

テーマ番号	1EP180				
プロジェクト テーマ	和文	深層学習に基づく野生動物の「見える化」技術に関する研究		指導教員	長田 茂美 教授
	英文	Studies on wildlife habitat visualization using image recognition based on deep learning			
プロジェクト メンバー	4EP1-07	大谷 直也 (Naoya Otani)	4EP2-40	西本 圭佑 (Keisuke Nishimoto)	
	4EP2-03	犬塚 博俊 (Hiroto Inuzuka)			

Abstract In recent years, crop damage by wildlife has become a serious social problem in Japan. In order to solve this problem, it is necessary to understand wildlife habitat, that is, its active time, location and species about appearing of wildlife. For this purpose, a camera trap which takes pictures when a sensor detects object motion is used. However, it results in a large burden for researchers to identify the species of wildlife from a huge number of images. In this study, we improve the system that was developed in Nagata's laboratory for automatic wildlife species recognition from images based on deep learning technology. Our system realized a higher recognition accuracy (93%) than previous one (64%) by introducing a more sophisticated deep learning model and developing wildlife detection and super-resolution technologies.

Keywords wildlife, deep learning, convolutional neural network, semantic segmentation, super-resolution.

1. まえがき

野生動物による農作物被害は毎年約 200 億円にのぼり、深刻な社会問題となっている^[1]。その対策を講じるためには、どのような種の野生動物がいつ、どこに現れるかといった生息情報の調査が必要であり、カメラトラップ（定点自動撮影カメラ）画像が活用されている。しかし、調査者が大量の画像を目視で確認し、動物が写っている画像を見つけ、その種を判定する労力の大きさが問題となっていた。

この問題を解決するために、長田研究室では、深層学習を用いて画像内の野生動物の種を自動認識するシステムを開発し、継続的な認識精度の向上を図っている。

本研究では、さらなる認識精度の向上を目指して、従来システムの「領域検出」、および、「種認識」の処理を改良するとともに、野生動物の在/不在を認識して在の画像のみを種認識の対象とする処理、および、超解像により画像を高解像度化して認識精度の向上を図る処理を新たに導入し、評価実験を実施した。

2. 提案システム

図 1 に、本研究で提案したシステムの概要を示す。提案システムは、「在/不在認識」、「領域検出」、「超解像」、「種認識」の処理から構成される。

2.1 在/不在認識

カメラトラップ画像には、野生動物が写っている在の画像だけでなく、写っていない不在の画像が多く含まれており、調査者の労力の大きさが問題となっている。この在/不在を認識し、不在の画像を調査者の確認対象から外せば調査者の労力を軽減できる。また、従来システム^[3]では、不在の画像も領域検出や種認識で処理していたが、不在の画像の背景領域を野生動物と誤って検出し、認識する場合があった。そこで、在の画像のみを処理することで領域検出や種認識の精度の向上も期待できると考え、画像認識分野で高い認識精度を実現している ResNet50^[2]を用いて在/不在認識を実現した。




図 1 提案システムの概要

Fig. 1 Overview of the proposed system.

2.2 領域検出

従来システムでは、深層学習のセマンティックセグメンテーション手法である SegNet を用い、野生動物の領域を検出し (図 1)、種認識の入力としていた^[3]。しかし、検出精度は十分ではなかった。そこで、より高精度な領域検出の実現を考え、医療分野の細胞画像向け応用で実績のある U-Net^[4]を採用して、検出精度の向上を試みた。

2.3 超解像

従来システムでは、カメラトラップ画像上で小さく写っている野生動物の種認識の精度が低い場合があり、その原因として野生動物の領域の解像度が著しく低いことが考えられた。そこで、深層学習による超解像の処理を導入し、領域検出結果の画像を高解像度化することで種認識の精度向上を試みた。超解像の手法としてはさまざまな提案がなされているが、FSRCNN^[5]は処理が高速であり、かつ精度も高いことから採用した。

