

UAV 画像を用いた水面の水鳥の自動カウント

Automated Counting of Waterfowl on Water Surface Using UAV Imagery

小川健太^{*1†}・牛山克巳^{*2}・小練史弥^{*1}Kenta OGAWA^{*1†}, Katsumi USHIYAMA^{*2} and Fumiya KONERI^{*1}

Abstract

The monitoring of migratory geese at known stopover sites is crucial to their habitat conservation but usually requires skilled manpower for counting large flocks of waterfowl. The use of observations from UAVs (unmanned aerial vehicles, a.k.a. drones) is a potential alternative to traditional bird counting methods. We used a multicopter-type UAV with a well-stabilized camera to count greater white-fronted geese (*Anser albifrons*) that seasonally roost in Lake Miyajima-numa, Hokkaido, Japan. Since the geese roost at sundown, we had to find good camera settings that enabled the detection of geese on the lake under dim light conditions. The key camera setting was a very long exposure time of half a second, which allowed us to detect and count geese up to about 30 minutes after sunset. A single UAV flight could observe the entire lake from an altitude of 100 m above the water surface with little disturbance to the roosting geese.

We used a cascade classifier, which is a machine learning technique, to automatically count geese in the imagery. The counting accuracy ranged from -4.1% to $+6.1\%$ in four validation cases compared with manual counts on the UAV image. We conclude that the combination of UAV and machine learning methods can yield goose counts with an accuracy of $\pm 15\%$. The results suggest that this approach will be useful for monitoring geese or other waterfowl.

Keywords : UAV (Unmanned Aerial Vehicle; drone), Lake Miyajima-numa, Greater white-fronted goose (*Anser albifrons*), Machine learning

1. はじめに

水鳥の保護計画のためには対象種の生態の把握、とりわけ、個体数の把握が重要な課題である。現状における個体数の把握は熟練者による地上からの目視観測に依存しており、大きな労力を要するとともに、多数の地点や広域の調査が困難である。

近年 UAV を用いた野生動物、特に野鳥のモニタリングやカウントに関する研究が注目されている^{1)~3)}。UAV の飛行そのものが野生生物に影響を与える可能性もあるが、飛行の際に低高度側の制限を設けるなど、その影響を最小限に留める方法も確立しつつある^{4)~6)}。

本研究では渡り鳥であるマガン (greater white-fronted goose; *Anser albifrons*) を対象として、UAV による撮影と自動カウントによりその個体数の把握を試みた。マガンは昼間には採餌等のために近隣の田畑などに分散しており、その個体数把握のためには、夕方時入りした後、もしくは早朝の

時立ち前の飛行・撮影が必要である。しかし、このような低照度下での撮影およびカウントについてはまだ研究事例がほとんどない。

そこで著者らはこのような低照度の条件での撮影を可能とすべく、2016 年からマガンの国内有数の経由地である北海道美唄市の宮島沼を対象地として研究を実施しており、その成果の一部について発表を行ってきた⁷⁾⁸⁾。その成果として機械学習による自動カウント結果が実用的なレベルに達してきたことから、本論文では UAV 撮影方法から画像の機械学習によるカウントまでの一連の手法を提案する。

将来的にはこの手法が他地域においても、また他の種の水鳥においても適用され、普及することを目標として研究を行っている。

2. 調査対象地及びマガンの生態について

本研究の対象地、宮島沼の位置を Fig. 1 に示す。宮島沼

(2018. 12. 5 受付, 2019. 10. 11 改訂受理)

^{*1} 酪農学園大学

〒069-8501 北海道江別市文京台緑町 582 番地

^{*2} 宮島沼水鳥・湿地センター

〒072-0057 北海道美唄市西美唄町大曲 3 区

† 連絡著者

^{*1} Rakuno Gakuen University, Hokkaido, Japan 069-8501

^{*2} Miyajimanuma Waterbird and Wetland Center, Hokkaido, Japan 072-0057

† Corresponding author




Fig. 1 Study area of Lake Miyajima-numa. This map is a reproduction of the Basic Geospatial Information published by Geospatial Information Authority of Japan.

