

Literatur Reviu Sistematis : Identifikasi jenis ular berbasis *computer vision*.

Eva Putriany*¹ dan Dhani Ariatmanto²

1-2 Universitas AMIKOM Yogyakarta

Jl. Padjajaran, Ring Road Utara, Kel. Condongcatur,
Kec. Depok, Kab.Sleman, Prop. Daerah Istimewa Yogyakarta
evaputriany@students.amikom.ac.id;dhaniari@amikom.ac.id

Abstrak

Literatur reviu sistematis ini bertujuan untuk mengidentifikasi algoritma-algoritma yang digunakan dalam identifikasi spesies ular yang menggunakan *computer vision*, mengevaluasi dataset, tingkat akurasi, faktor-faktor yang memengaruhi akurasi, dan keterbatasan yang dihadapi. Melalui tinjauan literatur sistematis, 20 paper terpilih dari tahun 2019-2023, yang didapat dari berbagai sumber literatur. Penelitian-penelitian tersebut mengeksplorasi berbagai strategi untuk mengatasi tantangan pengenalan objek ular secara otomatis, termasuk peningkatan kinerja model, eksplorasi pendekatan baru, dan penerapan solusi efektif. Hasil dari studi literatur menyoroti pentingnya pemrosesan data yang cermat, pemilihan arsitektur model yang tepat, serta penyesuaian parameter algoritma yang optimal dalam mencapai kinerja maksimal pada model-model yang dikembangkan. Beberapa peneliti juga mengemukakan keterbatasan dalam penelitiannya, seperti kualitas dan jumlah dataset, kompleksitas morfologi ular, dan variasi pose ular. Diperlukan kerja sama lintas disiplin dan berbagi pengetahuan untuk mengatasi tantangan ini dan memajukan bidang identifikasi spesies ular melalui *computer vision*.

Kata Kunci literatur reviu sistematis, *computer vision*, identifikasi ular.

Digital Object Identifier 10.36802/jnanaloka.2022.v5-no1-43-50

1 Pendahuluan

Gigitan ular merupakan masalah serius yang sering diabaikan dalam kesehatan masyarakat. Menurut Organisasi Kesehatan Dunia (WHO), setiap tahunnya terdapat sekitar 4.5 hingga 5.4 juta kasus gigitan ular, dimana 95% dari kasus yang dilaporkan terjadi di negara berpenghasilan rendah dan menengah [1]. Dari jumlah tersebut, sekitar 2.7 juta kasus merupakan gigitan ular berbisa, dengan dampak yang serius: antara 81.000 hingga 130.000 menyebabkan kematian dan kecacatan permanen [1]. Tingginya tingkat gigitan ular menjadi perhatian penting karena lebih dari 50% dari gigitan ular tidak dapat diidentifikasi secara spesifik jenis ular yang menggigit, bahkan di negara-negara maju [2].

Identifikasi jenis ular secara konvensional memiliki banyak keterbatasan dan sulit untuk dilakukan. Misalnya membedakan antara ular tidak berbisa dan viperid berdasarkan ciri karakteristik (kepala berbentuk oval, pupil bulat) tidaklah cukup, karena ciri-ciri ini juga ditemukan pada ular elapid [3], dan viperid maupun elapid berpotensi fatal bagi manusia.

Selain itu kesulitan yang dihadapi adalah banyaknya variasi visual antar spesies, serta adanya fenomena mimikri yang membuat beberapa spesies terlihat menyerupai spesies lain [4]. Hal ini menyebabkan kesulitan dalam mengidentifikasi spesies ular secara akurat, terutama di daerah dengan keanekaragaman spesies yang tinggi. Sehingga untuk mendapatkan

* Corresponding author.



tingkat ketepatan yang tinggi dalam identifikasi spesies ular perlu dilakukan pengamatan morfologi fisik atau analisis sampel DNA yang dilakukan oleh ahlinya. Akan tetapi metode identifikasi ini memerlukan waktu dan sumber daya yang cukup besar, serta membutuhkan keahlian khusus.

