

## 深層学習に基づく野生動物認識システム

上原 祐介・大谷 直也・西本 圭佑・川崎 邦将・松井 康浩・長田 茂美（金沢工業大学）・  
北村 俊平（石川県立大学）・矢田 豊（石川県農林総合研究センター）

野生動物の保護管理への対策を講じるためには、野生動物の生息状況の調査が必須である。このため、カメラトラップを用いた調査が行われているが、大量に撮影される画像を調査者が確認して、野生動物を見つけ出し、種を同定する労力の大きさが問題となっている。この問題を解決するため、深層学習に基づいて、画像から野生動物の在/不在や種を認識し、画像上の領域とともに提示することで、調査者の労力を軽減する野生動物認識システムを構築した。石川県農林総合研究センター林業試験場で撮影した画像を用いて本システムを評価した結果、野生動物の種の同定作業の6割以上の労力が削減可能であり、調査者の労力軽減に有用であることが示された。  
キーワード：野生動物認識、カメラトラップ、深層学習、画像認識、セマンティックセグメンテーション

### I はじめに

日本国内の野生動物による農作物への被害は、平成30年度には約160億円にのぼり、深刻な社会問題となっている(9)。また、植栽木の食害などによる林業被害も深刻であり、平成23年度から平成29年度までの被害範囲は毎年約7,000～9,000 haに及んでいる(13)。この問題に対し、国や自治体では、野生動物の生息状況を把握し、防除や捕獲などによる適切な管理を実現することが急務となっている。その一方で、絶滅の恐れがある種の保護や生物多様性の保全への施策も必要である(7)。野生動物は人間の存続の基盤である森林の自然環境の一部を構成しており、人々に多くの恩恵も与えている。さまざまな野生動物の生息環境の確保に努めていくことが必要である(6)。

野生動物の保護管理に対して有効な対策を講じるためには、野生動物が出現する場所、時間や種に関する生息状況を調査し、得られた情報を活用することが必須である(5)。このため、直接観察や足跡、食痕の痕跡調査などの方法があるが、近年、カメラトラップを活用した調査が行われている(12)。カメラトラップとは、動く物体を赤外線センサなどで検知して自動撮影するカメラのことである(4)。カメラトラップを用いる方法は、他の調査方法と比べて、調査者がその場にいなくても非常に正確なデータを記録できること、野生動物を攪乱することなく観察できること、長時間の連続的なモニタリングが可能であることなどの利点があり、生息状況調査の非常に有用な方法となっている。

しかし、カメラトラップにより膨大な画像が入手できるようになることで、調査者が目視で画像を判定する労力の大きさが問題となってきている。今後、大量の画像を用いてより詳細な調査ができるようになったとしても、調査者の作業が追い付かなくなることが問

題となる。この問題に対し、コンピュータビジョン分野の画像認識技術を用いて、画像中の野生動物の在/不在や種などを自動認識し、調査者の作業を支援する方法がある。特に、近年の画像認識手法の主流であり、極めて高い認識精度を実現している深層学習(11)を活用する方法が提案されている(1, 10)。

Norouzzadehらは、タンザニア連合共和国のセレンゲティ国立公園で撮影された画像群を対象に、野生動物の在/不在、種や頭数の認識器を構築している(10)。しかし、この先行研究が対象としている野生動物は、日本の森林に生息する野生動物とは異なり、また、野生動物の背景として写る情景も日本の森林とは異なることが多い。このため、この先行研究で構築された認識器を日本の森林の野生動物にそのまま適用することは難しい。一方、安藤らは、国内の森林の野生動物を対象に、野生動物の在/不在、種や頭数に対する認識器を構築し、有用性を検証している(1)。しかし、この先行研究では、画像中の野生動物の領域検出については触れられていない。野生動物が小さく写っている場合や背景との見分けがつきにくい場合に、画像上の野生動物の領域を提示することは、調査者の労力軽減に有用であり、そのためには野生動物の領域検出が必要となる。また、この先行研究の種認識の評価では、比較的大型のニホンジカ、イノシシ、ニホンカモシカ、ツキノワグマの4種を対象としているが、中型も含めたより多種を同時に認識した場合の評価には触れられていない。

