

人工知能（Artificial Intelligence）Labellio を用いた飼育下カマイルカの個体識別

木村容子¹, 吉中敦史², 笹森琴絵¹, 北 夕紀¹

Individual identification of captive Pacific white-sided dolphins using Labellio

Yoko Kimura¹, Atsushi Yoshinaka², Kotoe Sasamori¹ and Yuki F. Kita¹

¹Department of Marine Biology and Sciences School of Biological Sciences Tokai University

²Noboribetsu Marine Park Nixe

Abstract

Individual identification of cetaceans is important for understanding their ecology, and many whales have been identified using photographic surveys. However, the amount of data is enormous, and there are cases where objectivity is poor when observed by more than one researcher. In this study, we focused on the image recognition website Labellio, which can even be used by researchers without knowledge of artificial intelligence. We examined the effectiveness of seven optimization algorithms installed in Labellio in the observation of four captive Pacific white-sided dolphins (*Lagenorhynchus obliquidens*), but no significant difference was found in any of the algorithms. As a result of comparing the accuracy, recall, and precision derived from deep learning through progressive trials A to G, the values were significantly higher in trials F and G, and the highest values for individual verification were achieved in trial G. The results also suggest that the images used for learning should be oriented in a certain direction, be clear, and have no background features. The results of this research are expected to contribute to the processing of extensive image data for individual identification in the wild.

¹ 東海大学生物学部海洋生物科学科

² 登別マリンパークニクス

* Tel : 011-571-5111, Fax : 011-571-7879, Email : y2bridge@tsc.u-tokai.ac.jp

1. はじめに

鯨類の行動パターンを知ることは、分布生態を明らかにするという生物学的な興味だけでなく、我々が鯨類を利用もしくは保護管理しようとする際にも重要な情報となる¹⁾。鯨類の行動を知るための一つに、個々のイルカやクジラを識別し、その観察歴を繋ぐことで移動の実態を明らかにする標識法という方法があり、中でも、鯨類の背鰭や尾鰭に元来よりある体色や外部形態などの特徴を利用した自然標識法が主流である¹⁾。室蘭市噴火湾に来遊するカマイルカ (*Lagenorhynchus obliquidens*) においても、その特徴を写真やビデオに記録することで、本種の個体群動態が明らかにされつつある²⁻³⁾。しかしながら、写真データは非常に膨大であり、ヒトの目で視認し、一個体ずつ識別するには、多大な労力と時間を要する。また、複数人で個体識別を行う場合、個体における特徴の捉え方に個人差が生じ、客観性に乏しいという問題があった。

一方、人工知能 (Artificial Intelligence: AI) が現在注目されている。AI は、人間が持つ高度な情報処理機能を調べ、これを機械的に実現することを目指した技術である⁴⁾。その技術の一つに、画像を識別させることが可能な深層学習 (ディープラーニング) と呼ばれる機械学習法がある。深層学習は、大量の画像を AI に認識させることで、どの特徴に着目して識別すればよいかを自ら学習する機能を持つ。中でも Labellio という画像認識ウェブサイトは、プログラミングや画像認識技術の知識を持たない初心者でも、個人のオリジナル画像認識モデルを数分で作成できるウェブサービスである。一般的に画像認識は教師画像と学習パラメータの試行錯誤を繰り返すことを基本と

するが、Labellio はそれらの試行錯誤を簡単に行うことが可能とされている。本来、画像認識技術を活用するためには、AI の専門知識、高性能な計算機、Python などの機械学習用ソフトウェアのノウハウなどが必要であり、専門家のいない現場にとって単独で取り組むにはハードルが高かった。その点 Labellio は、画像認識技術や AI を扱う専門的な知識がなくても簡単に扱うことが可能という点で非常に期待できる。

本研究では、野生下での実用化を視野に、個体 ID が明確な飼育個体より得られた画像データを用い、画像認識ウェブサイト Labellio の有効性を検討したのでここに報告する。

