

MMLA: M 多环境、M 多物种、L 低海拔 A 材料镜头数据集

Jenna Kline¹, Samuel Stevens¹, Guy Maalouf², Camille Rondeau Saint-Jean²,
Dat Nguyen Ngoc³, Majid Mirmehdi³, David Guerin⁴, Tilo Burghardt³,
Elzbieta Pastucha², Blair Costelloe⁵, Matthew Watson³, Thomas Richardson³,
Ulrik Pagh Schultz Lundquist²

¹The Ohio State University ²University of Southern Denmark ³ University of Bristol ⁴ WildDroneEU ⁵ Max Planck Institute of Animal Behavior

Abstract

无人机图像中的实时野生动物检测对于动物生态学、保护和生物多样性监测等众多应用至关重要。低空无人机任务能够有效收集精细的动物运动和行为数据，尤其是如果任务被自动化以提高速度和一致性时更是如此。然而，关于评估计算机视觉模型在低空航拍影像上的效果以及跨不同物种和环境的一般性的研究很少。为了填补这一空白，我们提出了一种新型多环境、多物种、低空航拍视频 (MMLA) 数据集。MMLA 包含了在三个多样化的环境中收集的无人机视频：肯尼亚的奥佩捷塔保护区和姆帕拉研究中心，以及俄亥俄州的野外保护中心，其中包括五个物种：平原斑马、格维茨斑马、长颈鹿、亚洲野驴和非洲野犬。我们全面评估了三种 YOLO 模型 (YOLOv5m, YOLOv8m 和 YOLOv11m) 用于检测动物的表现。结果表明，在不同地点和物种特定的检测方面存在显著性能差异。我们的研究强调了在不同的环境中评估检测算法的重要性，以实现使用无人机进行稳健的野生动物监测应用。

1. 介绍

遥感技术的应用，包括无人机、相机陷阱、生物声学传感器、卫星和 GPS 追踪器，通过实现前所未有的规模的非侵入性野生动物监测，彻底改变了野外动物生态学研究 [2]。这些技术生成了新的数据来源来在自然社会和环境背景下研究动物原位。然而，大量数据超过了手动标注的能力。人工智能为这一挑战提供了一个高效解决方案 [35]，产生了一门名为图像组学 [17]

的新科学领域。

野生动物监测技术可以根据其生态应用和成像特性被分为三类 [16, Fig. 1]。

相机陷阱在捕捉动物的详细图像方面表现出色，但从根本上受限于其固定的性质和狭窄的视野，限制了它们对动态行为进行景观研究的实用性。

高空航拍提供了优秀的人口统计覆盖范围 [5, 38]，但从最低点¹ 角度拍摄时每只动物只有几个像素，不足以进行个体识别 [33] 或精细的行为分析 [14]。低空无人机研究 (40 米或更低) 处于中间地带，因为它们提供了足够的分辨率 (每只动物 100 多个像素)，用于行为分析 [31, 34]、运动 [21] 和个体识别 [7, 33]，同时覆盖比相机陷阱更大的空间范围。低空影像，如 WildWing [18] 和 WildBridge [25] 系统所收集的，为对象检测算法提出了独特的挑战。

尽管在通用物体检测方面取得了进展，标准计算机视觉模型在应用于无人机影像中的野生动物检测时性能显著下降。像 YOLO [13] 这样的模型在 MSCOCO [23] 等基准数据集上表现出色，但在变化多端的自然环境中部署用于动物检测时，其性能大幅降低 (参见 Sec. 4)。这种性能差距为计算机视觉研究人员通过技术创新解决现实世界生态挑战提供了强烈机遇。现有的针对相机陷阱设计的检测模型 (如 MegaDetector [1]) 主要侧重于减少假阴性，而高空影像模型 (例如 POLO [24] 和 HerdNeT [6]) 则优先考虑从最少的像素信息中进行准确计数。没有现有的方法解决低空无人机研究的具体要求。