2.4 種認識

ここまで述べてきた在/不在認識と超解像の導入や領域検出の改良に加え、種認識の処理自体の改良を試みた。まず、従来システムでは、畳み込みニューラルネットワークのモデルの一つである AlexNet^[6]を用いていたが、より高精度な認識が期待できる ResNet50^[2]を採用し、学習回数やミニバッチサイズなどのパラメータチューニングを実施した。さらに、転移学習の導入、データ拡張の見直しを行い、従来システムと同じ 10 種の野生動物の種認識を実現した。

3. システム評価

3.1 データセット

従来システムと同様に、石川県農林総合研究センター林業試験場に設置された 6 台のカメラトラップの画像を使用した。在/不在認識と種認識の深層学習で用いる正解データは石川県立大学から提供を受け、領域検出と超解像の正解データは長田研究室で作成した。

提案システムの評価実験は、以上の画像と正解データから成るデータセットを学習データとテストデータに分けて実施した。評価実験に用いた学習データの画像は、在/不在認識では 5798 枚、領域検出では 1354 枚、種認識と超解像では 3540 枚である。一方、評価実験に用いたテストデータの画像は、在/不在認識では 509 枚、領域検出では在/不在認識の処理で在と認識された 151 枚である。また、超解像と種認識で用いた画像は領域検出で野生動物の領域が検出できた 135 枚である。

3.2 在/不在認識の評価

評価指標として、次式(1)で定義される適合率と次式(2)で定義される再現率を用いた。

$$\text{適合率} = \frac{\text{認識結果が A で正解も A であるデータ数}}{\text{認識結果が A であるデータ数}} \quad (1)$$

$$\text{再現率} = \frac{\text{認識結果が A で正解も A であるデータ数}}{\text{正解が A であるデータ数}} \quad (2)$$

ここで、A は認識すべきクラスを表し、在/不在認識では A は“在”を表す。式(1)の適合率は認識結果の正確さを表し、式(2)の再現率は正解データを漏れなく正しく認識できるかの度合いを表す。評価の結果、適合率は 87%であり、在としたうちの約 9 割は正解であった。また、再現率は 98%であり、在の画像をほぼ漏らさず認識できることが確認できた。

3.3 領域検出の評価

領域検出の評価指標には、次式(3)で定義される IoU(Intersection over Union)を用いた。

$$\text{IoU} = \frac{\text{検出領域かつ正解領域の画素数}}{\text{検出領域または正解領域の画素数}} \quad (3)$$

IoU は、領域検出の処理結果である検出領域と実際に野生動物が写っている正解領域との一致度合いを表し、完全に一致する場合は 1.0、一致部分がない場合は 0.0 となる。表 1 に、評価結果を示す。従来システムとの比較のために、SegNet の評価結果も併記した。U-Net は IoU の評価指標で 0.8 を超えており、非常に高い精度を示し、SegNet よりも大幅な精度向上が図れた。また、領域検出精度を評価するために、画素単位の検出漏れや誤検出の大きさも調べた。画素ごとに野生動物の領域として正しく認識されているか否かを調べ、そこから領域検出した野生動物の画像枚数を適合率および再現率で算出した。U-Net の検出漏れは、野生動物の画像枚数の 4%、誤検出は野生動物の画像枚数の 31%であった。この範囲のずれであれば、種認識のための入力画像を切り出す用途としては十分であり、U-Net を用いた領域検出の有用性が確認できた。

3.4 超解像・種認識の評価

種認識は、次式(4)で定義される正解率と種ごとの適合率、再現率の平均を用いて評価した。また、超解像の処理による認識精度向上の効果を評価するため、超解像の処理を行わない場合とも比較した。表 2 に、評価結果を示す。

$$\text{正解率} = \frac{\text{正解のデータ数}}{\text{総データ数}} \quad (4)$$

評価の結果、従来システムの正解率 64%^[3]に対し、提案システムの正解率は 93%であり、認識精度の向上が図れた。種ごとの平均の適合率、再現率は概ね高い精度であったが、イノシシ、ニホンアナグマ、ニホンカモシカは他の種に比べて低い精度であった。この 3 種の認識失敗画像を目視で確認したところ、野生動物の体の一部しか写っていない画像が多くみられた。この問題は今回の手法の改良だけでは対応できなかったが、認識対象の写り方の多様性が原因であり、動物の体の一部しか写っていない状況の学習データを拡充することにより解決し、種認識の精度向上が図れると考えられる。