2. 実験材料および方法

2-1. 供試画像

登別マリンパークニクスで飼育されているカマイルカ、キヨ、コウ、マル、キラの合計 4 個体より得られた画像データ 323 枚を深層学習用データ (246 枚) と、評価用画像 (77 枚) とに分類し、本研究に供した (Table 1, 2)。

本研究では Labellio の有効性を検討することから、個体 ID が明確で、複数人が容易に識別可能な個体を用いる必要があった。キヨは、体側面に特徴的な模様はないが、前頭部の灰黒色と灰白色の境が直線的という特徴を有する。コウは、目の黒模様が濃く、胸鰭の上部に黒色のまだら模様がある。マルは、他の個体に比べて眉のような模様が濃いのが特徴である。キラは、白色の体側面に黒点が 1 つあり、黒模様の背部から頭部に向けて 1 本の黒い線を有する (Fig. 1)。

Table 1 Number of images in each trial.

Trial	Kiyo	Kou	Maru	Kira	Total
A	60	56	56	74	246
B	39	45	43	58	185
C	34	26	33	44	137
D	23	19	24	35	101
E	23	17	21	35	96
F	18	14	19	30	81
G	18	14	19	30	81

Table 2 Number of images in each test

Test	Kiyo	Kou	Maru	Kira	Total
A	15	29	19	14	77
B	9	14	11	11	45
C	15	23	17	11	66
D	9	8	9	8	34
E	9	8	9	8	34
F	5	5	5	5	20
G	5	5	5	5	20




Fig. 1 The Photo of captive Pacific white-seeded dolphin in Noboribetsu Marine Park Nikusu
A shows Kiyo. B shows Kou. C shows Maru. D shows Kira

2-2. Labellio を用いた深層学習

取得した画像 246 枚全てを使用した試行 A, 鮮明な画像 185 枚を抜粋した試行 B, 試行 A より左向きのみの画像 137 枚を使用した試行 C, 試行 C から鮮明な画像 101 枚を抜粋した試行 D, 試行 D からグレースケールのみの画像 96 枚を抜粋した試行 E, 試行 A よりバックヤードにて左向きで撮影した画像 81 枚を使用した試行 F, 試行 F から背景を削除した画像 81 枚を使用した試行 G に細分化し, Labellio の有効性を検討した (Table 1).

試行データごとに Zip ファイルを作成し, 画像認識ウェブサイト Labellio (<https://www.labell.io/ja/>) に画像をアップロードした. 学習に用いる最適化アルゴリズムは Labellio に搭載されている 7 種類 (デフォルト設定, AdaDelta, AdaGrad, Adam, FTRM, Momentum, RMSPro) 全てを比較した後, 最適だと思われる条件にて各試行を 5 回実施することによって正確率を算出した.

2-3. 深層学習の評価と再現率の算出

深層学習の精度を評価するために, 各試行に対応した評価用画像データを読み込ませ (Table 2), 画像が

どの個体に識別されるかを各試行と各最適化アルゴリズムにおいて検証した. 評価用画像データに対して正しく識別された割合を再現率, AI によって識別されたデータ数に対して正しく識別された割合を適合率として算出した⁵⁾.

$$\text{再現率} = \frac{\text{正確に識別された画像の枚数}}{\text{評価用画像枚数}} \quad (\text{式 1})$$

$$\text{適合率} = \frac{\text{正確に識別された画像の枚数}}{\text{AI によって識別されたデータ数}} \quad (\text{式 2})$$