¹ 鸟瞰图，或自上而下




图 1. 通过相机陷阱、高空和低空无人机任务收集的动物图像比较。

Dataset	Categories	Image Count	Size ¹	Multi-Location ²
Population estimates [8]	elephant, zebra, giraffe	561 RGB	50px	✗
Bird detection [39]	bird	24K RGB	35px	✓
Seabird colonies [10]	albatross, penguin	4K RGB	300px	✗
Conservation Drones [3]	human, elephant, lion, dog	48 thermal videos	35px	✓
Group behavior [21]	zebra, gazelle, waterbuck, buffalo, gelada, human	2K RGB	56px	✓
KABR [14]	giraffe, zebra	130K videos	100px	✗
WAID [28]	sheep, cattle, seal, camel, kiang, zebra	14K RGB	166px	✗
MMLA (ours)	dogs, zebras, onagers, giraffes	155K RGB	100px	✓

¹ 大小表示典型动物的像素尺寸。² 多位置表示在同一物种跨越多个地理位置的数据集。

表 1. 多物种航空数据集的总结。请注意，MMLA 包含大型动物（100 像素）和多个地点，这与之前的工作不同。

合适的训练数据集的缺失一直是开发有效的低空无人机野生动物监测检测方法的主要障碍 [26, 41]。现场地点之间的环境变化带来了显著的领域转移，导致在一个地点训练的模型在不同地点部署时失败。后勤挑战限制了之前的数据集开发工作，包括跨多个地点协调实地活动 [5]，受保护区的复杂许可 [31]，以及注释过程中对生态专业知识的需求 [34]。我们的新型 **m 多环境, m 多物种, l 低海拔 a 材料片段数据集 (MMLA)** 直接解决了这些限制，通过提供跨越多样化地点（肯尼亚的 Ol Pejeta 保护区和 Mpala 研究中心及俄亥俄州的 The Wilds 保护中心）和物种（平原斑马、格维扎斑马、波斯野驴、长颈鹿、非洲绘画犬）的一致高分辨率图像，使研究人员能够开发适用于实际生态应用的检测方法。

2. 背景及相关工作

我们将动物视频分为三大类：相机陷阱、低空航拍和高空航拍，如 Fig. 1 所示。相机陷阱捕捉到的野生动

物图像中，动物通常占据画面较大的比例，这取决于定位和动物大小 [11, 22]。低空视频捕获了适合行为研究和跟踪研究的中等像素数量的图像 [14, 16, 29]。高空无人机记录的画面中，动物显得很小，限制了细节但覆盖了更大的区域 [5, 10, 12]。尽管相机陷阱数据集和高空航拍数据集非常有价值，它们本质上不适合某些生态应用。相机陷阱数据集 [37] 受限于其固定位置和有限的视野，不足以研究动态社会互动和跨景观的移动模式。高空航拍虽然非常适合人口调查和密度估计，但缺乏细粒度行为分析和个人识别所需的分辨率。

我们对现有多物种航空数据集的回顾，总结在 Tab. 1 中，突显了现有数据集中存在一个关键差距 [27]。没有一种多物种、多地点的航空片段数据集能让感兴趣的物种至少每只动物达到 100 像素。这对从无人机数据集中开发通用哺乳动物检测系统构成了重大障碍。虽然鸟类检测数据集 [39] 拥有多个地点的鸟类图像（跨越 13 个生态系统的 2.4 万张图片），但动物大小有限（35 像素）且缺少哺乳动物种类。现有的哺乳动物数据

集 [8, 14, 21, 28] 包含数千个标注样本, 但在每个物种上地理范围仅限于单个地点, 这可能导致检测模型在不同环境间迁移时表现不佳 [4, 36]。此外, 对于高级生态应用 (如个体识别 [33]、行为分析 [14, 21, 30] 和种间及种内互动研究 [32]) 的最佳分辨率要求每个动物大约为 100-300 像素 [20], 这只能通过保持不同地形和光照条件下一致图像质量的受控低空飞行来实现 [17, 18]。

