特集 カメラおよび画像処理技術を活用した生態系モニタリング

事例研究 CASE STUDY

ロボットボートの視覚による誘導のためのディープニューラルネットワークを用いた湖沼水面の植生および環境認識

九間 啓士朗¹⁾・海津 裕^{1)*}・嶋田 哲郎²⁾・高橋 佑亮²⁾・古橋 賢一¹⁾・芋生 憲司¹⁾

1) 東京大学大学院農学生命科学研究科 〒113-8657 東京都文京区弥生 1-1-1

2) 宮城県伊豆沼・内沼環境保全財団 〒989-5504 宮城県栗原市若柳上畑岡敷味 17-2

Keishiro KUMA¹⁾, Yutaka KAIZU^{1)*}, Tetsuro SHIMADA²⁾, Yusuke TAKAHASHI²⁾, Kenichi FURUHASHI¹⁾, Kenji IMOU¹⁾: Recognition of aquatic plants and lake surface environment using deep neural network for visual navigation of robot boat. *Ecol. Civil Eng.* 23(2), 369-376, 2021

1) Graduate School of Agricultural and Life Sciences, The University of Tokyo, 1-1-1 Yayoi, Bunkyo, Tokyo, 113-8657, Japan

2) The Miyagi Prefectural Izunuma-Uchinuma Environmental Foundation, 17-2 Shikimi, Wakayanagikamihataoka, Kurihara, Miyagi, 989-5504, Japan

Abstract: The degradation of wetlands caused by the overgrowth of aquatic plants is a problem in many areas; therefore, low-cost, labor-saving vegetation management using robot boats is under development. Herein, we propose a method to classify aquatic plants and obstacles by real-time image processing to enable the full-autonomous operation of a robot boat. We adopted a semantic segmentation method using deep learning for the image processing and conducted teaching and testing on our own dataset. Regarding classification by segmentation, it was possible to classify the lotus (*Nelumbo nucifera*), which is the target of harvesting, and a rare species of fringed water lily (*Nymphoides peltata*), with an accuracy rate of about 90%. The deep neural network could learn the color, shape, and position information in the image. This reduced the influence of external environmental disturbances such as changes in illuminance and harsh sunlight reflections on the water surface, and the inference was robust. Regarding the obstacles, it was possible to classify with an accuracy rate of 80% or more within the depth-obtainable range of an RGB-D camera. It was also confirmed that classification was possible even when the obstacle was located 4.0 m or more away.

Key words: aquatic plant, robot boat, depth camera, deep learning, semantic segmentation

はじめに

日本には50のラムサール条約湿地が存在しており、水鳥や様々な動植物の生息地として保護・管理されている。本研究の対象地である宮城県北部に位置する伊豆沼も、ラムサール条約湿地に登録されており、国内有数の

渡り鳥飛来地としても有名である。しかし、家庭排水の流入や水鳥の糞尿などの影響によって富栄養化が問題になっている(梅田ほか 2011)。環境省(2019)の調査によると、伊豆沼は化学的酸素要求量(COD)が13 mg/lと全国で見ても最も高い湖の一つとされている。湖沼環境の変化によって沈水植物が減少し、現在ではハス(*Nelumbo nucifera*)が水面の約8割を占有している(安野ほか 2015; 仲田ほか 2015)。過剰繁茂したハスは日