表 1 領域検出の評価結果

Table 1 Evaluation of wildlife area detection.

	SegNet	U-Net
IoU	0.66	0.84
適合率[%]	43	69
再現率[%]	100	96

表 2 超解像・種認識の評価結果

Table 2 Evaluation of wildlife species recognition.

	超解像なし		超解像あり	
	適合率 [%]	再現率 [%]	適合率 [%]	再現率 [%]
ツキノワグマ	100	100	100	100
イノシシ	78	90	86	90
ニホンタヌキ	96	92	100	96
ニホンアナグマ	100	75	100	75
ニホンザル	100	100	100	67
ホンドテン	94	100	94	100
ニホンカモシカ	78	93	70	93
ハクビシン	100	100	100	100
アカギツネ	100	90	100	95
ニホンシカ	100	100	100	100

超解像なし/ありの比較については、種認識の正解率は超解像なしが 92%、超解像ありが 93%であった。種ごとの適合率、再現率では、イノシシとニホンタヌキ、アカギツネで精度向上が図れた。一方、ニホンザルとニホンカモシカの精度は低下した。これは、ニホンザルの画像が他の種に比べて極端に少ないことが原因であり、超解像で起こり得る輝度変化も考慮した学習データを拡充することにより解決できるものと考えられる。

4. 考察

在/不在認識の評価結果より、野生動物が不在の画像の 98%近くを調査者の確認対象から外せることが確認できた。カメラトラップ画像のうち、不在画像は 2/3 を占めるため、調査者の労力を 70%程度軽減できることになる。さらに、超解像を用いた種認識により、調査者が在の画像から種を判定してシステムに入力する労力の 93%を削減できることが確認できた。従来システムでは 64%の削減であったため、大幅な労力軽減の効果を示すことができた。

5. あとがき

本研究では、カメラトラップ画像から野生動物の種を認識する従来システムを改良し、評価実験により、その有用性を確認した。今後は、さらなる認識精度の向上を目指し、野生動物の写り方の違いに影響されない実用的なシステムへと発展させていきたい。最後に、カメラトラップ画像データをご提供頂いた石川県立大学の北村俊平准教授、石川県農林総合研究センターの関係各位に感謝いたします。

参考文献

- [1] 農林水産省, “鳥獣被害の現状と対策,” 農村振興局, (2019).
- [2] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun, “Deep Residual Learning for Image Recognition,” arXiv:1512.03385, (2015).
- [3] 大角和希, “深層学習に基づく野生動物の「見える化」技術に関する研究,” 平成 30 年度プロジェクトデザインⅢ公開発表審査会予稿集, EP168, (2019).
- [4] Zongwei Zhou, Md Mahfuzur Rahman Siddiquee, Nima Tajbakhsh, Jianming Liang, “UNet++: A Nested U-Net Architecture for Medical Image Segmentation,” arXiv:1807.10165, (2018).
- [5] Chao Dong, Chen Change Loy, Xiaoou Tang, “Accelerating the Super-Resolution Convolutional Neural Network,” arXiv:1608.00367v1, (2016).
- [6] Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks,” NIPS, Vol. 25, (2012).

本プロジェクトに関する業績

- 1) 上原祐介, 大谷直也, 西本圭佑, 川崎邦将, 松井康浩, 長田茂美, 北村俊平, 矢田豊, “深層学習に基づく野生動物認識システム,” 中部森林研究, (2020)(投稿中).