Saat ini, teknologi *computer vision* atau visi komputer telah menjadi salah satu solusi yang diusulkan untuk meningkatkan kecepatan dan ketepatan identifikasi spesies ular. *Computer vision* atau visi komputer adalah penggabungan dari pemrosesan gambar dan pengenalan pola yang menghasilkan pemahaman gambar dan menentukan pengambilan suatu keputusan [5]. Visi komputer memungkinkan identifikasi ular secara cepat melalui analisis gambar, sehingga dapat mempercepat penanganan kasus gigitan ular, terutama di daerah di mana ahli herpetologi tidak tersedia atau terbatas [6].

Tujuan utama dari tinjauan literatur sistematis (SLR) ini adalah untuk mengidentifikasi algoritma-algoritma yang telah diterapkan dalam identifikasi spesies ular menggunakan teknologi visi komputer, baik dari dataset, tingkat akurasi, faktor yang memengaruhi akurasi identifikasi, serta mengidentifikasi keterbatasan yang dihadapi dalam penerapan teknologi visi komputer untuk tujuan identifikasi spesies ular. Dengan demikian, penelitian bertujuan untuk memberikan pemahaman yang lebih mendalam tentang penggunaan teknologi visi komputer dalam identifikasi spesies ular, serta mengetahui di mana penelitian lebih lanjut diperlukan untuk meningkatkan efektivitas dan ketepatan sistem identifikasi tersebut.

2 Metodologi

Pendekatan yang digunakan dalam melakukan review literatur ini mengikuti panduan review yang disarankan oleh Brereton dkk. [7]. Proses tinjauan sistematis ini memberikan pendekatan yang sesuai, efisien, dan dapat diandalkan untuk melakukan tinjauan pada topik penelitian dengan mempertimbangkan berbagai aspek dari studi yang relevan. Proses tinjauan literatur sistematis yang digunakan terdiri dari lima langkah [8], yaitu :

- | | |
|------|---|
| I: | <i>Planning of the review process</i>
Tahap ini melibatkan penetapan persyaratan untuk proses tinjauan serta pembentukan pertanyaan penelitian yang relevan. |
| II: | <i>Find the relevant work</i>
Tahap ini mencakup seleksi tinjauan pustaka yang relevan sesuai dengan kriteria yang telah ditetapkan. |
| III: | <i>Assessing the research quality</i>
Tahap ini melibatkan kriteria-kriteria minimal dari kualitas tinjauan pustaka yang akan digunakan. |
| IV: | <i>Writing up the document</i>
Langkah ini mencakup dokumentasi hasil penelitian dalam bentuk sebuah makalah sesuai dengan standar penulisan ilmiah. |
| V: | <i>Analyze the results</i>
Pada langkah terakhir, hasil yang telah didapat dianalisis secara menyeluruh untuk menyusun laporan penulisan. |

Objek utama dari penelitian ini adalah mengetahui perkembangan *computer vision* yang digunakan pada identifikasi jenis ular. Dalam perencanaan penelitian dilakukan identifikasi pertanyaan penelitian sebagai dasar dilakukannya peninjauan studi literatur. Pertanyaan penelitian yang digunakan untuk proses tinjauan literatur sistematis saat ini adalah:

RQ1:	Algoritma apa yang digunakan oleh peneliti untuk mengidentifikasi spesies ular?
RQ2:	Apa kriteria dataset yang digunakan oleh peneliti dalam studi identifikasi ular?
RQ3:	Apa tahapan pre-processing dataset yang digunakan?
RQ4:	Berapa tingkat akurasi yang dicapai dengan menggunakan algoritma-algoritma tersebut dalam identifikasi spesies ular?
RQ5:	Apa faktor-faktor utama yang memengaruhi tingkat akurasi dan efektivitas identifikasi ular menggunakan algoritma tertentu?
RQ6:	Apa keterbatasan utama yang dihadapi oleh peneliti dalam identifikasi ular?

Tahapan selanjutnya adalah mencari literatur yang relevan dengan penelitian. Berbagai artikel dipilih dari berbagai situs web berdasarkan judul studi yang beragam, kata kunci yang relevan, abstrak, serta kesimpulan. Artikel-artikel ini dipilih dari berbagai sumber basis data seperti ACM Digital Library, Google Scholar, IEEE Xplore, Scencedirect, Google Books, dan Semantic Scholar. Untuk mencari artikel tersebut digunakan berbagai kombinasi kata kunci seperti "*computer vision, snake identification, image processing, deep learning*."