本研究では、深層学習に基づく手法により、カメラトラップ画像から野生動物の在/不在や種を認識し、さらに画像上の野生動物の領域も検出する野生動物認識システムを構築した。また、本システムの有用性を評価するため、国内の森林に設置したカメラトラップの

UEHARA Yusuke\*, OTANI Naoya, NISHIMOTO Keisuke, KAWASAKI Kunimasa, MATSUI Yasuhiro, NAGATA Shigemitsu, KITAMURA Shumpei, YADA Yutaka

A wildlife recognition system based on deep learning

b7900040@planet.kanazawa-it.ac.jp

画像を用い、大型と中型を含む 10 種の野生動物を対象とした評価を試みた。

## II 方法

### 1. 材料

野生動物認識システムを構築し、調査者の労力軽減に対する有効性を評価するため、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用いた。画像の解像度は、縦が 1920 ピクセル、横が 2560 ピクセルであり、撮影時期は、2015 年から 2017 年までの画像である。撮影日時については、天候や日照の変化による画像の写り方の多様性に対応するため、年間を通して各月の画像が含まれるようにし、また、昼夜を問わず評価するため、夜間は撮影時にフラッシュを点灯する方式で撮影した画像を用いた。

深層学習により画像認識や領域検出を実現するためには、認識や検出したい対象に関する情報を正解データとして用意し、対応する画像に紐づけておく必要がある。本研究では、在/不在、種、領域の各々について正解データを作成し、画像に紐づけた。在/不在については、調査者が画像を目視して、在あるいは不在のラベルを紐づけた。種については、農林業への影響が大きいと考えられる大型と中型の種から表-1 に示す 10 種を対象に選択し、調査者が画像を目視して、その種の名称をラベルとして紐づけた。領域については、著者らが画像を目視し、野生動物の領域の画素を選択することで正解データを作成して紐づけた。

### 2. 野生動物認識システム

図-1 に、本研究で構築したシステムの構成を示す。本システムは、在/不在認識器、種認識器、領域検出器とこれらを深層学習により構築するための画像データ、正解データから成る。本システムの動作は、在/不在認識器、種認識器、領域検出器を深層学習で構築する構築フェーズと構築後に調査者が利用する利用フェーズに分かれる。

表-1. 本研究で対象とした野生動物の種

大型	ツキノワグマ、イノシシ、 ニホンカモシカ、ニホンジカ
中型	ニホンザル、ホンドテン、 ニホンアナグマ、ニホンタヌキ、 ハクビシン、アカギツネ

利用フェーズでは、調査対象のカメラトラップ画像とその撮影日時および場所が入力される（撮影日時はカメラトラップから得られ、撮影場所はカメラトラップの設置場所を調査者が予め入力する）。入力されたカメラトラップ画像に対して、まず初めに、在/不在認識を実行し、在と認識された画像のみを後段の処理に渡す。これにより、野生動物が写っていない画像を確認する無駄な作業を省くことができる。次に、種認識を実行し、野生動物の種のラベルを端末の画面に表示する。また、領域検出を実行し、野生動物の領域の外接矩形をカメラトラップ画像に重畳して表示する。調査者はこの表示を確認し、種ラベルが正しいければ、特別な操作をすることなく野生動物の種を撮影日時、場所と合わせて生息状況記録データとして格納できる。表示された種ラベルが誤っていた場合は、調査者が正しい種ラベルを入力する。このため、誤認識が少ないほど調査者の労力は軽減されることになる。

次に、以上の機能を実現するために、構築フェーズにおいて在/不在認識器、種認識器、領域検出器を構築する方法について述べる。

在/不在認識器は、深層学習の畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) の一つである ResNet50 (3) を用いて構築した。ResNet50 は、コンピュータビジョン分野で著名な画像認識コンテスト ILSVRC (ImageNet Large Scale Visual Recognition Challenge) の 2015 年の検出・分類部門で優勝をおさめるなど高い認識精度を実現しており、野生動物認識の関連研究 (1, 10) でも有用性が示されていることから採用した。また、深層学習では学習用のデータが多い