2019年12月23日受付, 2020年5月20日受理

*e-mail: yuta_kaizu@yahoo.co.jp

光を遮り、水中照度を下げるため沈水植物等の生育を阻害するという報告がされている(藤本 2011)。また、沈水植物による光合成や水面でのガス交換が阻害されるため植物群落内の湖水が貧酸素化し、底生動物の成育が困難になっている可能性がある(安野ほか 2015)。その他にも、山室(2010)や野村ほか(2017)は、ハスの枯死体が堆積することで湖沼が浅底化することを示唆している。また、枯れたハスの葉が翌春まで水面を占有し、広い水面を好むマガン等の渡り鳥のねぐら面積の縮小(嶋田ほか 2016)など、様々な悪影響を及ぼしている。そのため、ハス群落を適切に管理することが伊豆沼における生態系保全の課題となっている。成育中のハスの葉柄を刈り払うことでその生長を阻害できる可能性が示されている(藤本 2018; 平塚・山室 2013)。しかし、伊豆沼のような広大な面積(28.9 ha)を持つ湖沼において、植生管理を長期的に継続するには多大な労力とコストが必要である。芦澤ほか(2015)は、有人で操作されるボートに取り付けるハスの刈り払い機を開発しその効果を確認した。その一方でハスはその生育後期になり植物体が大きくなり、密度が高くなると刈り払いができないという問題があった。そこで、我々は芦澤ほか(2015)の刈り払い機では困難であった生育後期のハスを刈り払うことが可能なカッターをボート前部に取り付けて無人でハスを刈り払うロボットボートの開発を行ってきた。従来の有人によるハス刈りの代替法として作業期間の延長や省力化が期待できる。ロボットボートには人工衛星の情報を使用し地上の現在位置を高い精度で計測可能な Real-Time Kinematic Global Navigation Satellite System (RTK-GNSS: リアルタイムキネマティック全球測位衛星システム)の受信機を搭載しており、この位置情報を元に自律航行が実現されている。しかし、現段階でのロボットボートは GNSS 情報のみで走行しているため、障害物や刈り取り対象外の希少植物の回避を自動で行うことはできない。ロボットボートで刈り払いを行うときは、刈り幅に対して横方向のオーバーラップを設けているため理論的には刈り残しは発生しない。しかしハスの密度が高いとカッターの前にはまだ切断されていない茎が溜まり、偶然、切断前にカッターの脇に逸れてしまうと刈り残しが発生する可能性がある。そのため、ロボットボートには進行方向に存在する物体が何かを把握した上で、回避もしくは接近など適切な制御を行うためのシステムを組み込む必要があると考えられる。

近年、自動車などの自動運転を目的とした距離画像カメラやディープラーニングを用いた画像処理による物体

認識の研究が進められている(Dos Reis et al. 2019)。ディープラーニングによる物体検出は、物体の位置と種類を検出し、物体の周りにバウンディングボックスを描くタイプと、1ピクセル毎に物体の種類を判別するセマンティックセグメンテーションとに分けられる(斎藤 2016)。1ピクセル毎に距離を測定できる距離画像カメラと、セマンティックセグメンテーションを組み合わせることで先述の自動回避もしくは接近が可能になると考えられる。これを踏まえ、本研究では、ハス刈りロボットボートの自律航行のための画像処理による環境認識システムの開発を目的とする。ディープラーニングを用いたセマンティックセグメンテーションにより、ハスと他の希少植物の分類や障害物の認識を行い、その精度を評価した。

方 法

画像データの収集

撮影は宮城県伊豆沼にて、2018年6月30日と8月8日、9月1日に行った。データ収集の目的は刈り取り対象であるハスや希少水生植物、ポールなどの障害物、背景の森林や空、水面が写った画像をディープラーニングによって分類するための学習および検証用の RGB 画像データの収集である。

ロボットボート(Fig. 1)はドローン用のフライトコントローラ(Pixhawk, 3DR 社製)によって制御されており、遠隔監視用のテレメトリデータとして、フライトコントローラ内部の IMU (Inertial Measurement Unit: 慣性計測ユニット)から方位姿勢角、外部に接続した RTK-GNSS (C94-M8P, u-blox 社製)から位置情報の取得が可能である。RTK-GNSS は本体に搭載された受信機とは別に固定基地局を設置することで、2.5 cm の誤差で位置計測が行える。カメラには RGB 画像に加えてカメラからの距離を画像として表現した深度画像も取得可能な RGB-D カメラ(Kinect V2, Microsoft 社製)を船首に水面から約 1 m、水平から 15 度下向きにして取り付けた。

また、データログおよび画像処理用のコンピュータとして GPU (Graphic Processing Unit) を搭載したロボット向け組み込みボード(Jetson TX2, NVIDIA 社製)を採用した。今回の実験では、画像処理に基づくボートの制御は行わなかったが、実用を考えて、同組み込みボードを用い、保存した画像を使って処理速度の検証を行った。

Fig. 1. Robot boat for cutting aquatic plant.
水草刈り払いロボットボート.

