

DESENVOLVIMENTO E VALIDAÇÃO DE UM SISTEMA AUTOMATIZADO DE DETECÇÃO COMPORTAMENTAL EM CÃES BASEADO EM INTELIGÊNCIA ARTIFICIAL UTILIZANDO MODELO YOLO DE DEEP LEARNING

GUSTAVO DE A. FUSQUINE¹, LARISSA G. DELFINO¹, KATIANI S. VENTURINI², LUCIANO TREVIZAN¹

¹Departamento de Zootecnia, Universidade Federal do Rio Grande do Sul, Porto Alegre/RS; ²Special Dog Company
Contato: 00276739@ufrgs.br / Apresentador: GUSTAVO DE A. FUSQUINE¹

Resumo: A análise do comportamento animal é amplamente empregada em estudos experimentais, porém ainda é majoritariamente manual, pontual e limitada a períodos curtos, restringindo as avaliações e aumentando o erro experimental pela variabilidade entre observadores. Nesse contexto, o presente estudo teve como objetivo desenvolver e aplicar um sistema automatizado, baseado no modelo YOLO v8 (2023), para detecção e quantificação de comportamentos em cães a partir de vídeos. Foram utilizados 14 cães da raça Beagle, mantidos em gaiolas metabólicas com gravação contínua de aproximadamente 9 horas diárias. Os vídeos foram segmentados e utilizados para construção de um banco de dados com 11.816 anotações, referentes aos comportamentos deitado, sentado, em pé, bípede e latindo. O modelo foi treinado com divisão de 80% treinamento, 10% validação e 10% teste, para processamento por frames, incluindo rastreamento dos animais e regras de pós-processamento temporal. O modelo apresentou mAP50 de aproximadamente 0,92 e mAP50-95 de 0,83, indicando alta precisão na detecção. A validação de 288 vídeos demonstrou concordância com a observação manual. O sistema identificou e quantificou os comportamentos com precisão, indicando alto potencial da IA para automatizar análises e reduzir o erro experimental.

PalavrasChaves: Visão computacional; Etograma; Monitoramento animal

DEVELOPMENT AND VALIDATION OF AN AUTOMATED SYSTEM FOR BEHAVIOR DETECTION IN DOGS BASED ON ARTIFICIAL INTELLIGENCE USING A YOLO DEEP LEARNING MODEL

Abstract: Animal behavior analysis is widely used in experimental studies; however, it is still predominantly manual, punctual, and limited to short observation periods, restricting evaluations and increasing experimental error due to inter-observer variability. In this context, the present study aimed to develop and apply an automated system, based on the YOLOv8 model (2023), for the detection and quantification of dog behaviors from video recordings. Fourteen Beagle dogs were used, housed in metabolic cages with continuous recording of approximately 9 hours per day. The videos were segmented and used to build a dataset comprising 11,816 annotations, corresponding to the behaviors lying, sitting, standing, bipedal posture, and barking. The model was trained using an 80/10/10 split for training, validation, and testing, and applied for frame-by-frame processing, including animal tracking and temporal post-processing rules. The model achieved an mAP50 of approximately 0.92 and an mAP50-95 of 0.83, indicating high detection accuracy. Validation using 288 videos showed agreement with manual observation. The system accurately identified and quantified behaviors, demonstrating the strong potential of artificial intelligence to automate behavioral analysis and reduce experimental error.

Keywords: Computer vision; Ethogram; Animal monitoring

Introdução: A avaliação do comportamento animal é amplamente utilizada em estudos experimentais, permitindo a quantificação de padrões comportamentais sob diferentes condições de manejo. Em cães, essa análise é feita diretamente ou por vídeos, o que limita o tempo avaliado, demanda tempo e sofre influência dos avaliadores. A anotação manual de comportamentos em vídeos, embora essencial, é trabalhosa e suscetível a vieses e problemas de reprodutibilidade (CHAN, 2025). Nesse contexto, avanços em visão computacional e deep learning relacionado a inteligência artificial (IA) têm possibilitado a automatização da detecção e quantificação comportamental, aumentando a eficiência e padronização das análises, permitindo a avaliação de vídeos longos e não de cortes aleatórios na leitura de dados. Assim, o objetivo deste trabalho foi desenvolver e aplicar um sistema automatizado baseado em modelo YOLO v8 (2023) para detecção e quantificação de comportamentos em cães a partir de vídeos experimentais.