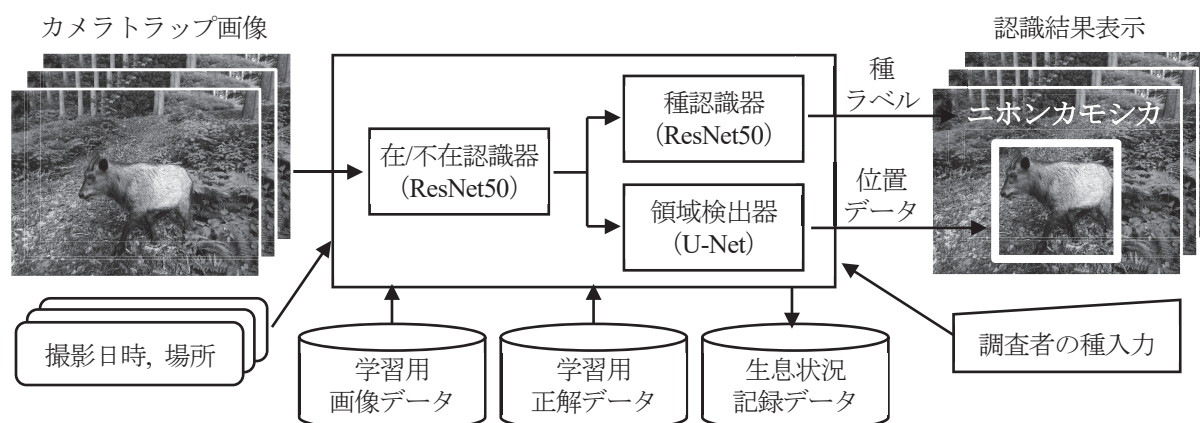


図-1. 野生動物認識システムの構成

ほど認識精度の向上が図れるため、1,000 万枚以上の画像データと正解データから成る ImageNet (2) のデータを用いた転移学習 (8) を採用した。ImageNet には野生動物のデータも多数含まれているため、本研究のデータだけでは学習できない多様な写り方をする野生動物の特徴を転移学習という形で学習に取り込んでいる。さらに、本研究で収集した画像に対し、左右反転画像を生成して学習データに加えるデータ拡張 (11) を行った。これにより、元のカメトラップ画像とは向きの異なる写り方の野生動物の画像特徴も学習可能とすることで、認識精度の向上を試みた。以上の方法で学習した画像特徴に基づいて在/不在の認識結果を出力するため、ResNet50 の出力層は 1 つのユニットで構成し、活性化関数としてシグモイド関数 (11) を用いた。これにより、在/不在認識器にカメトラップ画像が入力されると、野生動物が在である確率が 0 から 1 の間の連続値として出力される。ResNet50 の出力値が 0.5 以上のときに在、0.5 未満のときに不在のラベルを在/不在認識器の出力とする。

種認識器は、在/不在認識器と同様の方法で ResNet50 を用いて構築した。ただし、在/不在認識は在か不在の 2 クラスの認識であったのに対し、種認識は 10 クラスの認識であるため、出力層のユニット数は 10 で、活性化関数はソフトマックス関数 (11) とした。学習済みのネットワークに未知のカメトラップ画像を入力すると、野生動物の 10 種に対応する出力層の 10 個のユニットに 0 から 1 の間の確信度が出力される。この確信度が最大のユニットに対応する種を認識結果のラベルとして出力する。

領域検出器は、深層学習に基づくセマンティックセグメンテーション手法の U-Net (14) を用いて構築した。U-Net は、医用の細胞画像に対し、細胞部分の領域を検出するために開発された手法であり、精度の高い領域検出が期待できることから採用した。領域検出器の入力はカメトラップ画像であり、それに対応する正解領域画像を正解データとして学習する。ここで、正解領域画像とは、野生動物の領域の画素に 1、それ以外の背景領域の画素に 0 を割り当てた 2 値画像であり、学習に先立ち著者らが作成した (図-2)。学習後に野生動物の領域が未知であるカメトラップ画像を




図-2. 正解領域画像の例

白は野生動物領域、黒は背景領域。

入力すると、野生動物の領域と推定した画素を 1、その他の画素を 0 とした画像が生成される。最後に、野生動物領域の外接矩形の位置を算出し、入力されたカメトラップ画像の対応する位置に矩形を重畳し、端末の画面に表示する。