ロボットボートに設置した RGB-D カメラからディープラーニングの学習及びテスト用データとしてハスやヒシ (*Trapa japonica*), 希少植物としてアサザ (*Nymphaeoides peltata*), ポール等の障害物が写りこんだ画像を収集した。障害物として竹と鋼管のポールを打ち込み、マニュアル操縦でロボットボートをポールに近づけながら、撮影を行った。RTK-GNSS でポールとカメラの距離を記録しておき、解析に用いた。

セマンティックセグメンテーションによる画像認識

セマンティックセグメンテーションは 픽셀클러스터링とも呼ばれ、画像を構成する 픽셀ごとに分類されるクラスを推定する手法であり、画像中に存在する全ての物体を分類することができるため、環境認識に有効な手法である (Digumarti et al. 2019)。Ghosh et al. (2019) は、自動運転のための画像データセットに対してセマンティックセグメンテーションを適用した。ボートから撮影した画像データセットに対してこの手法を採用することで、水面に存在するハスやヒシ、アサザなどの水生植物と竹や鉄パイプなどの障害物、その他、水面や空、樹木などの画像中に現れうる物体を同時に検出可能になると考えた。

本研究では Long et al. (2015) によって提案された FCN (Fully Convolutional Networks) を用いたセマンティックセグメンテーションを実装した。ディープラーニングは従来の画像認識手法に比べその高い精度と汎用性から広く用いられている技術である。しかし、分類精度と処理

速度はトレードオフの関係にある。例えば DeepLabv3+ (Chen et al. 2018) のような分類精度が 90% を超えるが、ロボット等に組み込まれることが多い低～中スペックの PC で、このような計算量の多いニューラルネットワークを用いることは現実的ではない。本システムでは Jetson TX2 の処理能力を考慮して DNN (Deep Neural Network: ディープニューラルネットワーク) モデルにはリアルタイム性を重視した ESPNetv2 (Mehta et al. 2018) を用いた。また、ディープラーニングのフレームワークとしてオープンソースの PyTorch (The Pytorch organization 2020) を用いて実装した。

DNN モデルの学習・評価

伊豆沼での実験で撮影した画像から DNN モデルを学習・評価するためのセマンティックセグメンテーションのためのデータセットを作成した。データセットには、RGB 画像とそれに対応したラベル画像が含まれる。Pixel Annotation Tool (Breheret 2017) を用いて原画像のすべての 픽셀をハス (lotus), アサザ (fringed water lily), ヒシ (water caltrop), ポール (pole), 人 (human), ボート (boat), 浮き (float: 樹脂製の漁業用ブイ), 空 (sky), 森林 (woods), 水面 (water surface) の 10 クラスに目視で識別できる範囲でラベリング (塗分け) した。このソフトには半自動機能 (watershed アルゴリズム) が実装されており、隣り合う二つのクラスの領域内をそれぞれ別のクラスとして指定すると色の差を用いて自動的に塗分けすることができる (Kaehler & Bradski 2018)。

ラベル画像は学習用 165 枚、評価用 52 枚作成した。ディープラーニングの学習にはできるだけ多くの画像データが必要であり、165 枚では枚数が不足していると考えた。そこで、元の画像を修正することによって学習データを増やした。その手法として、まず、一つの画像に対して、左右反転を行い 2 倍の 330 枚に増やした。その後それぞれの画像に対して、無処理、4 段階のコントラスト調整、3 段階の鮮鋭化（ハイパスフィルター）、2 種類 2 段階のノイズ付加（白および黒のインパルスノイズ）、2 段階の平滑化処理（平均処理）を施した。これによって得られる 4620 枚（330 枚×（無処理 1 種類 + 13 処理））の画像を学習用データに用いた。