据我们所知, 我们的 MMLA 数据集代表了首个在同一物种跨越多个环境下的低空无人机影像集合 [27]。大量地理多样化的相机陷阱数据集的可用性, 如 LILA 收藏 [22], 使训练和部署稳健、可泛化模型成为可能, 例如 SpeciesNet [9] 和 MegaDetector [1]。载人飞机数十年来一直用于估算野生动物数量, 因此高空无人机任务受益于进行此类研究的既定协议和基准 [5]。已开发出几种模型, 可以自动从高空无人机调查中计数动物种群, 包括 POLO [24] 和 HerdNet [6]。开发新的计算机视觉模型对于充分利用我们跨地点、多物种、低空数据集至关重要, 该数据集独特地弥合了静态相机陷阱数据与广泛的高空调查之间的差距。在多样化的环境和物种上进行训练将产生比仅在单个地点或单一物种数据集上训练的模型更稳健且可泛化的效果, 通过实现实时行为分析和动态跟踪, 跨越多样的地形和生态背景, 彻底改变了野生动物监测。

3. MMLA 数据集

我们的 MMLA 数据集包含用于野生动物监测和保护研究的标注无人机影像, 支持动物检测与分类的计算机视觉模型开发。MMLA 包含来自三个地点的影像: 肯尼亚莱基皮的奥佩捷塔保护区和姆帕拉研究中心以及美国俄亥俄州的野生动植物保护中心。数据集包括五个物种: 平原斑马、格维茨斑马、长颈鹿、波斯野驴和非洲彩犬。在不同环境中捕捉的不同动物种类允许计算机视觉专家评估模型的泛化能力。该数据集包含 155,074 帧, 总结于 Tab. 2 中。每个视频帧都有使用 CVAT 和 kabr-tools [19] 手动创建的 COCO 格式标注 (带有归一化坐标的边界框)。

奥佩杰塔数据集包含来自肯尼亚奥佩捷塔保护区的 29,268 帧平原斑马画面 (2025 年 1 月至 2 月), 这些画面通过自主 WildWing 系统 [18] 在 WildDrone Hackathon [40] 期间进行的七次高分辨率视频会话中收集。

姆帕拉数据集包含来自肯尼亚 Mpala 研究中心的 104,062 帧长颈鹿、格维茨斑马和平原斑马的画面 (2023 年 1 月), 这些画面作为肯尼亚动物行为识别 (KABR) 项目 [14] 的一部分, 通过使用 DJI Air 2S 无人机手动收集了五个会话的数据。

Wilds 数据集包含来自俄亥俄州野外保护中心的非洲野狗、波斯野驴、长颈鹿和格维茨斑马的 21,744 帧图像 (2024 年 4 月-7 月), 使用大疆迷你无人机和派诺特阿纳菲无人机收集, 结合手动和自主 WildWing 系统采集 [15]。

4. 评估

我们评估了三种流行的 YOLO 模型——YOLOv5m、YOLOv8m 和 YOLOv11m——在 MMLA 监测无人机图像中对动物检测的性能, 这些图像是在三个不同环境中收集的。YOLO (You Only Look Once) 系列模型由于其速度、易用性和准确性 [13, 16], 是人工智能驱动的动物生态学 (ADAE) 研究中的流行选择。我们选择了中型变体来平衡检测性能与计算效率, 因为 ADAE 研究通常使用边缘设备, 如笔记本电脑和 Raspberry Pi 计算机。YOLO 模型在单次前向传递中进行检测, 使其适合资源受限设备上的实时应用。所有评估均使用预训练模型进行, 没有额外的微调, 以评估它们在我们数据集上的开箱即用性能。为了确保 MMLA 数据集中的均匀覆盖, 我们从每个会话中提取了大约 400 帧用于评估目的。评估子集包含 5,073 帧, 其中 Ol Pejeta 自然保护区有 1,050 帧, Mpala 研究中心有 1,923 帧, The Wilds 保护中心有 2,100 帧。我们使用 F1、Tab. 3 和交集与并集比 (IoU) 阈值为 50% 的平均精度均值 (mAP50)、Tab. 4 对每个位置的每种模型性能进行了评估。我们报告了每种模型在各位置检测长颈鹿和斑马的 F1 分数和精确度性能, Tab. 4。YOLOv11m 在整个 MMLA 数据集上表现最佳, F1 分数为 18.55%, mAP50 分数为 32.83%。

