélia Dutra de Freitas Siqueira. Análise de Doenças Zoonóticas no Brasil Utilizando Dados do Datasus. **Revista Saúde em Foco**, v. 11, n. 1, p. 03/20, 2024.

SOARES, Thiago Ferreira. Meio Ambiente e Saúde Única: o que podemos esperar? **Revista Brasileira de Meio Ambiente**, v. 8, n. 4, 10 set. 2020.

TABAK, Michael 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, abr. 2019.

TAN, Mingxing; LE, Quoc V. **EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks**. arXiv, , 11 set. 2020. Disponível em: <<http://arxiv.org/abs/1905.11946>>. Acesso em: 14 fev. 2026

TORNEY, Colin J. *et al.* A comparison of deep learning and citizen science techniques for counting wildlife in aerial survey images. **Methods in Ecology and Evolution**, v. 10, n. 6, p. 779–787, jun. 2019.

UGALDE, J. M. *et al.* Parasitological diagnosis of fecal samples from domestic dogs from the municipality of Niterói, Rio de Janeiro, Brazil. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, v. 75, p. 35–40, 2023.

VON ESSEN, Erica; ALLEN, Michael P. A Rabble in the Zoopolis? Considering Responsibilities for Wildlife Hybrids. **Journal of Social Philosophy**, v. 47, n. 2, p. 171–187, jun. 2016.

WEARN, Oliver; PAUL, Glover-Kapfer. **Camera-trapping for conservation: a guide to best-practices**. [*S.l.*]: World Wide Fund for Nature, 2017.

WEINSTEIN, Ben G. A computer vision for animal ecology. **Journal of Animal Ecology**, v. 87, n. 3, p. 533–545, maio 2018.

WHYTOCK, Robin C. *et al.* Robust ecological analysis of camera trap data labelled by a machine learning model. **Methods in Ecology and Evolution**, v. 12, n. 6, p. 1080–1092, jun. 2021.

ZOHURI, Bahman; RAHMANI, Farhang Mossavar. Artificial General Intelligence (AGI) Unleashing The Power of Artificial General Intelligence: OpenAI's Pursuit of Generative AI. **Lupine Publishers**, 16 out. 2023.

APÊNDICE

APÊNDICE A - CÓDIGO DE TREINAMENTO E VALIDAÇÃO

```
# Treinamento -----
```

```
library(torch)
```

```
library(torchvision)
```

```
library(magick)
```

```
device <- 'cpu'
```

```
set.seed(19)
```

```
torch_manual_seed(19)
```

```
caminho_treino <- "D:/Universidade/TCC/dataset3/train"
```

```
caminho_valid <- "D:/Universidade/TCC/dataset3/valid"
```

```
loader_leitura <- function(path) {
```

```
  img <- tryCatch({
```

```
    magick::image_read(path)
```

```
  }, error = function(e) {
```

```
    return(magick::image_blank(224, 224, "black"))
```

```
  })
```

```
  if (length(img) > 1) { img <- img[1] }
```

```
  img <- magick::image_convert(img, colorspace = "rgb")
```

```
  return(img)
```

```
}
```

```
pipeline_processamento <- function(img) {
```

```
  img %>%
```

```
    transform_to_tensor() %>%
```

```
    transform_resize(size = c(224, 224)) %>%
```

```

transform_normalize(
  mean = c(0.485, 0.456, 0.406),
  std = c(0.229, 0.224, 0.225)
)
}

full_ds <- image_folder_dataset(
  root = caminho_treino,
  loader = loader_leitura,
  transform = pipeline_processamento
)

classes <- full_ds$classes
todos_targets <- full_ds$targets
indices_por_classe <- list()
contagens <- c()

for (i in 1:length(classes)) {
  idxs <- which(todos_targets == i)
  indices_por_classe[[ classes[i] ]] <- idxs
  contagens <- c(contagens, length(idxs))
}

LIMITE <- min(contagens)
indices_finais <- c()

for (nome in classes) {
  disponiveis <- indices_por_classe[[nome]]
  escolhidos <- sample(disponiveis, LIMITE)
  indices_finais <- c(indices_finais, escolhidos)
}

train_ds_balanced <- dataset_subset(full_ds, indices_finais)