(北緯 43 度 20 分 東経 141 度 43 分付近) は、石狩川に点在する湖沼湿地の一つで、水深は平均約 50 cm、周囲は水田地帯であり、周囲の湖沼も含め、マガンの渡りの中継地として利用されている⁹⁾。

マガンは、春は 4 月ごろ、秋は 9 月ごろから飛来し、その飛来数は 1975 年より記録されている⁹⁾¹⁰⁾。春の最大飛来数は 1980 年以前には 1 万羽以下であったがその後増加し、2000 年以降の春の最大飛来数は約 6~8 万羽程度に増加している¹⁰⁾。

3. 研究方法

3.1 UAV および撮影方法

撮影に使用した UAV およびカメラの仕様を Table 1 に示す。事前テストを繰り返し行い、マガンのカウントが可能で且つ、なるべく広範囲を撮影できるように飛行高度を 100 m に設定した。撮影に使用したカメラ・システムのセンサ・サイズは 17.3×13 mm、焦点距離は 12 mm であるので、撮影領域は計算上約 144×108 m となる。また、一画素のサイズ (Ground sampling distance : GSD) は約 27.3 mm である。マガンの全長は約 75 cm 程度であり、約 30 画素程度に相当し、良好な画質で撮影ができれば十分に検出が可能である。

対象となる宮島沼の開放水面の面積は概ね 25 ha であり、沼全体を撮影するには、20 枚程度の画像の撮影が必要となる。汎用の飛行計画・管理ソフトウェア (DJI 社 GS Pro) により自動飛行させて撮影を行った。飛行に要する時間は 10 分程度である。なお、通常的环境調査等においては、画像間のオーバーラップを UAV 進行方向およびその直角方向にそれぞれ 60% 以上とることが多いが、今回はできるだけ短時間で撮影を完了させるためと、後の画像処理による重複カウント排除の手間を削減するためにオーバーラップ 0% となるよう飛行コースを作成した。

マガンの購入後には撮影を開始する必要がある一方で時

Table 1 Specifications of the UAV and camera used in this study.

UAV	Model	Inspire2		
	Make	DJI		
	Weight	3,440 g	Without gimbal & camera	
	Max takeoff weight	4,250 g		
	Hovering accuracy	±0.5 m	Vertical	
		±1.5 m	Horizontal	
	Max flight time	23 min	With Zenmuse X7	
Camera/	Model	Zenmuse X5S		
Gimbal	Make	DJI		
	# Pixel	5280 x 3956		
	Angular vibration range	±0.01°		
	Lens	Olympus	M.ZUIKO DIGITAL ED	
			12 mm F2.0	
	Focal length	12 mm		

間が遅くなると照度が低下し、カウントが可能な画質（特にコントラスト）での撮影ができない。この点でも試行錯誤を繰り返し、撮影開始時刻を晦入りがほぼ完了する日没後 20 分とし、日没後 30 分ごろまでに撮影を完了することとした。

このような低照度の時間帯での UAV による撮影は特殊であるが、露出時間を 1/2 秒と非常に長く設定することにより、マガンを目視で検出可能な画像の撮影が可能となることを見出した。このような長時間露出では、UAV 機体のブレや振動の影響で取得する画像が不鮮明となる恐れがあるが、高性能なジンバルを使用しマガンの検出が可能な程度の画質を確保することができた。なお、できるだけ明るい画像を得るために、センサ・サイズの大きなカメラ、F 値の小さなレンズを使用することも重要である。ISO 感度は撮影中の照度の低下に合わせ、3,200～12,800 程度を使用した。

3.2 夜間飛行申請

日本国内では、航空法により夜間（日没以降あるいは日出以前）の飛行を行う場合、あらかじめ、地方航空局長の承認を受ける必要がある。本研究では、東京航空局より承認（東空運第 311 号、東空運第 7084 号）を受け、指定された条件のもとで飛行させた。

3.3 UAV 画像の前処理

UAV からの撮影した画像（以下、UAV 画像という）に写っているマガンの自動カウント処理の前処理として UAV 画像の陸域部分をマスクし、検出対象外とした。その理由は、陸域を対象とすると誤検出が大量に発生するためである。なお宮島沼では一年を通じ水面の空間的変動は小さい為、GIS 上に水域ポリゴンデータを作成する簡単な処理により陸域をマスクすることが可能である。