5. 讨论

我们对 YOLOv5m、YOLOv8m 和 YOLOv11m 模型在 MMLA 数据集上的比较分析揭示了一些有趣的模式。YOLOv11m 在整个组合数据集中表现最强。然而, 性能因地点而异, 所有模型在 Mpala 数据集 (mAP50 > 63%) 中的得分明显高于 OPC 和 The Wilds。YOLO [13]

Location	Session	Date	Total Frames	Species
Ol Pejeta Conservancy, Laikipia, Kenya	1	1/31/25	16,726	Plains zebra
	2	2/1/25	12,542	Plains zebra
	Subtotal:		29,268	
Mpala Research Center, Laikipia, Kenya	1	1/12/23	16,891	Giraffe
	2	1/17/23	11,165	Plains zebra
	3	1/18/23	17,940	Grevy's zebra
	4	1/20/23	33,960	Grevy's zebra
	5	1/21/23	24,106	Giraffe, Plains and Grevy's zebras
	Subtotal:		104,062	
The Wilds Conservation Center, Ohio, USA	1	6/14/24	13,749	African Painted Dog
	2	7/31/24	3,436	Giraffe
	3	4/18/24	4,053	Persian onager
	4	7/31/24	506	Grevy's zebra
	Subtotal:		21,744	
Total:			155,074	

表 2. 按位置、会话、日期和物种对 MMLA 数据集进行帧级汇总。

Model	Overall F1				Giraffe F1				Zebra F1			
	All	Mpala	OPC	Wilds	All	Mpala	OPC	Wilds	All	Mpala	OPC	Wilds
YOLOv5m	16.31	22.60	16.34	12.02	49.33	52.62	–	39.98	10.73	7.10	18.42	4.03
YOLOv8m	17.01	20.20	16.08	15.33	46.05	49.29	–	38.70	10.16	5.51	17.97	5.08
YOLO11m	18.55	21.86	15.52	17.59	50.89	54.59	–	41.88	16.08	4.60	16.36	42.55

表 3. F1 分数 (%) 在 MMLA 中的不同物种和地点的分布。

Model	MSCOCO (mAP50)	Overall mAP50				Giraffe Precision				Zebra Precision			
		All	Mpala	OPC	Wilds	All	Mpala	OPC	Wilds	All	Mpala	OPC	Wilds
YOLOv5m	49.0	31.58	64.88	29.78	22.17	76.05	77.91	–	70.64	31.17	35.44	30.37	22.40
YOLOv8m	50.2	31.77	63.88	26.33	24.99	66.85	77.90	–	47.47	29.67	36.74	27.05	37.30
YOLOv11m	51.2	32.83	65.71	27.06	19.51	71.53	80.28	–	53.30	34.18	28.84	21.59	68.24

表 4. 精度指标 (%) 在 MMLA 物种和位置上的分布。我们报告了每个 YOLO 变体在 MSCOCO 数据集 [23] 上实现的 mAP50 作为对象检测性能的参考基线 [13]。

在 MSCOCO [23] 上进行了训练, 可能与 Mpala 数据更相似相比 The Wilds 和 OPC, 这解释了在这些地点性能上的差异。对于特定物种检测, YOLO11m 在长颈鹿检测中表现出色, F1 得分为 50.89%, 始终优于其他模

型的数据集表现。有趣的是, 尽管 YOLO11m 在 The Wilds 数据集中显示了出色的斑马检测能力 (42.55% F1), 但在 OPC 数据集中, YOLOv5m 的斑马检测性能更好 (18.42% F1)。33% 的 mAP50 得分显著低于

YOLOv5m、YOLOv8m 和 YOLO11m 在 MSCOCO 数据集 [13] 上平均达到的 50% mAP50 得分。

6. 结论

我们的研究揭示了野生动物检测性能在不同环境中的显著差异，YOLO11m 模型总体上在整体检测 (32.83% mAP50) 和特定物种如长颈鹿 (50.89% F1) 方面普遍优于其他模型。然而，Mpala 数据集中的高性能与 OPC 和 The Wilds 数据集中较低的得分之间的鲜明对比表明，环境因素——可能是栖息地特征、图像质量或动物密度——对检测可靠性的重大影响。这些发现强调了在部署野生动物检测系统时进行位置特定调整的重要性。未来的工作应探索针对环境优化的微调策略，调查影响检测性能的环境因素，并考虑使用集成方法来提高在各种保护设置中的鲁棒性。我们的 MMLA 数据集为开发适用于无人机野生动物监测的更具泛化能力的动物检测算法提供了有价值的基准。