Material e Métodos: Foram utilizados 14 cães da raça Beagle, mantidos em gaiolas metabólicas durante ensaios de digestibilidade, dispostas para monitoramento simultâneo de dois animais por câmera, posicionadas frontalmente, com gravação contínua de 9 h/dia e armazenamento em cartões SD. Para construção do banco de dados, foi desenvolvido um script em linguagem computacional Python para automatizar a extração de *frames* (quadros) na frequência de 1 imagem por segundo, visando reduzir a redundância temporal. As imagens foram rotuladas manualmente por meio de *bounding boxes* (caixas delimitadoras para localizar objetos), utilizando o software Roboflow (2026), classificando os comportamentos deitado, sentado, em pé, bípede e latindo, totalizando 11.816 rotulagens. O conjunto de dados foi dividido em 80% para treinamento, 10% validação e 10% teste. O modelo YOLO foi treinado para ajustar os parâmetros da rede neural, permitindo identificar simultaneamente a localização e a classe dos comportamentos. Para análise, foi desenvolvido um pipeline em Python (fluxo automatizado de processamento) para processamento *frame a frame* dos vídeos, com detecção e classificação. Foi implementado rastreamento baseado na posição horizontal, definindo o animal A à esquerda e B à direita (Figura 1). Aplicaram-se regras de pós-processamento temporal para corrigir oscilações e ausências de detecção (Figura 2). Como saída, foram gerados vídeos anotados e arquivos CSV com identificação do animal, comportamento e tempo de permanência. Para validação, 288 vídeos foram analisados por inspeção visual comparativa.

Resultado e Discussão: O modelo apresentou alto desempenho na detecção e classificação dos comportamentos, com mAP50 de aproximadamente 0,92 e mAP50-95 de 0,83, valores considerados elevados na literatura de detecção de objetos (Lin et al., 2014). Durante o treinamento, observou-se redução contínua das perdas do modelo, acompanhada de aumento na precisão e *recall* (Figura 3), indicando aprendizado consistente sem sinais de sobreajuste (*overfitting*). O sistema de rastreamento baseado na posição horizontal permitiu a manutenção da identidade dos animais ao longo dos vídeos, garantindo consistência na atribuição dos comportamentos ao animal A (à esquerda) e B (à direita). Essa abordagem mostrou-se eficiente em condições de enquadramento fixo, reduzindo trocas de identidade entre indivíduos. A aplicação de regras de pós-processamento temporal contribuiu para a estabilidade das classificações, corrigindo oscilações pontuais entre frames consecutivos e melhorando a coerência das sequências comportamentais. A análise frame a frame dos vídeos permitiu maior sensibilidade na detecção de eventos de curta duração, ampliando a capacidade de observação em comparação à análise manual. A validação por inspeção visual de 288 vídeos indicou boa concordância entre as detecções do modelo e a observação direta. Entretanto, limitações foram observadas, especialmente em frames ambíguos ou com baixa visibilidade, além da dependência de um conjunto de dados equilibrado entre as classes para melhor desempenho do modelo.



Figura 1. Exemplo de saída do sistema de detecção comportamental, demonstrando a identificação dos animais (A e B), aplicação de *bounding boxes* e classificação automática dos comportamentos (sentado, em pé, latindo e bipede), acompanhada do nível de confiança do modelo.



Figura 2. Frame representativo de ausência de detecção, no qual ambos os animais não são identificados pelo modelo e o comportamento é inferido como "deitado (sem bbox)", evidenciando a regra de preenchimento aplicada na ausência de *bounding boxes*.




Figura 3. Evolução das perdas e métricas durante o treinamento do modelo YOLO, com redução de *box_loss*, *cls_loss* e *dfl_loss* e aumento de precisão, *recall*, mAP50 e mAP50-95, indicando boa convergência e ausência de *overfitting*.

Conclusão: O sistema baseado na arquitetura YOLO demonstrou alta capacidade de detecção e quantificação de comportamento em cães. A integração com rastreamento e pós-processamento aumentou a estabilidade das classificações, permitindo análise contínua de vídeos. A IA mostrou-se promissora, aumentando padronização, reprodutibilidade e sensibilidade, embora dependa da qualidade dos dados e validação adequada.

Agradecimentos: Os autores agradecem à Special Dog Company pelo apoio e fornecimento das dietas utilizadas neste estudo, contribuindo para a realização dessa pesquisa.

Referências Bibliográficas: LIN, T.-Y.; MAIRE, M.; BELONGIE, S.; HAYS, J.; PERONA, P.; RAMANAN, D.; DOLLÁR, P.; ZITNICK, C. L. Microsoft COCO: Common Objects in Context. In: EUROPEAN CONFERENCE ON COMPUTER VISION (ECCV), 2014. Proceedings... Cham: Springer, 2014. p. 740–755; CHAN, A. H. H.; PUTRA, P.; SCHUPP, H.; KÖCHLING, J.; STRAßHEIM, J.; RENNER, B.; SCHROEDER, J.; PEARSE, W. D.; NAKAGAWA, S.; BURKE, T.; GRIESSER, M.; MELTZER, A.; LUBRANO, S.; KANO, F. YOLO-Behaviour: A simple, flexible framework to automatically quantify animal behaviours from videos. *Methods in Ecology and Evolution*, v. 16, p. 760–774, 2025. DOI: <https://doi.org/10.1111/2041-210X.14502>