Kriteria inklusi dan eksklusi kemudian ditetapkan untuk menyaring artikel yang relevan dengan penelitian. Kriteria inklusi menjadi panduan untuk topik yang akan dijangkau, sedangkan kriteria eksklusi tidak akan digunakan dalam penelitian ini. Kriteria inklusi serta kriteria eksklusi yang digunakan dalam penelitian ini ditampilkan pada Tabel 1.

■ **Tabel 1** Kriteria Inklusi dan Eksklusi

	Artikel diterbitkan pada tahun 2019-2024
Inklusi	Artikel identifikasi jenis ular dengan pendekatan Computer Vision Artikel dalam bahasa Inggris
	Artikel diterbitkan sebelum tahun 2019
Eksklusi	Artikel yang subjek utamanya bukan identifikasi ular Artikel dalam bahasa selain bahasa Inggris

Dalam penelitian ini, peneliti mengidentifikasi 30 paper dari berbagai sumber literatur yang relevan antara tahun 2019 hingga 2023. Setelah melalui proses evaluasi, ditemukan bahwa 10 di antaranya tidak memenuhi standar kualitas yang diperlukan untuk dimasukkan dalam analisis lebih lanjut. Oleh karena itu, hanya 20 paper yang memenuhi kriteria untuk disertakan dalam tinjauan tersebut. Penyaringan ini dilakukan untuk memastikan bahwa hanya paper-paper berkualitas yang relevan dengan ruang lingkup penelitian yang disertakan dalam analisis.

3 Hasil dan pembahasan

Studi ini merangkum hasil dari serangkaian penelitian yang bertujuan untuk meningkatkan kemampuan identifikasi spesies ular melalui pendekatan computer vision dalam rentang waktu antara tahun 2019 hingga 2023. Penelitian tersebut melibatkan implementasi berbagai strategi penelitian dalam mengatasi tantangan pengenalan objek ular secara otomatis. Data yang didapatkan dari penelitian tersebut dapat memberikan pemahaman yang lebih baik tentang berbagai pendekatan dan model yang digunakan dalam identifikasi ular menggunakan teknologi computer vision. Dan diharapkan dapat dilakukan pengembangan lebih lanjut dalam bidang ini, termasuk peningkatan kinerja model-model yang ada, eksplorasi pendekatan baru, dan penerapan solusi-solusi yang lebih efektif dalam upaya melindungi populasi ular dan manusia. Hasil analisis data tersebut ditampilkan pada Tabel 2.

■ **Tabel 2** Hasil Penelitian

No	Tahun	Dataset	Data Split	Jumlah Kelas	Algoritma	Akurasi	Sitasi
1	2021	1766	80:20	2	Inception Net	82.38	[9]
					VGG19	43.75	
					ResNet50	81.81	
					Xception Net	80.94	
					MobileNet V2	82.35	
					Inception-Resnet-v2	89.62	
					VGG 16	62.50	
2	2021	594	80:20	6	Proposed Model	90.50	[3]
					MobileNet V2	93.00	
3	2021	16.483 42,688 248 248	-	45 45 45 27	VGG 16	78.00	[6]
					Efficient Net	87.00	
					Human-labelled	84.00	
					ResNet	73.00	
4	2020	247	211:36	9	ResNet	75.00	[10]
			211:36		InceptionV2	70.00	
			230:50		VGG 16	70.00	
			237:10		Mobile Net	10.00	
5	2020	409.670	386.006:23.673	772	Vision Transformer	96.00	[11]
				269	YOLO v3	96	
					Tiny YOLO	77.08	
6	2021	1027	9:1	11	SSD MobileNet	66.23	[12]
					SSD VGG16	63.24	
					Faster RCNN ResNet	55.56	
					RetinaNet	81.62	
7	2021	409.679	90:10	772	Efficient Net & ViT	33.94	[13]
8	2023	196.332	168.144:28.188	1784	ConvNeXt V2 CNN	82.88	[14]
9	2022	318.532	270.251:48.281	1572	EfficientNet-L2, BEiT-L, EfficientNet- B7, dan Swin-L	81.90	[15]
10	2020		245.185	783	EfficientNet-B4	78.27	[16]
11	2021	409.679	90:10	772	EfficientDet and Effi- cientNet	59.40	[17]
12	2021	409,679	90:10	772	ResNeSt, ResNeXt, dan ResNet	95.00	[18]
13	2021	409.679	347.405:38.601	772	Single ResNeXt-50- V2	91.60	[19]
14	2021	414,424	-	772	ResNet-18	85.77	[20]
15	2023	182.261	-	1.784	Data Efficient Image Transformers	86.00	[21]
16	2019	415	-	5	CNN	72.00	[22]
17	2020	3050	-	28	DenseNet	82.00	[23]
					MobileNet	72.00	
					VGG 16	58.65	
18	2022	318.532	270.251:48.281	1572	ResNet101	12.28	[24]
					EfficientNetB0	89.11	
					EfficientNetB4	86.01	
					EfficientNetB6	80.86	
19	2019	200	2:1	84	ResNeXt101	79.81	[25]
					Siamese	78.64	
20	2020	245.185		783	ResNet 50-v2	05.00	[26]