3. 結果

7 種類の最適化アルゴリズムを用いた深層学習の結果, AdaDelta は 0.631 ~ 0.975 (平均 0.831), AdaGrad は 0.631 ~ 0.975 (平均 0.831), Adam は 0.719 ~ 0.963 (平均 0.879), FTRM は 0.794 ~ 0.975 (平均 0.910), Momentum は 0.800 ~ 1.000 (平均 0.923), RMSPro は 0.406 ~ 0.944 (平均 0.717) という正確率を示し, デフォルトに対する有意差は認められなかった ($p > 0.05$, Fig. 2). 再現率においても, AdaDelta で 0.353 ~ 1.000 (平均 0.564), AdaGrad で 0.324 ~ 0.850

(平均 0.529), Adam で 0.324 ~ 0.750 (平均 0.489), FTRM で 0.294 ~ 0.900 (平均 0.567), Momentum で 0.338 ~ 0.950 (平均 0.529), RMSPro で 0.400 ~ 0.900 (平均 0.576) を示し, 正確率同様にデフォルト設定に対する有意差は認められなかった ($p>0.05$, Fig. 2).

最適化アルゴリズムをデフォルトに設定し, 試行 A ~ G の深層学習を各 5 回実施した際の比較を行ったところ, 正確率は 0.731 ~ 0.891 (平均 0.815), 識別画像を用いた再現率は 0.347 ~ 0.860 (平均 0.512), 適合率は 0.241 ~ 0.911 (平均 0.498) であった (Fig. 3). Tukey-Kramer の多重比較検定の結果, 正確率と再現率および適合率との間に有意差が認められ, 正確率はどの施行においても高い値を示した ($p<0.05$). 各試行間との比較においては, 正確率はいずれの試行に

おいても有意差は認められなかったが, 再現率と適合率においては, 試行 F と G が他の試行と比較して有意に高かった ($p<0.05$).

個体別における再現率は, キヨが 0.222 ~ 1.000 (平均 0.361), コウが 0.325 ~ 0.960 (平均 0.611), マルが 0.442 ~ 1.000 (平均 0.827), キラが 0.000 ~ 0.320 (平均 0.157) であり, いずれの試行においてもキラの再現率は他個体よりも低い値を示した (Fig. 4). また, キラはいずれの試行においても有意差は認められなかったが, キヨとマルは試行 F と G が他の試行と比較して有意に高い値を示し ($p<0.05$), コウにおいては試行 G と他の試行との間に有意差が認められた ($p<0.05$).




Fig. 2 Accuracy and recall for each optimization algorithm. Solid line shows accuracy. Dotted line shows recall. Error bar shows standard deviation.




Fig. 3 Accuracy, recall and precision in each trial. Black solid line shows accuracy. Black dotted line shows recall. Gray solid line shows precision. Error bar shows standard deviation. * shows $p<0.05$.




Fig. 4 Correct answer rate under each trial. Black box shows Kiyo. Gray box shows Kou. White box shows Maru. Diagonal line texture shows Kira. Error bar shows standard deviation. * shows $p<0.05$.




Fig. 5 Precision under each trial. Black box shows Kiyo. Gray box shows Kou. White box shows Maru. Diagonal line texture shows Kira. Error bar shows standard deviation. * shows $p<0.05$.

個体別における適合率は、キヨが 0.100 ~ 0.710 (平均 0.531), コウが 0.237 ~ 1.000 (平均 0.608), マルが 0.347 ~ 0.967 (平均 0.514), キラが 0.000 ~ 1.000 (平均 0.341) であり (Fig. 5), キヨはいずれの試行においても有意差は認められなかったが, コウとマルは試行 F と G が他の試行と比較して有意に高い値を示し ($p < 0.05$), キラにおいては試行 G と他の試行との間に有意差が認められた ($p < 0.05$, Fig. 5).

4. 考 察

7 種類の最適化アルゴリズムを用いた正確率と再現率との比較では, 正確率と再現率の間には有意差は認められたものの, 各最適化アルゴリズム間における有意差は認められなかった (Fig. 2). 深層学習のためのモデルの作成には, 損失関数, 多クラス交差エントロピー, 最適化アルゴリズムの指定が必要であるとされており, 最適化アルゴリズムは損失関数を最小化するためのチューニング要素となると報告されている⁸⁾. Labellio のデフォルト設定がどの最適化アルゴリズムを使用しているかの記載はなかったが, 他のアルゴリズムとの有意差が認められなかったことから, 以後の解析はデフォルト設定を基本に実施した.