7. 数据可用性声明

MMLA 数据集可在 HuggingFace 获取。非洲野犬数据集需请求获取。

参考文献

- [1] Sara Beery, Dan Morris, and Siyu Yang. Efficient pipeline for camera trap image review. arXiv preprint arXiv:1907.06772, 2019.
- [2] Marc Besson, Jamie Alison, Kim Bjerger, Thomas E. Gorochowski, Toke T. Høye, Tommaso Jucker, Hjalte M. R. Mann, and Christopher F. Clements. Towards the fully automated monitoring of ecological communities. *Ecology Letters*, 25(12):2753 – 2775, 2022.
- [3] Elizabeth Bondi, Raghav Jain, Palash Aggrawal, Saket Anand, Robert Hannaford, Ashish Kapoor, Jim Pivavis, Shital Shah, Lucas Joppa, Bistra Dilkina, and Milind Tambe. BirdSai: A dataset for detection and tracking in aerial thermal infrared videos. In *WACV*, 2020.
- [4] Yuhua Chen, Wen Li, Christos Sakaridis, Dengxin Dai, and Luc Van Gool. Domain adaptive faster r-cnn for object detection in the wild. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 3339–3348, 2018.
- [5] Evangeline Corcoran, Megan Winsen, Ashlee Sudholz, and Grant Hamilton. Automated detection of wildlife using drones: Synthesis, opportunities and constraints. *Methods in Ecology and Evolution*, 12(6):1103 – 1114, 2021.
- [6] Alexandre Delplanque, Samuel Foucher, Jérôme Théau, Elsa Bussière, Cédric Vermeulen, and Philippe Lejeune. From crowd to herd counting: How to precisely detect and count african mammals using aerial imagery and deep learning? *ISPRS Journal of Photogrammetry and Remote Sensing*, 197:167–180, 2023.
- [7] Brinky Desai, Arpitkumar Patel, Vaishwi Patel, Supan Shah, Mehul S Raval, and Ratna Ghosal. Identification of free-ranging mugger crocodiles by applying deep learning methods on uav imagery. *Ecological Informatics*, 72:101874, 2022.
- [8] Jasper A.J. Eikelboom, Jelle Wind, Evert van de Ven, Lizzie M. Kenana, Bennet Schroder, Henrik J. de Knecht, Frank van Langevelde, and Herbert H.T. Prins. Improving the precision and accuracy of animal population estimates with aerial image object detection. *Methods in Ecology and Evolution*, 10(11):1875–1887, 2019.
- [9] Tomer Gadot, Ștefan Istrate, Hyungwon Kim, Dan Morris, Sara Beery, Tanya Birch, and Jorge Ahumada. To crop or not to crop: Comparing whole-image and cropped classification on a large dataset of camera trap images. *IET Computer Vision*, 18(8):1193–1208, 2024.
- [10] Madeline C Hayes, Patrick C Gray, Guillermo Harris, Wade C Sedgwick, Vivon D Crawford, Natalie Chazal, Sarah Crofts, and David W Johnston. Drones and deep learning produce accurate and efficient monitoring of large-scale seabird colonies. *Ornithological Applications*, 123(3):duab022, Aug. 2021.
- [11] Wentong He, Ze Luo, Xinyu Tong, Xiaoyi Hu, Can Chen, and Zufe Shu. Long-tailed metrics and object detection in camera trap datasets. *Applied Sciences*, 13(10), 2023.
- [12] Jarrod C. Hodgson, Rowan Mott, Shane M. Baylis, Trung T. Pham, Simon Wotherspoon, Adam D. Kilpatrick, Ramesh Raja Segaran, Ian Reid, Aleks Terauds, and Lian Pin Koh. Drones count wildlife more accurately and precisely than humans. *Methods in Ecology and Evolution*, 9(5):1160–1167, 2018.