Analisis data yang disajikan dalam Tabel 2 menunjukkan adanya variasi yang signifikan dalam ukuran dataset yang digunakan. Jumlah dataset yang relatif kecil sebanyak 415 hingga dataset yang besar yaitu sebanyak 409,679. Perbedaan ini mencerminkan ketersediaan sumber daya, kompleksitas spesies yang diteliti, serta tujuan dari penelitian yang dilakukan. Jumlah keseluruhan dataset tersebut kemudian dibagi menjadi 2, yaitu pembagian data antara tahap pelatihan dan pengujian. Pembagian data ini juga menjadi pertimbangan penting. Dalam beberapa literatur disebutkan perbandingan pembagian data yang variatif, seperti 80:20, 90:10, dan beberapa sumber tidak menyebutkan bagaimana perbandingannya.

Selain itu, berbagai metode pra-pemrosesan telah diterapkan untuk meningkatkan kualitas data dan memperluas keragaman dataset. Teknik augmentasi gambar, seperti rotasi, *zoom*, kontras, dan *flip*, serta beberapa tahapan *pre-processing* juga digunakan dalam beberapa penelitian. Hal ini menyoroti pentingnya pemrosesan data yang cermat dalam mencapai kinerja optimal pada model-model yang dikembangkan.

Model-model yang diuji mencakup berbagai arsitektur yang umum digunakan dalam computer vision, seperti Inception Net, MobileNet, Efficient Net, dan YOLO. Evaluasi model-model ini menghasilkan tingkat akurasi yang beragam, berkisar dari sekitar 10% hingga 99%. Selain metode yang umum digunakan, beberapa penelitian juga menggabungkan metode tertentu atau merubah arsitektur dari sebuah metode. Terdapat salah satu penelitian yang menambahkan penggunaan dropout pada lapisan-lapisan padat (*dense layers*) untuk mencegah *overfitting*, serta penambahan lapisan *max-pooling* dan dropout yang spesifik untuk mengatasi tugas identifikasi spesies ular menggunakan teknologi pengolahan citra komputer [9].

Modifikasi arsitektur tersebut kemudian dibandingkan dengan metode deep learning lainnya dan menghasilkan nilai akurasi tertinggi. Sehingga dapat diketahui bahwa pemilihan algoritma klasifikasi yang sesuai dengan karakteristik data dan jenis identifikasi yang diinginkan juga mempengaruhi akurasi. Algoritma yang cocok akan mampu menangani pola-pola kompleks dalam data dengan lebih baik. Arsitektur model dari algoritma yang dipilih juga berpengaruh terhadap hasil akhir akurasi model. Beberapa arsitektur seperti Inception, ResNet, MobileNet, dan VGG16 memiliki karakteristik yang berbeda-beda, termasuk kemampuan dalam menangani kompleksitas dan variasi dalam gambar [10].