また、マガンが全く居ない領域を撮影した UAV 画像は、判読者によって容易に確認ができるため、誤検出軽減の観点から自動カウントの対象から外すこととした。

3.4 機械学習（カスケード分類）による自動カウント手法

多数のマガンを UAV 画像からカウントするためには、人手による作業では多大な時間を要するので計算機による自動カウントが必要と考えた。本研究では、物体検出によく使われるカスケード分類手法¹¹⁾¹²⁾を利用し、自動カウントを試みた。

なお、物体検出の方法として、例えばより単純な適応的閾値処理（2 値化）を利用することも考えられるが、事前のテストでは個別の画像をうまく処理ができて、複数の画像に渡ってうまくマガンと背景を分離できるパラメータを決定することが困難であった。その原因は対象となる UAV 画像が前述のように低照度の時間帯に撮影されていることからノイズが大きいことと太陽の照射方向とその逆の方向で背景となる水面や波の明るさが異なること、が挙げられる。そのため適応的閾値処理（2 値化）により様々な撮影条件で安定した性能を発揮させるのは困難と考えら

れる。

そこで本研究では、品質が良くかつ十分な数の画像を用いて学習させれば安定して物体を検出できる可能性のある機械学習によるアプローチを提案する。

3.5 自動カウントのためのトレーニング・データの作成

UAV 画像のそれぞれに対し、マガンの中心座標のリストを作成した。この作業は、PC 上で UAV 画像を汎用画像処理ソフトウェア（本研究では NIH Image/ImageJ 1.5 を使用）に表示し、人手によりマガン一羽一羽の中心付近をマウスでクリックし、その座標を記録することで作成することができる。

なお物体検出のトレーニング・データ整備において、通常は人手によりバウンディング・ボックス（bounding box：対象物体をちょうど囲うのに必要な大きさの四角い領域）を作成するが、本研究では、中心座標のみのリストを作成し、それを規定の画素数だけ上下左右方向に拡張させることにより、バウンディング・ボックスを生成させることとし、大幅に労力を軽減した。具体的には、中心から上下左右にそれぞれ 16 画素拡張し、32 画素四方の領域をマガンのトレーニング・データとした。

3.6 学習による検出器の作成について

前述の方法で作成したトレーニング・データを用いて、カスケード分類手法による学習を行い、検出器を作成した。画像特徴量として、Local Binary Patterns (LBP)¹²⁾を採用し、カスケードのステージ数を 20 とし、「許容可能な偽警報率」および「最小真陽性率」の 2 つのパラメータについては、各種の組み合わせで実験することにより、より高い検出精度を示すパラメータを後述のように探索することとした。

3.7 検証および精度評価

前述の検出器の精度の検証にあたっては、学習に使用した UAV 画像とは別の日に撮影された UAV 画像に対して、物体検出処理を行うことにより精度を評価した。

マガンの検出座標は各方向 5 画素までのズレは許容することとし、まず正解の検出結果（True Positive：TP）をカウントした。次に検出座標の付近に、正解データの無いものを誤検出（False Positive：FP）としてカウントし、最後に検出されなかったがマガンが居た座標を検出漏れ（False Negative：FN）とし、カウントした。なお、1 つの正解データに対し、一部が重なりあって 2 つの検出結果がある場合、一つは正解とし、もう一つは誤検出とした。

また、マガンの画素数がほぼ一定であることを考慮し、検出の最小サイズは 32 画素、最大サイズは 64 画素と限定することにより精度の向上を図った。

精度評価のため、以下の式により算出される F 値（F-measure）を用いた。F 値は予測結果の評価指標の一つであり、精度と再現率の調和平均である。0～1 の値を取り、1 に近いとより高精度であると判断される。

$$F = \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}}$$

ここで、精度 (precision) および再現率 (recall) は以下のように計算される。

$$\text{precision} = \frac{TP}{TP + FP}$$

$$\text{recall} = \frac{TP}{TP + FN}$$

なお、本研究ではマガンをカウントの対象としているが、類似したサイズのカモ類などが混在していた場合には、マガンと誤認識される可能性がある点に留意する必要がある。ただし、宮島沼においては、マガンと比較してカモ類は個体数が少ないために問題とはならない。類似した他の種が多数いる湖沼の場合、その種がいるエリアを手作業で指定し画像解析の対象外とすることにより対応する必要がある。