### III 評価

#### 1. 在/不在認識器の構築と評価

表-2 に、在/不在認識器の構築と評価で用いたデータ (カメトラップ画像と在/不在の正解ラベルの組) の内訳を示す。深層学習では、学習用のデータに過剰に適合し、他のデータで精度が低下するという過学習の問題がある (11)。このため、学習で用いるデータを訓練データと検証データに分け、訓練データによる学習と検証データによる過剰適合の確認を繰り返すことで認識器を構築した。また、構築された認識器の性能評価には、訓練データや検証データとは異なるテストデータを用いた。また、テストデータにおける在と不在のデータ数の比率は、カメトラップの設置場所での在/不在の撮影頻度にほぼ合わせて、1 : 2 とした。

在/不在認識器の構築のための ResNet50 の学習では、ミニバッチサイズを 16 とした。学習の終了条件は、検証データに対する正解率が 50 エポックの間に向上しなかった場合とした。ここで、正解率は、次の式 (a) で定義される認識精度の評価指標である。

$$\text{正解率} = (\text{正解データ数}) / (\text{データの総数}) \quad (\text{a})$$

学習の実行時間は約 12 時間であった。実行環境は、CPU が Intel Core i7、メモリ容量が 40 GB で、GPU として NVIDIA 社製の GeForce GTX 1060 を搭載した PC である。深層学習のフレームワークは、TensorFlow および Keras を用いた。

以上の方法で構築した在/不在認識器に対し、テストデータを用いて認識精度を評価した。評価指標は、以下の式 (b) および式 (c) で定義される再現率と適合率である。

$$\text{再現率} = (\text{真に在で認識結果も在のデータ数}) / (\text{真に在のデータ数}) \quad (\text{b})$$

$$\text{適合率} = (\text{真に在で認識結果も在のデータ数}) / (\text{認識結果が在のデータ数}) \quad (\text{c})$$

表-2. 在/不在認識の評価用データ

	訓練	検証	テスト
在	7,935	992	992
不在	2,899	363	1,984
合計	10,834	1,355	2,976



在/不在認識器は、調査者が確認すべき画像を在の画像のみに絞り込むために用いる。評価の結果、野生動物が在と認識された画像は、2,976 枚から成るテストデータ全体の約 4 割の 1,194 枚であり、不在と認識された画像は約 6 割の 1,782 枚であった。実用的には、真に野生動物が在である画像は漏らさずに在と認識する必要があり、再現率は 100%を達成しなければならない。この要件に対して、評価結果の再現率は 96%であり、4%の認識漏れがあった。しかし、この 4%の認識漏れの画像は、人が見ても在/不在の判定に迷うような画像であり、明確に野生動物が写っている画像については、正確に在と判定できていた。一方、評価結果の適合率は 79%であり、確認すべき対象画像の中で真に不在の画像は 2 割程度であった。

## 2. 種認識器の構築と評価

表-3 に、種認識器の構築と評価で用いたデータ（カメラトラップ画像と種の名称のラベルの組）の内訳を示す。種認識器の構築で用いた訓練データと検証データの画像は、在/不在認識器の構築に用いた画像と同一である。評価に用いたテストデータの画像は、在/不在認識器の評価で在と認識されたテストデータの画像を用いた。種ごとのデータ数の偏りは、カメラトラップの設置場所での撮影頻度の違いによるものである。

種認識器を構築するための ResNet50 の学習で、ミニバッチサイズや終了条件は在/不在認識器の学習のときと同一である。また、実行環境も同一であり、実行時間は約 20 時間であった。

以上の方法で構築した種認識器に対し、テストデータを用いて認識精度を評価した（表-4）。評価指標としては、正しい種を認識できた割合を調べるため、式(a)の正解率を用いた。さらに、種による精度の違いを調べるため、以下の式(d)および式(e)で定義される種  $x$  ( $x$  は表-1 に示した 10 種のいずれかを表す) ごとの再現率  $x$  と適合率  $x$  を評価指標として用いた。

$$\text{再現率 } x = \frac{\text{真に種 } x \text{ で認識結果も種 } x \text{ のデータ数}}{\text{真に種 } x \text{ のデータ数}} \quad (d)$$

$$\text{適合率 } x = \frac{\text{真に種 } x \text{ で認識結果も種 } x \text{ のデータ数}}{\text{認識結果が種 } x \text{ のデータ数}} \quad (e)$$