DNN モデル ESPNetv2 の学習は PyTorch を用いて行った。自動運転系で用いられる Cityscapes dataset で事前学習した重みを初期値として、DNN モデルを伊豆沼のデータセットでファインチューニングを行った。

学習した DNN モデルは、先述の計 52 枚の評価用画像データセットによって評価した。注目する評価対象は①各クラスの解像度別の分類精度、②障害物までの距離（1.0~4.0 m を 0.5 m 間隔）・照度（約 10,000 lx および約 100,000 lx）を変化させた場合の分類精度を検証した。屋外では雲の有無や時間帯によって照度が大きく変化するため、曇天時（約 10,000 lx）と晴天時（約 100,000 lx）の両方で学習を行い、分類器の頑強性の検証を行った。

RGB-D カメラの深度取得可能な範囲は 0.5~8.0 m であるが、水面上では反射や太陽光の影響で 1.0~4.0 m が限界であったため、カメラと障害物の距離が 1.0~4.0 m の範囲内にある画像で評価を行った。分類精度の指標として、正解率と IoU（Intersection over Union）を用いた。評価用画像と分類結果画像のそれぞれの同じ座標のピクセルに対して、TP（True Positive: 正しい(Positive)と予想して正解(True)）か FP（False Positive: 正しい(Positive)と予想して不正解(False)）、FN（False Negative: 誤っている(Negative)と予想して不正解(False)）、TN（True Negative: 誤っている(Negative)と予想して正解(True)）の判定を行い画像の全ピクセルの分類結果を集計した。正解率、IoU はそれぞれ各クラスについて計算され、正解率は、 $(TP + TN) / (TP + TN + FP + FN)$ 、IoU は、 $TP / (TP + FP + FN)$ で表される。正解率は予測領域全体の内の正解の割合を示す。また、IoU は、正解と分類結果の重なり具合を示す指標として DNN を使った画像のセグメンテーションや物体検出の評価に用いられている（藤田・高原 2016）。

ESPNetv2 では処理過程で画像サイズが 16 分の 1 まで

圧縮される。そのため縦横のピクセルサイズが 16 の倍数である必要がある。また入力画像サイズが大きいと組み込みボードの処理過程で計算時間が長くなってしまう。これらのことを考慮して RGB-D カメラで撮影された 1920×1080 px の画像を 1024×576 px, 768×432 px, 512×288 px, 256×144 px の 4 種類の解像度に縮小した。

結果と考察

解像度による処理速度の違い

組み込みボードでセグメンテーション処理を行った結果、各解像度において、1024×576 px では 3.1 fps, 768×432 px では 3.3 fps, 512×288 px では 4.4 fps, 256×144 px では 4.8 fps となった。画像サイズが小さいほど処理速度が速くなる傾向が見られた。実用に向けてはさらなる高速化（10 fps 以上）が望まれるが、今後組み込みボードの性能向上によって実現可能であることが示唆された。

各クラスの分類精度

Fig. 2 に元画像とディープラーニングによって先述の 10 クラスに分類されたセグメンテーション画像の一例を示す。各クラスの分類精度を IoU で評価した結果、分類精度の平均値が解像度が下がるにつれて下がる傾向にあることがわかった（Table 1）。1024×576 px では平均 IoU が 63.9% だったが、256×144 px では 18.5% と著しく低下した。特に 512×288 px から 256×144 px の差が大きく出る結果となった。他の解像度で高い精度を示している、森林や、ハスなどの精度が、256×144 px では低くなっている。このことから、今回の実験での実用上の限界は 512×288 px だと考えられる。以下、特に注記がない場合は最も分類精度が高かった 1024×576 の結果について述べる。

ハス（lotus）やアサザ（fringed water lily）については、86.5%、82.3% と高い精度を示した。水上で鏡面反射が生じる場合、RGB の色情報がその反射の状態によって変わるため分類が困難になることが多い。画像の縦の中央部に鏡面反射が見られる画像に着目すると（Fig. 4）、多くのクラスが混在する画像でもハスやアサザと水面を識別することができている。これは DNN では色に加えて形状や位置などの空間情報も同時に学習するため、反射の影響を受けにくく、より頑強な分類が行えているためであると考えられる。