Dalam kompetisi SnakeCLEF 2021, *Biomedical Computer Science Group* menggabungkan hasil dari model ViT Large dan model EfficientNet-B4, dengan menghitung rata-rata prediksi probabilitas softmax-scaled dari kedua model tersebut [13]. Penggabungan model tersebut memiliki hasil yang lebih baik dibandingkan dengan hasil dari model-model individual, dengan hasil akurasi 82.88% [13]. Sementara itu, nilai akurasi tertinggi yang dihasilkan adalah 99% pada level genus yang juga dicapai dalam kompetisi SnakeCLEF 2021 [11]. Pemilihan arsitektur model yang tepat dalam pengujian ini juga memengaruhi akurasi dan efektivitas identifikasi. Dalam studi ini, penggunaan Vision Transformer (ViT), yang merupakan arsitektur jaringan saraf terbaru dengan kinerja klasifikasi gambar yang unggul, telah membantu dalam mencapai tingkat akurasi yang tinggi [11].

Selain pemilihan arsitektur, pengujian dalam [11] juga melakukan beberapa tahap pra-pemrosesan data, yaitu diantaranya data *cleaning*, data *augmentation*, *test time augmentation*, serta penambahan informasi geografis dari jenis-jenis ular. Hal ini menunjukkan pentingnya tahapan *pre-processing* dalam proses pelatihan model untuk meningkatkan kualitas data. Kualitas dataset yang digunakan dalam pelatihan algoritma sangat memengaruhi akurasi dan efektivitas identifikasi! [3].

Dataset yang lengkap, representatif, dan berkualitas tinggi akan menghasilkan model yang lebih baik, sedangkan dataset yang terbatas atau tidak representatif dapat menye-

babkan model tidak mampu mengenali variasi spesies ular dengan baik. Proses preprocessing seperti augmentasi data atau penghapusan latar belakang dapat mempengaruhi hasil akhir. Metode ekstraksi fitur yang digunakan dalam proses pra-pemrosesan dataset juga memainkan peran penting. Metode yang tepat dapat membantu mengekstrak fitur-fitur yang relevan dan membedakan antara spesies ular dengan lebih baik [3]. Jika preprocessing tidak dilakukan dengan benar, informasi penting dalam gambar mungkin hilang atau terdistorsi [10].

Penyetelan parameter algoritma yang optimal merupakan tahapan yang sangat penting untuk mencapai akurasi yang tinggi. Parameter yang salah dapat mengakibatkan *overfitting* atau *underfitting*, yang akan merugikan kinerja model [3]. Karenanya, *hyperparameter tuning* yang dilakukan memiliki dampak besar pada kinerja arsitektur CNN. Penggunaan optimizers seperti Adam, Adamax, dan SGD dengan jumlah epoch yang sesuai serta learning rate yang tepat mempengaruhi performa model uji secara signifikan [9]. Penyesuaian yang tepat dari hyperparameter merupakan proses yang memakan waktu dan memerlukan pengetahuan yang mendalam tentang arsitektur model [3].

Selain dalam proses pelatihan model, ditemui beberapa kesulitan dan keterbatasan. Salah satu keterbatasan yang menjadi penghambat utama adalah terbatasnya jumlah data yang tersedia untuk pelatihan. Khususnya untuk spesies ular yang jarang atau langka, sulit untuk mengumpulkan dataset yang cukup besar untuk melatih model yang akurat [3]. Ketergantungan pada kualitas gambar juga menjadi faktor penting. Gambar yang buram atau berkualitas rendah dapat menghambat ekstraksi fitur yang akurat, yang pada gilirannya mempengaruhi kinerja algoritma identifikasi, terutama jika dataset pelatihan terdiri dari gambar-gambar yang tidak konsisten dalam kualitasnya. Variasi dalam pencahayaan dan latar belakang dapat memengaruhi kualitas gambar dan kemampuan algoritma untuk mengidentifikasi ular dengan akurat. Gambar-gambar dengan latar belakang yang kompleks dapat menyulitkan proses identifikasi. Model mungkin kesulitan membedakan ular dari latar belakang yang ramai atau berubah-ubah [10]. Sehingga algoritma harus mampu menyesuaikan diri dengan kondisi lingkungan yang berbeda.