```

```

BATCH_SIZE <- 16
train_dl <- dataloader(train_ds_balanced, batch_size = BATCH_SIZE, shuffle = TRUE)

valid_ds <- image_folder_dataset(root = caminho_valid, loader = loader_leitura, transform =
pipeline_processamento)
valid_dl <- dataloader(valid_ds, batch_size = BATCH_SIZE, shuffle = FALSE)

model <- model_resnet50(pretrained = TRUE)

for (p in model$parameters) {
  p$requires_grad <- FALSE
}

num_features_entrada <- model$fc$in_features
model$fc <- nn_linear(in_features = num_features_entrada, out_features = 8)

model$to(device = device)
optimizer <- optim_adam(model$parameters, lr = 0.001)
criterion <- nn_cross_entropy_loss()
epochs <- 10

for (epoch in 1:epochs) {
  model$train()
  train_loss <- 0
  batches <- 0

  coro::loop(for (b in train_dl) {
    optimizer$zero_grad()
    b$x <- b$x$to(device = device)
    b$y <- b$y$to(device = device)

    output <- model(b$x)

```

```

loss <- criterion(output, b$y)
loss$backward()
optimizer$step()

train_loss <- train_loss + loss$item()
batches <- batches + 1
})

model$eval()
acc_correct <- 0
total_valid <- 0

with_no_grad({
  coro::loop(for (b in valid_dl) {
    b$x <- b$x$to(device = device)
    b$y <- b$y$to(device = device)
    output <- model(b$x)
    preds <- torch_argmax(output, dim = 2)
    acc_correct <- acc_correct + (preds == b$y)$sum()$item()
    total_valid <- total_valid + b$y$size(1)
  })
})

acc_final <- acc_correct / total_valid
cat(sprintf("Época %d | Perda: %.4f | Acurácia: %.2f%%\n",
           epoch, train_loss/batches, acc_final * 100))
}
torch_save(model$state_dict(), "modelo_resnet50_tcc_unifap.pt")

# Validação -----

library(torch)
library(torchvision)

```

```

library(magick)

device <- "cpu"
pasta_imagens <- "D:/cameras_trap/LO_01_0400"
caminho_modelo <- "modelo_resnet50_tcc_unifap.pt"

class_names <- c("cao", "carro", "vazio", "gato", "humano", "moto", "passaro", "roedor")

model_test <- model_resnet50(pretrained = FALSE)
model_test$fc <- nn_linear(in_features = model_test$fc$in_features, out_features = 8)
model_test$load_state_dict(torch_load(caminho_modelo))
model_test$to(device = device)
model_test$eval()

analisar_imagem_completa <- function(filepath, model) {
  img_tensor <- tryCatch({
    img <- magick::image_read(filepath)
    if (length(img) > 1) img <- img[1]
    img <- magick::image_convert(img, colorspace = "rgb")

    img %>%
      transform_to_tensor() %>%
      transform_resize(size = c(224, 224)) %>%
      transform_normalize(mean = c(0.485, 0.456, 0.406), std = c(0.229, 0.224, 0.225))
  }, error = function(e) return(NULL))

  if (is.null(img_tensor)) return(NULL)

  batch <- img_tensor$squeeze(1)$to(device = device)
  inicio <- Sys.time()

  with_no_grad({
    output <- model(batch)
  })
}

```

```

    probs <- nnf_softmax(output, dim = 2)
    top2 <- torch_topk(probs, k = 2)
  })

  fim <- Sys.time()
  tempo_ms <- as.numeric(difftime(fim, inicio, units = "secs")) * 1000

  scores <- as.numeric(top2[[1]]$cpu())
  indices <- as.numeric(top2[[2]]$cpu())

  return(data.frame(
    filename = basename(filepath),
    prediction = class_names[indices[1]],
    confidence = paste0(round(scores[1] * 100, 2), "%"),
    inference_time_ms = round(tempo_ms, 2),
    top_2_prediction = class_names[indices[2]],
    top_2_score = paste0(round(scores[2] * 100, 2), "%"),
    stringsAsFactors = FALSE
  ))
}

arquivos <- list.files(pasta_imagens, pattern = "\\.(jpg|jpeg|png)$", full.names = TRUE,
ignore.case = TRUE)
df_final <- data.frame()

for (i in 1:length(arquivos)) {
  resultado_linha <- analisar_imagem_completa(arquivos[i], model_test)
  if (!is.null(resultado_linha)) {
    df_final <- rbind(df_final, resultado_linha)
  }
}

write.csv2(df_final, "resultados_metricas.csv", row.names = FALSE)

```

APÊNDICE B - MOSAICO DE FOTOS DAS INSTALAÇÕES DAS ARMADILHAS DE CÂMERA



APÊNDICE C - MOSAICO DE FOTOS DOS DADOS DAS ARMADILHAS DE CÂMERA