複数の植物種が同時に映り込んでいる場合、ハスとアサザを誤分類した推定結果も見られた（Fig. 3）。アサザ

Fig. 2. The results of semantic segmentation. (a) Image taken at where the lotus is dominant. (b) Segmented image of (a). (c) Image taken at where the fringed water lily is dominant. (d) Segmented image of (c).
セマンティックセグメンテーションの結果。(a) ハスが優勢な場所で撮影された画像。(b) (a)をセグメンテーションした画像。(c) アサザが優勢な場所で撮影された画像。(d) (c)をセグメンテーションした画像。

Table 1. Classification accuracy rate by class using Intersection over Union (IoU).
クラス分類精度。

Resolution (pixel)	IoU (%)										
Width × Height	Lotus	Fringed water lily	Water caltrop	Pole	Human	Boat	Float	Sky	Woods	Water surface	Average
1024 × 576	86.5	82.3	14.0	62.3	53.7	71.3	0.0	97.5	92.3	79.1	63.9
768 × 432	85.2	80.5	13.8	59.5	42.8	66.9	0.0	98.0	88.8	77.9	61.3
512 × 288	81.3	75.4	7.3	49.2	23.6	51.3	0.0	97.3	77.5	71.8	53.5
256 × 144	0.6	25.2	0.0	27.1	0.0	0.0	0.0	81.9	4.1	46.1	18.5

は個体で見ると、ハスよりかなり小さいことから、十分に成長していない小さいハスとアサザの分類が困難であることを示唆している。またヒシも分離しておりなおかつ面積が小さい場合はアサザと誤認識されるケースが見受けられた。しかし、個体であった場合でも大きく成長したハスをアサザに誤分類するケースは見られなかった。このことから、成長していないもしくは枯れた小さなハスを形状と色情報からアサザと誤分類する可能性がある。

ポールに関しては62.3%と、ハスやアサザに比べて

低くなった。これは分類時に畳み込み層により画像が縮小されていく段階で、境界があいまいになり本来ポールである領域が背景のクラスに分類されたことが原因だと考えられる。ポールのように細長いオブジェクトは、真円に近いオブジェクトと比較して同じ面積に対する周囲長が長くなるため、境界での誤判定がIoUに与える影響が大きい。本研究においては、画像処理をロボットの視覚部として使うことを想定している。そのため、カメラの前に存在する物体の位置と種類を正しく認識する必要がある。

Fig. 3. Example of misclassification. (a) Input image. (b) Partially enlarged view of (a). Segmentation by human. (c) Segmented image. (d) Partially enlarged view of (c). Some lotus and some water caltrop are misclassified as fringed water-lily.

誤分類の例. (a) 入力画像. (b) 人によるセグメンテーション. (c) (a)の部分拡大図. セマンティックセグメンテーションの結果. (d) (c)の部分拡大図. ハスとヒシの一部がアサザに誤分類された.

ある. IoU はピクセル単位の評価であるためその数値が 62.3%と低く出たが, 画像上において推論されたボールの位置と本来の位置は重なっているため, ボールがその方向に存在するという判定には誤りがなかった. 水上にはボールに類似した物体はなく, 別のものをボールと誤認識することはなかった. ただし後述するが, カメラから距離が離れると検出できなくなる傾向が見られた. 障害物回避を目的とすればここで実施した画像認識は重要であったといえる.

人は, 使用した学習用画像にはあまり含まれてはいなかったが, IoU は 53.7%と極端に低くはならなかった. Cityspaces dataset で事前学習を行った際に, そのデータセットに人の領域が多く含まれていたことが低くならなかった要因として考えられる.

ボートは, その形状と色が明らかにハスや水面などと異なるため, 71.3%という比較的高い精度が得られた. その一方で同じく人工物である浮きは 0%となった. 0

%とは人が画像中であるクラスであると判断した領域と, 推定された領域の重なりが全くないことを示している. 浮きのピクセルはすべて水面と判断された. その原因は, 浮きが写っている画像数が少なかったためネットワークが適切に訓練されなかったことであろう.