4 Kesimpulan

Studi ini menggambarkan serangkaian penelitian dari tahun 2019 hingga 2023 yang bertujuan untuk meningkatkan kemampuan identifikasi spesies ular melalui pendekatan *computer vision*. Penelitian tersebut melibatkan implementasi berbagai strategi untuk mengatasi tantangan pengenalan objek ular secara otomatis. Data dari penelitian ini memberikan pemahaman yang lebih baik tentang berbagai pendekatan dan model yang digunakan dalam identifikasi ular menggunakan teknologi *computer vision*. Hasil penelitian menyoroti pentingnya pemrosesan data yang cermat, pemilihan arsitektur model yang tepat, serta penyesuaian parameter algoritma yang optimal dalam mencapai kinerja maksimal pada model-model yang dikembangkan. Strategi pelatihan model juga berkontribusi pada tingkat akurasi, dengan penggunaan metode pelatihan yang sesuai seperti algoritma optimasi yang tepat, penjadwalan laju pembelajaran yang adaptif, dan teknik augmentasi data.

Evaluasi sejauh mana sistem otomatis mendekati keahlian manusia dalam identifikasi ular tetap menjadi tantangan, yang memerlukan perbandingan kinerja antara algoritma berbasis mesin dengan ahli manusia. Beberapa penelitian menunjukkan bahwa penggabungan model dapat meningkatkan akurasi identifikasi secara signifikan. Namun, penelitian juga menghadapi keterbatasan seperti keterbatasan data, variasi kualitas gambar, kompleksitas morfologi ular, dan variasi pose yang tinggi. Diperlukan pengembangan lebih lanjut untuk

memperbaiki kinerja model, mengatasi keterbatasan tersebut, dan meningkatkan kolaborasi antara bidang *computer vision*, biologi, dan konservasi ular. Yang mencakup pengumpulan dataset berkualitas tinggi, evaluasi arsitektur model, dan penyesuaian parameter algoritma. Kolaborasi antarbidang penelitian dan berbagi pengetahuan juga diperlukan untuk mengatasi keterbatasan data, variasi kualitas gambar, dan kompleksitas morfologi ular.

Pustaka

- 1 D. A. Warrell, *Guidelines for the management of snake-bites*. Geneva: World Health Organization.
- 2 I. Bolon, A. M. Durso, S. Botero Mesa, N. Ray, G. Alcoba, F. Chappuis, and R. Ruiz de Castañeda, "Identifying the snake: First scoping review on practices of communities and healthcare providers confronted with snakebite across the world," *PLoS one*, vol. 15, no. 3, p. e0229989, 2020.
- 3 M. Rajabizadeh and M. Rezghi, "A comparative study on image-based snake identification using machine learning," *Scientific reports*, vol. 11, no. 1, p. 19142, 2021.
- 4 S. E. Henke, S. S. Kahl, D. B. Wester, G. Perry, and D. Britton, "Efficacy of an online native snake identification search engine for public use," *Human-Wildlife Interactions*, vol. 13, no. 2, p. 14, 2019.
- 5 G. Stockman and L. G. Shapiro, *Computer vision*. Prentice Hall PTR, 2001.
- 6 A. M. Durso, G. K. Moorthy, S. P. Mohanty, I. Bolon, M. Salathé, and R. Ruiz de Castañeda, "Supervised learning computer vision benchmark for snake species identification from photographs: Implications for herpetology and global health," *Frontiers in artificial intelligence*, vol. 4, p. 582110, 2021.
- 7 P. Brereton, B. A. Kitchenham, D. Budgen, M. Turner, and M. Khalil, "Lessons from applying the systematic literature review process within the software engineering domain," *Journal of systems and software*, vol. 80, no. 4, pp. 571–583, 2007.
- 8 K. S. Khan, R. Kunz, J. Kleijnen, and G. Antes, "Five steps to conducting a systematic review," *Journal of the royal society of medicine*, vol. 96, no. 3, pp. 118–121, 2003.
- 9 N. I. Progga, N. Rezoana, M. S. Hossain, R. U. Islam, and K. Andersson, "A cnn based model for venomous and non-venomous snake classification," in *Applied Intelligence and Informatics: First International Conference, AII 2021, Nottingham, UK, July 30–31, 2021, Proceedings 1*. Springer, 2021, pp. 216–231.
- 10 A. Patel, L. Cheung, N. Khatod, I. Matijosaitiene, A. Arteaga, and J. W. Gilkey Jr, "Revealing the unknown: Real-time recognition of galápagos snake species using deep learning," *Animals*, vol. 10, no. 5, p. 806, 2020.
- 11 I. Bolon, L. Picek, A. M. Durso, G. Alcoba, F. Chappuis, and R. Ruiz de Castañeda, "An artificial intelligence model to identify snakes from across the world: Opportunities and challenges for global health and herpetology," *PLoS neglected tropical diseases*, vol. 16, no. 8, p. e0010647, 2022.
- 12 L. Bloch, A. Boketta, C. Keibel, E. Mense, A. Michailutschenko, O. Pelka, J. Rückert, L. Willemeit, and C. M. Friedrich, "Combination of image and location information for snake species identification using object detection and efficientnets." in *CLEF (Working Notes)*, 2020.
- 13 L. Bloch and C. M. Friedrich, "Efficientnets and vision transformers for snake species identification using image and location information." in *CLEF (Working Notes)*, 2021, pp. 1477–1498.
- 14 Z. Yang and R. Sinnott, "Snake detection and classification using deep learning." in *Proceedings of the 54th Hawaii International Conference on System Sciences*, 2021.