- [13] Glenn Jocher, Jing Qiu, and Ayush Chaurasia. Ultralytics YOLO.
- [14] Maksim Kholiavchenko, Jenna Kline, Michelle Ramirez, Sam Stevens, Alec Sheets, Reshma Babu, Namrata Banerji, Elizabeth Campolongo, Matthew Thompson, Nina Van Tiel, et al. Kabr: In-situ dataset for kenyan animal behavior recognition from drone videos. In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, pages 31–40, 2024.
- [15] Jenna Kline. Wildwing system deployment data. <https://zenodo.org/records/14838101>, 2025.
- [16] Jenna Kline, Austin O’Quinn, Tanya Berger-Wolf, and Christopher Stewart. Characterizing and modeling ai-driven animal ecology studies at the edge. In *2024 IEEE/ACM Symposium on Edge Computing (SEC)*, pages 220–233. IEEE, 2024.
- [17] Jenna Kline, Christopher Stewart, Tanya Berger-Wolf, Michelle Ramirez, Samuel Stevens, Reshma Ramesh Babu, Namrata Banerji, Alec Sheets, Sowbaranika Balasubramaniam, Elizabeth Campolongo, Matthew Thompson, Charles V. Stewart, Maksim Kholiavchenko, Daniel I. Rubenstein, Nina Van Tiel, and Jackson Miliko. A framework for autonomic computing for in situ imageomics. In *2023 IEEE International Conference on Autonomic Computing and Self-Organizing Systems (ACSOS)*, page 11 – 16, Toronto, ON, Canada, Sept. 2023. IEEE.
- [18] Jenna Kline, Alison Zhong, Kevyn Irizarry, Charles V Stewart, Christopher Stewart, Daniel I Rubenstein, and Tanya Berger-Wolf. Wildwing: An open-source, autonomous and affordable uas for animal behaviour video monitoring. *Methods in Ecology and Evolution*, 2025.
- [19] Jenna Kline, Alison Zhong, Maksim Kholiavchenko, and Elizabeth Campolongo. kabr-tools: Tools for working with data for annotating animal behavior, 2024.
- [20] Jenna M Kline, Maksim Kholiavchenko, Otto Brookes, Tanya Berger-Wolf, Charles V Stewart, and Christopher Stewart. Integrating biological data into autonomous remote sensing systems for in situ imageomics: A case study for kenyan animal behavior sensing with unmanned aerial vehicles (uavs). *arXiv preprint arXiv:2407.16864*, 2024.
- [21] Benjamin Koger, Adwait Deshpande, Jeffrey T. Kerby, Jacob M. Graving, Blair R. Costelloe, and Iain D. Couzin. Quantifying the movement, behaviour and environmental context of group-living animals using drones and computer vision. *Journal of Animal Ecology*, n/a(n/a), 2022.
- [22] LILA BC. Lila bc: Labeled information library of alexandria: Biology and conservation. <https://lila.science/>, 2025. Accessed on March 24, 2025.
- [23] Tsung-Yi Lin, Michael Maire, Serge Belongie, Lubomir Bourdev, Ross Girshick, James Hays, Pietro Perona, Deva Ramanan, C. Lawrence Zitnick, and Piotr Dollár. Microsoft coco: Common objects in context, 2015.
- [24] Giacomo May, Emanuele Dalsasso, Benjamin Kellenberger, and Devis Tuia. Polo-point-based, multi-class animal detection. *arXiv preprint arXiv:2410.11741*, 2024.
- [25] Kilian Meier, Arthur Richards, Matthew Watson, Caspian Johnson, Duncan Hine, Tom Richardson, and Guy Maalouf. Wildbridge: Conservation software for animal localisation using commercial drones. In T. Richardson, editor, *15th annual International Micro Air Vehicle Conference and Competition*, page 324 – 333, Bristol, United Kingdom, 2024. Paper no. IMAV2024-39.
- [26] Payal Mittal, Raman Singh, and Akashdeep Sharma. Deep learning-based object detection in low-altitude uav datasets: A survey. *Image and Vision computing*, 104:104046, 2020.
- [27] Dan Morris. Datasets with annotated wildlife in drone/aerial images - publicly available datasets. <https://github.com/agentmorris/agentmorrispublic/blob/main/drone-datasets.md#publicly-available-datasets>, 2024.
- [28] Chao Mou, Tengfei Liu, Chengcheng Zhu, and Xiaohui Cui. Waid: A large-scale dataset for wildlife detection with drones. *Applied Sciences*, 13(1818):10397, Jan. 2023.
- [29] Chao Mou, Chengcheng Zhu, Tengfei Liu, and Xiaohui Cui. A novel efficient wildlife detecting method with lightweight deployment on uavs based on yolov7. *IET Image Processing*, 18(5):1296 – 1314, 2024.
- [30] Katalin Ozogány, Viola Kerekes, Attila Fülöp, Zoltán Barta, and Máté Nagy. Fine-scale collective movements reveal present, past and future dynamics of