ほとんどの画像で上部の多くの領域を占める空や森林は 97.5%, 92.3%と高い精度を示した. また, 画像下部に多くみられる水面も 79.1%と高い値となった.

本研究で使用したネットワークは今回の目的には十分な性能を備えていることが分かったが, 全体的に分類精度を向上させるためには, より多くの学習画像を使用することが望ましい.

ボールまでの距離及び照度がセグメンテーションに与える影響の評価

Fig. 4 に解像度 512×288 の時に晴天時 (約 100,000 lx, 6 月 30 日 11 時ころ) と曇天時 (約 10,000 lx, 8 月 8 日 13 時半ころ) において横軸にボールとの距離, 縦軸に

Fig. 4. Effects of ambient illumination and distance on classification accuracy.
環境照度と距離が分類精度に与える影響.

Fig. 5. Detection of a poll from a distance about 7 m. (a) Input image. (b) Segmented image.
約 7 m 離れた場所からのポールの検出. (a) 入力画像. (b) セグメンテーション画像.

正解率 (Classification accuracy) を取りそれぞれプロットしたグラフを示す.

ポールとの距離が遠くなるほど正解率が落ちる傾向にあることが分かる. これは, DNN によるセマンティックセグメンテーションでは物体が小さくなるにつれて, 分類時の色情報や空間情報が少なくなることで, 物体の境界があいまいになったためであると考えられる. しかし, 双方の照度で RGB-D カメラの深度取得限界である 4.0 m において, 正解率は 80% を超える結果が得られた. 本手法をロボットボートの視覚部として用いる場合, 異なる照度で, 4 m 先の障害物の方向と距離を検出できれば, 十分に回避制御が可能であると考えられる. 今後コンピュータの性能が上がれば, より高いレートでの処理が可能となると考えられる.

また, 深度の取得はできなかったが, 約 7 m 先のポ

ールも分類することが出来た (Fig. 5). これは, 今回使用した ToF (Time of Flight) 方式の RGB-D カメラの深度取得範囲を超えているため, 今後, より距離取得範囲が広いステレオ方式を使った深度センサと RGB カメラを組み合わせることでより遠くの障害物の検知が行えると考えられる.

謝 辞

本研究は平成 28 年度環境研究総合推進費 課題番号 1-1602 の下で行われた. 研究を進めるに当たってご協力頂いた宮城県伊豆沼内沼環境保全財団の皆様, ならびに関係各位に篤く御礼申し上げます.

摘 要

本研究では水草刈払いロボットの視覚センサとして、ディープラーニングによるセマンティックセグメンテーションにより、湖沼の水上の風景を自動的に分類するシステムの開発を行った。セマンティックセグメンテーションによるクラス分類に関しては今回実験を行った場所で刈り取り対象であるハスと希少種であるアサザを約90%の正解率で分類することができた。ディープラーニングでは画像中の色や形状、位置情報を統合的に学習するため、照度の変化や水面の太陽光反射などの外部環境からの影響を受けず、水上のような特殊な条件下でもロバストな分類が可能であることを示すことができた。障害物として設置した竹や銅管のポールに関しては、4 m以内であれば80%以上の正解率で分類が可能であり、さらに4.0 m以上先に位置する場合でも分類しその位置を測定できることを確認した。今後は、これらの分類結果と深度画像を組み合わせることによって、特定の植物種の刈払いや希少種の回避、障害物の回避などをロボットボートが自動的に行えるリアルタイム画像処理システムの開発を行う必要がある。