4. 結果と考察

4.1 UAV による撮影について

前述の方法により、宮島沼にて 2017 年秋に 8 回、2018 年春にも 8 回の撮影を早朝または夕方に行った。2017 年は撮影時のカメラ設定および撮影時刻について事前の試行段階であったため、撮影の成功例が多くはなく、2018 年春の初期は結氷の影響もあり、良好な UAV 画像は限定された。

以下の画像解析では、2017 年は 10/19 に、2018 年は 4/24、4/26、4/27 の 3 日間、合計 4 日間分のいずれも夕方日没後に撮影された UAV 画像を使用した。その UAV 画像の一部を Fig. 2 に示す。Table 2 にはそれぞれの撮影日と使用した UAV 画像の枚数、撮影されたマガンの目視カウント数、撮影時刻、日没時刻を示す。使用した UAV 画像はいずれも日没後 21~33 分の間に撮影されたものである。な

お、撮影において操縦者は機体の目視監視に専念し、別の撮影担当者がフォーカス調整および ISO 調整等に専念した。

2018/4/27 に撮影した UAV 画像すべてを接合したものを Fig. 3 に示す。なお、この図は沼全体の撮影が問題なく行われているか確認するために使用し、以後の自動カウント処理では、接合前の UAV 画像に対し、行っている。

4.2 トレーニング・データを用いた検出器の作成

前述 (3.4~3.6) の方法により学習を行い、2つの検出器を作成した。一つは 2017/10/19、もう一つは 2018/4/24 の UAV 画像を使い、それぞれをトレーニング・データとして、カスケード分類手法により、作成したものである。2つ作成したのは、トレーニング・データの違いがその後の検出




Fig. 2 Sample image acquired by the UAV (Inspire2) over Lake Miyajima-numa on Oct. 19, 2017 (upper-left), Apr. 24, 2018 (upper-right), Apr. 26, 2018 (lower-left), and Apr. 27, 2018 (lower-right).

Table 2 Training and validation image used in the machine learning

	Date	# of images	# of birds	Flight time	Sunset
Training 1	2017/10/19	12	6,715	17:09-17:14	16:43
Training 2	2018/4/24	16	31,210	18:46-18:51	18:25
Validation	2018/4/26	17	48,780	18:55-19:00	18:27
Validation	2018/4/27	13	24,183	18:54-19:00	18:28



Image Courtesy of DigitalGlobe (background of UAV image)

Fig. 3 An UAV mosaic image acquired on Apr. 27 over Lake Miyajima-numa. The UAV imagery fills a white-bordered frame. The background image was acquired by the WorldView2 satellite (provided by DigitalGlobe).

精度の差にどの程度影響するかを検討するためである。

「許容可能な偽警報率」を0.5および0.7,「最小真陽性率」を0.9および0.99のそれぞれ2通りの2変数の組み合わせ、4通りで実験を行った。その結果, F値はTraining 1の場合で0.650~0.783, Training 2の場合で0.751~0.901であった。F値がもっとも高い組み合わせでは, 2つのトレーニング・データのいずれも「許容可能な偽警報率」が0.5, 「最小真陽性率」が0.99の場合であった。

その結果をTable 3およびTable 4のTraining 1およびTraining 2の行に示す。両表において, 機械学習カウント数(Machine learning count)はTPとFPの合計を示し, 誤差(Diff.)は, 機械学習カウント数(machine learning count)の目視カウント数(manual count)に対する相対誤差を示す。この検出器を用いて, 以下の検証を行った。

4.3 検証および精度評価

上記2つの検出器を用いて, 4/26, 4/27の両日のUAV画像により, 機械学習の精度検証を行った。その結果をTable 3およびTable 4のValidationの行に示す。また, 検出結果