評価の結果、正解率は 87%であり、約 9 割は正しく認識できることが確認された。種ごとの再現率と適合率については、種の間でばらつきが見られた。学習データ数が他の種に対して少ないニホンジカが総じて精度が低く、他の種よりも多いニホンカモシカは総じて精度が高かった。しかし、他の種よりも少ない方であるツキノワグマは総じて精度が高いため、必ずしも学習データの数のみが精度を決める要因ではなかった。

認識が失敗した要因をより詳細に調べるため、画像

表-3. 種認識の評価用データ

種	訓練	検証	テスト
ツキノワグマ	200	25	24
イノシシ	1,440	180	175
ニホンアナグマ	661	83	76
ニホンザル	458	57	56
ホンドテン	396	50	48
ニホンタヌキ	922	115	110
ニホンカモシカ	2,899	362	346
ハクビシン	431	54	53
アカギツネ	418	52	47
ニホンジカ	110	14	14
不在	2,899	363	245
合計	10,834	1,355	1,194

表-4. 種認識の評価結果

種	再現率(%)	適合率(%)
ツキノワグマ	96	92
イノシシ	94	88
ニホンアナグマ	88	66
ニホンザル	91	96
ホンドテン	85	72
ニホンタヌキ	69	86
ニホンカモシカ	97	96
ハクビシン	81	80
アカギツネ	96	74
ニホンジカ	50	63
平均	85	81

表-5. 種認識の失敗要因

失敗要因	画像数
他の種と誤った	55
背景を野生動物と誤った	47
撮影状況の不良	22

を目視で確認し、表-5 に示す失敗要因のカテゴリに分類して、各要因に該当する画像数を算出した。最も多かったのは、他の種との誤認識であった。特に、ニホンアナグマとニホンタヌキは外見が酷似しているため、相互に誤認識することが多かった。二番目に多かったのは、背景領域を野生動物と認識してしまう誤認識であった。この失敗要因の調査・分析は、CNN に基づく画像認識において、画像中のどの部分が認識結果に影響を及ぼしているかを学習済みのニューラルネットワークからヒートマップとして可視化し、特定する Grad-CAM (15) 手法を用いて行った。その他の失敗要因としては、野生動物の体の一部しか写っていない場合や濃霧によって画像全体が不鮮明な場合など、撮影状況の不良からくる要因があった。

### 3. 領域検出器の構築と評価

表-6 に、領域検出器の構築と評価で用いたデータ（カメラトラップ画像と正解領域画像の組）の内訳を示す。領域検出器の構築と評価に用いたカメラトラップ画像は、在/不在認識器の構築と評価に用いた画像の部分集合に対し、著者らが作成した正解領域画像を紐づけたものである。

領域検出器を構築する U-Net の学習では、ミニバッチサイズを 6 とした。学習の終了条件は、検証データに対する正解率が 60 エポックの間に向上しなかった場合とした。ここで、正解率は、式(a)で定義される正解率である。学習の実行時間は約 20 時間であった。実行環境は、CPU が Intel Xeon E5-1603、メモリ容量が 40 GB で、GPU として NVIDIA 社製の GeForce RTX 2070 を搭載した PC である。深層学習のフレームワークは、PyTorch を用いた。

以上の方法で構築した領域検出器に対し、テストデータを用いて検出精度を評価した（表-7）。評価指標としては、以下の式(f)で定義される IoU (Intersection over Union) を用いた。

$$\text{IoU} = \frac{\text{検出領域かつ正解領域である画素の数}}{\text{検出領域あるいは正解領域の画素の数}} \quad (\text{f})$$

IoU は、コンピュータビジョン分野で使われる物体検出の評価指標であり、検出領域と正解領域の一致度合いを表す。検出領域が正解領域と完全に一致した場合は 1 となり、逆に、一致部分がない場合は 0 となる。評価指標として、さらに、野生動物領域の未検出部分の大きさ、および、背景領域を誤検出した部分の大きさを種ごとに調べるため、以下の式(g)および式(h)で定義される再現率、適合率をテストデータの画像ごとに計算し、種ごとの平均値を求めて評価した。

$$\text{再現率} = \frac{\text{真の野生動物領域を検出した画素数}}{\text{真の野生動物領域の画素数}} \quad (\text{g})$$

$$\text{適合率} = \frac{\text{真の野生動物領域を検出した画素数}}{\text{検出した領域の画素数}} \quad (\text{h})$$