- a multilevel society in przewalski's horses | nature communications. *Nature Communications*, 14(1):5096, Sept. 2023.
- [31] Lucia Pedrazzi, Hemal Naik, Chris Sandbrook, Miguel Lurgi, Ines Fürtbauer, and Andrew J. King. Advancing animal behaviour research using drone technology. *Animal Behaviour*, 222:123147, Apr. 2025.
 - [32] Lucia Pedrazzi, Hemal Naik, Chris Sandbrook, Miguel Lurgi, Ines Fürtbauer, and Andrew J. King. Advancing animal behaviour research using drone technology. *Animal Behaviour*, 222:123147, Apr. 2025.
 - [33] Edouard Rolland, Kasper Grøntved, Lucie Laporte-Devyllder, Jenna Kline, Ulrik Lundquist, and Anders Christensen. Drone swarms for animal monitoring: A method for collecting high-quality multi-perspective data. In T. Richardson, editor, 15th annual International Micro Air Vehicle Conference and Competition, pages 316–323, Bristol, United Kingdom, Sep 2024. Paper no. IMAV2024-38.
 - [34] Lukas Schad and Julia Fischer. Opportunities and risks in the use of drones for studying animal behaviour. *Methods in Ecology and Evolution*, 14(8):1864 – 1872, 2023.
 - [35] Devis Tuia, Benjamin Kellenberger, Sara Beery, Blair R Costelloe, Silvia Zuffi, Benjamin Risse, Alexander Mathis, Mackenzie W Mathis, Frank Van Langevelde, Tilo Burghardt, et al. Perspectives in machine learning for wildlife conservation. *Nature communications*, 13(1):792, 2022.
 - [36] Vidit Vidit, Martin Engilberge, and Mathieu Salzmann. Clip the gap: A single domain generalization approach for object detection. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pages 3219–3229, 2023.
 - [37] Juliana Vélez, William McShea, Hila Shamon, Paula J. Castiblanco-Camacho, Michael A. Tabak, Carl Chalmers, Paul Fergus, and John Fieberg. An evaluation of platforms for processing camera-trap data using artificial intelligence. *Methods in Ecology and Evolution*, 14(2):459–477, 2023.
 - [38] Dongliang Wang, Quanqin Shao, and Huanyin Yue. Surveying wild animals from satellites, manned aircraft and unmanned aerial systems (uass): A review. *Remote Sensing*, 11(1111):1308, Jan. 2019.
 - [39] Ben Weinstein, Lindsey Garner, Vienna R. Saccomanno, Ashley Steinkraus, Andrew Ortega, Kristen Brush, Glenda Yenni, Ann E. McKellar, Rowan Converse, Christopher D. Lipitt, Alex Wegmann, Nick D. Holmes, Alice J. Edney, Tom Hart, Mark J. Jessopp, Rohan Clarke, Dominik Markowski, Henry Senyondo, Ryan Dotson, Ethan P. White, Peter Frederick, and S.K Morgan Ernest. A global model of bird detection in high resolution airborne images using computer vision, June 2021.
 - [40] WildDrone EU Consortium. Wilddrone eu project, 2025. Accessed: 03-Apr-2025.
 - [41] Pengfei Zhu, Longyin Wen, Xiao Bian, Haibin Ling, and Qinghua Hu. Vision meets drones: A challenge. *arXiv preprint arXiv:1804.07437*, 2018.