画像の例をFig. 4に示す。

いずれの学習器においても, 検証(Validation)におけるF値は0.89~0.95程度の比較的高い値を示している。トレーニング・データにおける個体数が少ないTraining 1(2017/10/19画像の学習結果)の検出器の方が精度は低いと予想したが, 精度に大きな差はなかった。しかし, Training 1の検出器の2018/4/27画像に対する検証精度(F値)は0.9以下であり, より高いF値を示すTraining 2により作成した検出器の方が安定した性能を持っていることが示唆される。また, いずれのケースでもUAV画像目視カウントと機械学習カウントの差は-4.3%~+6.1%の範囲に収まっている。

なお, Table 3およびTable 4において, 学習時の方が検証時より低いF値を示し, 誤差(Diff.)も大きいのがこれは学習時のUAV画像には, 前述3.3に示した陸域をマスクする画像の前処理を施していないことが主な原因である。

なお, 検出漏れ(FN)の大部分は画像の西側の領域に起こっている。その原因は, 夕方の撮影において西側に沈む




Fig. 4 Examples of white-fronted geese extracted using machine learning. The left-side imagery were acquired on Apr. 26, and the right-side imagery were acquired on Apr. 27. Each of the lower images is an enlargement of the white square in the corresponding upper image. The area of the enlarged image is the same as that in Fig. 2.

Table 3 Machine learning validation results 1. *TP*, *FP*, and *FN* correspond to true positive, false positive, and false negative, respectively. “Diff” is the difference between “manual count” and “machine learning count” on a UAV image.

Date	Type	Manual count	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>F</i>	Machine learning count	Diff.
2017/10/19	Training 1	6,715	4,891	890	1,824	0.783	5,781	-14%
2018/4/26	Validation	48,780	45,858	2,349	2,922	0.946	48,207	-1.2%
2018/4/27	Validation	24,183	22,148	3,506	2,035	0.889	25,654	6.1%

Table 4 Machine learning validation results 2.

Date	Type	Manual count	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>F</i>	Machine learning count	Diff.
2018/4/24	Training 2	31,210	29,803	5,161	1,407	0.901	34,964	12%
2018/4/26	Validation	48,780	45,875	881	2,905	0.940	46,756	-4.1%
2018/4/27	Validation	24,183	22,022	1,119	2,161	0.931	23,141	-4.3%

太陽光の一部が水面に反射し、水面が明るくなり、マガンとのコントラストが低下することにより起こっていると考えられる。

4.4 カウント精度に関する考察

本論文で提案する手法が現場のマガンの個体数カウントにおいて有効か否かは、カウント精度が大きな要因となる。前述の機械学習のカウント誤差の以外に考えられる誤差要因として、以下2点が考えられる。

1. UAV 画像の位置のズレ (UAV 位置およびカメラ方向に起因)
2. マガンの撮影中の移動および撮影後の罨入り

前記1については、陸域を含む UAV 画像同士を接合した際に、画像が重畳される範囲内の目標物の予測位置の差異をもとにズレを推定することが出来る。その結果、ズレは概ね 5m 以内と見積もることができた。したがって、各南北方向画像間では 5m×144m (画像幅方向)、面積として 720m²、東西方向画像間では 5m×108m (画像縦方向)、面積として 540m² のズレが有りうる。

最も誤差の大きい条件として、ズレの部分全域にマガンが居たと想定する。マガンの密度を 0.3 羽/m² と仮定すると南北方向では、面積と密度の積の単純計算では 216 羽、東西方向で 162 羽の誤差が生じる可能性がある。南北方向には 18 の接合部分、東西方向には 11 の画像同士の接合部分があり、すべてを誤差が独立の偶発誤差と考え、全接合部分に対し自乗和の平方根を計算すると、約 1062 羽相当となる。前述の密度は 40,000 羽程度のマガンが宮島沼に居た場合の概数であるので相対的な誤差は最大で 3% 程度である。