評価の結果、IoU の全体平均は 0.78 であり、検出した領域と真の野生動物領域との間のずれは平均で野生動物領域の約 2 割程度の大きさ（画素数）であることが確認できた。種ごとの平均適合率はいずれも 9 割以上であり、平均再現率もニホンジカを除いて 8 割前後であった。ニホンジカの平均再現率が特に低かった原因を調べたところ、濃霧のためにぼやけやノイズが入り、動物領域が検出されなかった画像が含まれていたためであった。しかし、このニホンジカの画像を含め、野生動物領域が検出されなかった画像は 6 件のみであり、部分的な領域が検出できている場合も含めれば 96% の画像で野生動物領域が検出できていた。

表-6. 領域検出の評価用データ

種	訓練	検証	テスト
ツキノワグマ	107	14	10
イノシシ	157	20	19
ニホンアナグマ	146	22	20
ニホンザル	15	0	1
ホンドテン	145	16	25
ニホンタヌキ	164	16	17
ニホンカモシカ	141	18	16
ハクビシン	149	17	16
アカギツネ	128	24	22
ニホンジカ	51	4	6
不在	-	-	363
合計	1,203	151	515

表-7. 領域検出の評価結果

種	IoU	平均 再現率(%)	平均 適合率(%)
ツキノワグマ	0.87	0.91	0.95
イノシシ	0.91	0.95	0.95
ニホンアナグマ	0.70	0.74	0.89
ニホンザル	0.91	0.94	0.96
ホンドテン	0.70	0.75	0.92
ニホンタヌキ	0.88	0.93	0.94
ニホンカモシカ	0.83	0.89	0.93
ハクビシン	0.83	0.89	0.92
アカギツネ	0.81	0.87	0.93
ニホンジカ	0.37	0.39	0.96
平均	0.78	0.83	0.94

### 4. 認識・検出の実行時間

テストデータに対する処理時間を計測した結果、在/不在認識は画像 1 枚当たり約 0.3 秒、種認識も約 0.3 秒、領域検出は約 0.7 秒であった。種認識と領域検出は、在/不在認識の後に並行して実行するため、全体では画像 1 枚あたり約 1 秒で実行できる。これらの認識および検出処理は、調査者の判定作業よりも事前に、あるいは、判定作業と並行して実行できるため、調査者を待たせることなく処理できることが確認できた。

## IV まとめ・考察

本研究では、カメラトラップ画像から野生動物の種を同定する調査者の労力軽減を目的に、野生動物の在/不在認識器、種認識器、領域検出器から成る野生動物認識システムを構築し、評価した。

在/不在認識器は、野生動物が写っている画像のみを確認対象とすることで、調査者の労力を軽減することが目的である。この要件に対し、野生動物が在と認識される再現率は 96% であり、4% の認識漏れがあった。しかし、認識漏れの画像は人が見ても在/不在の判定に

悩む画像である。このため、人が見て判定する場合でも生じ得る誤差を許容できる調査であれば、問題のない精度と考える。一方、適合率は79%であり、調査者が確認すべき対象画像の中には、真に在である画像だけでなく、真に不在の画像が約2割程度含まれる結果となった。しかし、真に不在の画像のうち、確認対象に含まれてしまう画像以外の1,782枚は不在と正しく認識され、確認対象から除外することができた。これはテストデータの画像総数2,976枚の約6割にあたるため、在/不在認識器により調査者の確認作業の約6割の労力を削減できることが示された。

種認識器は、正解率が約90%であった。これにより、調査者が画像を目視して種を判定し、PCに入力する作業のうちの9割を効率化できることが確認できた。また、誤認識した10%の失敗要因の中で、約70%は異なる種の間、あるいは、野生動物と背景領域の間の誤認識であった(表-5)。これらについては、学習データ数を増やし、種ごとの違いや野生動物と背景領域の違いをより詳細に学習することで改善できると考えられる。また、その他の誤認識要因は濃霧などの撮影状況の不良によるものであるため、同様の状況の学習データを拡充することで改善できると考える。