- 15 B. Bracke, M. Bagherifar, L. Bloch, and C. M. Friedrich, “Joint feature learning of image data with embedded metadata to leverage snake species classification,” 2023.
- 16 R. Borsodi and D. Papp, “Incorporation of object detection models and location data into snake species classification.” in *CLEF (Working Notes)*, 2021, pp. 1499–1511.
- 17 J. Yu, H. Chang, Z. Cai, G. Xie, L. Zhang, K. Lu, S. Du, Z. Wei, Z. Liu, F. Gao *et al.*, “Efficient model integration for snake classification.” in *CLEF (Working Notes)*, 2022, pp. 2262–2274.
- 18 R. Chamidullin, M. Šulc, J. Matas, and L. Pícek, “A deep learning method for visual recognition of snake species,” 2021.
- 19 L. Kalinathan, P. Balasundaram, P. Ganesh, S. S. Bathala, and R. K. Mukesh, “Automatic snake classification using deep learning algorithm.” in *CLEF (Working Notes)*, 2021, pp. 1587–1596.
- 20 L. G. Coca, A. T. Popa, R. C. Croitoru, L. P. Bejan, and A. Iftene, “Uaic-ai at snakeclef 2021: Impact of convolutions in snake species recognition.” in *CLEF (Working Notes)*, 2021, pp. 1540–1546.
- 21 A. Balana, “Metric weighted ensemble focal loss for snake species identification,” 2023.
- 22 I. S. Abdurrazaq, S. Suyanto, and D. Q. Utama, “Image-based classification of snake species using convolutional neural network,” in *2019 International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*. IEEE, 2019, pp. 97–102.
- 23 M. Vasmatkar, I. Zare, P. Kumbala, S. Pimpalkar, and A. Sharma, “Snake species identification and recognition,” in *2020 IEEE Bombay Section Signature Conference (IBSSC)*. IEEE, 2020, pp. 1–5.
- 24 M. Palaniappan, K. Desingu, H. Bharathi, E. A. Chodisetty, and A. Bhaskar, “Deep learning and gradient boosting ensembles for classification of snake species,” in *CEUR Workshop Procding*, vol. 3180, 2022, pp. 2175–88.
- 25 C. Abeysinghe, A. Welivita, and I. Perera, “Snake image classification using siamese networks,” in *Proceedings of the 3rd International Conference on Graphics and Signal Processing*, 2019, pp. 8–12.
- 26 M. G. Krishnan, “Impact of pretrained networks for snake species classification.” in *CLEF (Working Notes)*, 2020.