前記2については、撮影した後に罨入りするマガンのタイミングは日により異なるが、地上からのマガンの観測結果から、宮島沼では通常日没 20 分後までには個体数の 95% 以上のマガンが罨入りしていることが分かっている。したがって、多くの場合その誤差は 5% 以下と考えて良い。移動中のマガンの個体数については、飛行中の UAV からの転送映像を見る限り、定位個体 (移動しない個体) 数と比較して無視できるほど小さいと考えられるが、本研究ではその定量化は困難であった。このことから撮影中のマガンの移動の影響を除くと、誤差は (1) 物体検出の誤差: 7% 以内 (本研究の結果が -4.3% ~ +6.1%), (2) UAV 画像の位置ずれによる誤差: 3% 以内, (3) 撮影後の罨入り: 5% 以内の 3 要素となる。これらを単純に合計すると総合的な精度として、±15% 以内で計測が可能であると結論づけることができる。なお、(3) 撮影後の罨入りによる過小評価 (誤差) は撮影後の従来法による地上からの目視カウント等により補うことも可能である。本手法の総合的な精度は、少々改善を要するがマガンの生態モニタリングにとって有用なレベルに近づいていると言える。

一方、既往研究との比較における本研究の位置づけについて考察する。上空から撮影した画像による鳥類の自動検出に関するレビュー論文²⁾によると UAV よる 3 つの事例

ではカウントのエラーがそれぞれ 0.8~0.9%, 2.4~4.8%, 0~0.7% である。ドローンでの鳥類コロニーに関するより新しい研究事例³⁾ では、カウントの誤差は 10% 程度であった。本研究でのカウントの誤差は、Table 3, 4 の validation 実験の Diff の欄に示されるように、4 つのケースでそれぞれ -1.2, 6.1, -4.1, -4.3% であり既往研究と比較し、数値のうえは特段優れているとは言えないが、既往研究とは異なり低照度の環境下で暗色のマガンを対象としており、ノイズが比較的大きな画像への自動カウント手法を提案しており、応用範囲も広く価値があるものと考えている。

4.5 地上からの目視カウントとの比較

2018/4/26 は、地上からの目視でのカウントを実施しており、その数は 43,570 羽であった。UAV 画像の目視カウント結果は 48,780 羽と約 10% の差異がある。UAV 画像を用いたカウント誤差の原因として、前述のように撮影後の罨入りや撮影中のマガンの移動の影響が考えられる。一方で従来法の地上からの目視カウントでは、オジロワシ等の飛来により逃げ惑うマガンと罨入りするマガンが混じり合い誤差が生じたり、調査人数や罨入りの状況によっては群れを見落としたりする可能性もある。詳しい原因の分析については、今後検討を要する。

5. 結論および今後について

以上の結果より、マガンを自動カウントするための UAV による低照度下での画像撮影は、本研究で使用したものと同等以上の UAV 本体、ジンバル、カメラの組み合わせ、および適切なカメラ設定により可能であることが分かった。また機械学習の一つであるカスケード分類手法を活用することにより、予め撮影した UAV 画像を事前に学習させ、後日撮影した UAV 画像によりマガンを自動でカウントすることができることを示した。本手法の総合的なカウント精度は撮影中のマガンの移動の影響を除くと、誤差±15% 以内であることを示した。これらにより UAV からの撮影によるマガンの自動カウントが生態モニタリングに活用される見込みが出てきたと言える。

今後の研究の方向性として、(1) 宮島沼での撮影の継続および地上からの目視カウント結果との比較によるカウント誤差要因の解析、(2) さらに精度を向上させるための機材、撮影方法の検討、(3) 別の湖沼での本手法の適用、などがあげられる。またトレーニング・データの数やバリエーションを増やすことにより、さらに精度を高めることが可能であると考えている。

謝辞：本研究は、(独)環境再生保全機構の環境研究総合推進費 (1-1602) の支援により実施された。プロジェクト関係者各位のご協力に感謝する次第である。また、マガンのトレーニング・データの作成にあたっては酪農学園大学環境空間情報学研究室の歴代の学生・スタッフが多大な努