領域検出器は、調査者が画像上で野生動物の位置を探す作業の労力軽減を目的としている。領域検出器が検出した領域の外接矩形がカメラトラップ画像に重畳表示され、野生動物の位置が調査者に提示される。これに対し、検出された領域と真の野生動物領域のずれは、平均で野生動物領域の大きさ(画素数)の2割程度であった。このずれの大きさであれば、調査者は野生動物の位置を十分容易に把握できる。また、テストデータのうち、野生動物領域が部分的にでも検出できなかった割合は4%であったため、96%の画像については調査者の労力軽減に寄与できると考えられる。

以上より、本研究で構築した野生動物認識システムは、在/不在認識で調査者の作業の約6割を削減でき、残りの約4割についても種認識や領域検出により大幅に削減できるため、全体で6割以上の作業削減が図れ、調査者の労力軽減に有用であることが示された。また、処理時間についても、調査者を待たせることなく処理できる時間であることが確認できた。今後、カメラトラップの設置場所を増やし、本システムを活用することで、野生動物の出現時間、場所、種に関するより詳細で広範囲の生息状況の把握が可能になると考える。

一方で、今回のシステムでは、濃霧などの特別な状況に対して誤認識する場合があった。また、より大量のカメラトラップ画像を活用できるようにするためにも、さらなる認識精度の向上が必要である。今後の課題として、学習データの拡充や認識手法、検出手法の改良が挙げられる。さらに、生息状況の情報として、種だけでなく、頭数や雌雄、幼獣/成獣などの属性や、

歩く/餌を食べるなどの行動情報も認識し、野生動物の保護管理に活用できるようにするためには、動きの特徴などより多くの情報が得られる動画に対する認識手法、検出手法の開発も必要であり、本研究を継続、発展させていく予定である。

#### 謝辞

本研究に多大なるご支援を頂いている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。

#### 引用文献

- (1) 安藤正規・中塚俊介・相澤宏旭・中森さつき・池田敬・森部絢嗣・寺田和憲・加藤邦人(2019) 深層学習(Deep Learning)によるカメラトラップ画像の判別. 哺乳類科学 59 (1): 49-60
- (2) Deng J, Dong W, Socher R, Li L, Li K, Fei-Fei L (2009) ImageNet: A large-scale hierarchical image database, In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR): 248-255
- (3) He K, Zhang X, Ren S, Sun J (2016) Deep residual learning for image recognition, In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR): 770-778
- (4) 飯島勇人・中島啓裕・安藤正規(2018) カメラトラップによる野生生物調査入門. 東海大学出版部
- (5) 小池伸介・山浦悠一・滝久智(2019) 森林と野生動物. 共立出版. 227-228
- (6) 環境省(2004) 野生鳥獣保護管理検討会報告書: 5-7
- (7) 環境省(2019) 令和元年版環境白書・循環型社会白書・生物多様性白書: 159-164
- (8) 中山英樹(2015) 深層畳み込みニューラルネットによる画像特徴抽出と転移学習. 電子情報通信学会音声研究会7月研究会技術報告: 55-59
- (9) 農林水産省(2019) 鳥獣被害の現状と対策. 農村振興局: 1-7
- (10) Norouzzadeh MS, Nguyen A, Kosmala M, Swanson A, Palmer MS, Packer C, Clune J (2018) Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning. In: Proceedings of the National Academy of Sciences 115: E5716-E5725
- (11) 岡谷貴之(2015) 深層学習. 講談社
- (12) 林野庁(2007) 保護林モニタリング調査マニュアル: 75-77
- (13) 林野庁(2019) 平成30年度森林・林業白書: 88-90
- (14) Ronneberger O, Fischer P, Brox T (2015) U-Net: Convolutional networks for biomedical image segmentation, In: Proceedings of the Medical Image Computing and Computer-Assisted Intervention (MICCAI), Springer, LNCS, Vol.9351: 234-241
- (15) Zhou B, Khosla A, Lapedriza A, Oliva A, Torralba A (2016) Learning deep features for discriminative localization, In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR): 2921-2929