引用文献

- 安野翔・嶋田哲郎・芦澤淳・星雅俊・藤本泰文・菊地永祐 (2015) 伊豆沼のハス群落拡大に伴う貧酸素化の底生動物群集への影響. 伊豆沼・内沼研究報告 **9**: 13-22.
- 芦澤淳・星雅俊・藤本泰文・嶋田哲郎 (2015) 湖沼における刈払い装置を用いたハス群落の抑制方法に関する試験. 伊豆沼・内沼研究報告 **9**: 61-70.
- Breheret A. (2017) Pixel Annotation Tool. <https://github.com/abreheret/PixelAnnotationTool>.
- Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018) Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. ECCV 2018 833-851. https://doi.org/10.1007/978-3-030-01234-2_49.
- Dos Reis, D. H., Welfer, D., De Souza Leite Cuadros, M. A. & Gamarra, D. F. T. (2019) Mobile Robot Navigation Using an Object Recognition Software with RGBD Images and the YOLO Algorithm. Applied Artificial Intelligence. <https://doi.org/10.1080/08839514.2019.1684778>.
- Digumarti, S. T., Schmid, L. M., Rizzi, G. M., Nieto, J., Siegart, R., Beardsley, P. & Cadena, C. (2019) An Approach for Semantic Segmentation of Tree-like Vegetation. 2019 International Conference on Robotics and Automation (ICRA) 1801-1807. <https://doi.org/10.1109/ICRA.2019.8793576>.
- 藤本泰文 (2011) 伊豆沼・内沼に隣接するため池で観察されたハス *Nelumbo Nucifera* の分布拡大にともなうコウガイモ *Vallisneria Denseserrulata* 群落の消失. 伊豆沼・内沼研究報告 **5**: 13-19.
- 藤本泰文 (2018) 葉柄の刈払いがハス *Nelumbo Nucifera* の枯死に及ぼす影響. 応用生態工学 **21**(1): 37-43.
- 藤田一弥・高原歩 (2016) 実装ディープラーニング. 第1版. オーム社.
- Ghosh, S., Pal, A., Jaiswal, S., Santosh, K. C., Das, N. & Nasipuri, M. (2019) SegFast-V2: Semantic image segmentation with less parameters in deep learning for autonomous driving. International Journal of Machine Learning and Cybernetics **10**(11): 3145-3154.
- 平塚智子・山室真澄 (2013) 国内におけるハス群落管理対策の事例. 水草研究会誌 **99**: 38-43.
- Kaehler, A., Bradski, G. R. (2018) 詳解 OpenCV3. 初版. オライリージャパン.
- 環境省 (2019) 平成30年度公共用水域水質測定結果. <https://www.env.go.jp/water/suiiki/h30/h30-1.pdf>.
- Long, J., Shelhamer, E. & Darrell, T. (2015) Fully convolutional networks for semantic segmentation. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) 3431-3440. <https://doi.org/10.1109/CVPR.2015.7298965>.
- Mehta, S., Rastegari, M., Shapiro, L. & Hajishirzi, H. (2019) ESPNetv2: A Light-Weight, Power Efficient, and General Purpose Convolutional Neural Network. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) 9182-9192. <https://doi.org/10.1109/CVPR.2019.00941>.
- 仲田信也・梅田信・嶋田哲郎・藤本泰文 (2015) 伊豆沼におけるハス群落消長の年間変動と湖水・底質環境の関連. 土木学会論文集 B1(水工学) **71**(4): 757-762.
- 野村宗弘・千葉高之・藤林恵・西村修 (2017) ハスの長期分解実験による粒状有機物の残存割合の評価及び底質への堆積傾向. 土木学会論文集 G(環境) **73**(7): III_241-III_246.
- 嶋田哲郎・神山和夫・森晃・藤本泰文 (2016) UAVを用いたマガンねぐらの環境収容力の推定. 日本鳥学会誌 **65**(2): 161-66.
- 斎藤康毅 (2016) ゼロから作る Deep Learning. 初版. オライリー・ジャパン.
- The Pytorch organization (2020) PyTorch documentation. <https://pytorch.org/docs/stable/index.html>.
- 梅田信・別当雄亮・進東健太郎 (2011) 伊豆沼における底質の巻き上げと湖面風の関連. 土木学会論文集 A2(応用力学) **67**(2): I_615-I_623.
- 山室真澄 (2010) 手賀沼においてハス群落が水環境に及ぼす影響評価と適切な整備・管理方法に関する研究. 河川整備基金助成事業 助成番号: 22-12. <http://public-report.kasen.or.jp/221211008.pdf>