力を払った。さらに匿名の査読者には大変有用なコメントを多数戴きました。

引用文献

- 1) Baraniuk Chris: Drones and AI make for better bird-spotting, *New Scientist*, 235 (3136), pp. 7, 2017.
- 2) Chabot Dominique, Francis Charles M.: Computer-automated bird detection and counts in high-resolution aerial images: a review, *Journal of Field Ornithology*, 87 (4), pp. 343-359, 2016.
- 3) Hodgson Jarrod C., Mott Rowan, Baylis Shane M., Pham Trung T., Wotherspoon Simon, Kilpatrick Adam D., 他: Drones count wildlife more accurately and precisely than humans, *Methods in Ecology and Evolution*, 9 (5), pp. 1160-1167, 2018.
- 4) Jones Iv G. P., Pearlstine L. G., Percival H. F.: An assessment of small unmanned aerial vehicles for wildlife research, *Wildlife Society Bulletin*, 34 (3), pp. 750-758, 2006.
- 5) Shimada Tetsuo, Koyama Kazuo, Mori Akira, Fujimoto Yasufumi: Estimating the carrying capacity of a goose roost by using a UAV, *Japanese Journal of Ornithology*, 65 (2), pp. 161-166, 2016.
- 6) McEvoy J. F., Hall G. P., McDonald P. G.: Evaluation of unmanned aerial vehicle shape, flight path and camera type for waterfowl surveys: disturbance effects and species recognition, *PeerJ*, 4, pp. e1831, 2016.
- 7) 小川健太, 松田亜希子, 鈴木 透, 丸山 樹, 三品未和, 藤若燈: UAV 画像による水鳥の自動検出の試み, *日本リモートセンシング学会第 63 回 (平成 29 年度秋季) 学術講演会論文集 ((一社)日本リモートセンシング学会)*, pp. 7-8, 2017.
- 8) Kenta Ogawa, Yutaka Kaizu, Hiroyuki Yamada, Toru Suzuki, Tetsuo Shimada, Katsumi Ushiyama, Kazuo Koyama: Initial trials to semi-automated counting wild birds on water surface using UAV, *Proceedings of International Symposium on Remote Sensing 2017, 62th (2017 Spring) Spring Meeting of RSSJ*, pp. 903-906, 2017.
- 9) 星子廉彰: 北海道宮島沼における 1975 年から 2000 年のマガンの個体数変化, *STRIX*, 19, pp. 169-173, 2001.
- 10) 牛山克己, 森口紗千子, 天野達也: 宮島沼におけるマガン研究と保全管理, *湿地研究 Wetland Research*, 5, pp. 5-14, 2014.
- 11) Dollar P., Wojek C., Schiele B., Perona P.: Pedestrian detection: an evaluation of the state of the art, *IEEE Trans Pattern Anal Mach Intell*, 34 (4), pp. 743-761, 2012.
- 12) Shan C., Gong S., McOwan P. W.: Facial expression recognition based on Local Binary Patterns: A comprehensive study, *Image and Vision Computing*, 27 (6), pp. 803-816, 2009.

[著者紹介]

●小川 健太 (おがわ けんた)



酪農学園大学 農食環境学群 環境共生学類 環境空間情報学研究室 准教授。1994 年早稲田大学教育学部地学専修卒業。2006 年東京大学大学院工学系研究科博士課程修了, 博士(工学)。2011 年より現職。衛星画像, UAV, GIS を利用した農地・環境・防災分野等の実利用研究に従事。

E-mail : k-ogawa@rakuno.ac.jp

●小練 史弥 (こねり ふみや)



現在, 株式会社岩崎企画開発部 CIM 課。2019 年酪農学園大学農食環境学群環境共生学類卒業。2019 年より現職。卒業論文では, UAV と機械学習を利用したマガンのモニタリングについて研究。

E-mail : f.koneri238@gmail.com

●牛山 克己 (うしやま かつみ)



宮島沼水鳥・湿地センター専門員。2003 年東京大学大学院農学生命科学科博士課程修了。2007 年より現職。湿地と渡り性水鳥に関する調査, 保全, 賢明な利用などの実践活動に従事。

E-mail : mwwc@dune.ocn.ne.jp