各試行における正確率には, 有意差は認められなかったが, 再現率および適合率においては, 試行 F と G において他の試行よりも有意に高い値を示した ($p < 0.05$, Fig. 3). したがって, 深層学習の学習用画像は, 一定方向を向き, 明瞭で, 背景に特徴が無いものが最適であると示唆された. また, 再現率と適合率が低い試行においても, 正確率は一定程度の高い値を示したことから, Labellio によって算出された正確率は信頼性に欠けると考えられた.

個体ごとの再現率を比較すると, キラが終始低い値を示したのに対し (0 ~ 32.0%), キヨとコウは試行 F (100%, 80%) と試行 G (100%, 96%) で高い値を示し, マルにおいては 44.2 ~ 100% と終始高い値を示した (Fig. 4). 一般的に学習用データ数の量で分類の平均精度が変わると報告されており, データ数の少ない個体がデータ数の多い個体に誤分類される場合が多い⁶⁾. しかしながら, 本研究ではいずれの試行においても個体ごとのデータ数に差はなく, 試行 F と G においてはキラが最も多くの画像を学習させている. したがって, キラに関しては Labellio における分類は

困難な可能性が示唆された.

一方, 適合率における比較では, 全試行で比較的高い値を示したマルにおいて, 試行 A ~ E (34.7 ~ 37.5%) で低い値を示した. 再現率と適合率はトレードオフの関係にあり, 一方が上昇することで, もう一方は減少すると報告されている⁷⁾. そのため, マルの適合率の低さはそれに起因する可能性もある. しかしながら, コウは再現率 (32.5 ~ 62.5%) と適合率 (23.7 ~ 55.4%) との間に差がなく, 再現率の低かったキヨやキラの画像がマルと認識された結果であると考えられた (Fig. 4, 5). 対して, 試行 G (67.9 ~ 100%) では, 再現率の低かったキラ (32%) も含めて高い値を示した. キラにおいてはそもそも認識された画像数が少なく, 結果的に誤分類も無いことから高い値を示すことは必然とも考えられるが, 個体の特徴を正確に学習させるためには, 一定方向を向き, 明瞭で, 背景に特徴が無いものが最適であると示唆された.

本研究では, 画像認識ウェブサイト Labellio の有効性を検討するため, 飼育下個体を用いて深層学習を行った. その結果, 再現率および適合率は試行 F と G で高くなり, 個体別に検証した結果, 試行 G が最適であると示された. 一方で, 本研究ではショー中やバックヤードにてイルカを制止させるために, トレーナーが画像背景に映り込んでいた. したがって, AI が学習する際にトレーナーを誤認識したために, 背景を除去した試行 G が最も良い結果となったと考えられた. 野生下鯨類における個体識別は, 御蔵島に生息するミナミハンドウイルカなどドルフィンスイムにてイルカの全体映像をとらえることの可能な種においては, 前後左右あらゆる特徴から実施されているが⁹⁻¹⁰⁾, 陸上や船上での観察しかできない多くの鯨類においては背鰭や尾鰭などで実施されている^{3, 11-13)}. これらの調査に Labellio を活用させる場合, 撮影者の能力にもよるが必ずしも鮮明な画像のみが蓄積されるとは限らない. 一方, 背鰭や尾鰭に明瞭な切れ込み等が存在する場合は, ある程度どの方向を向いていても学習データとして使用することが可能であるが, カマイルカの背鰭やザトウクジラの尾鰭のように, 前後左右で模様が異なるような場合がある. したがって, 明瞭な画像の使用が好ましいが (試行 F 以上), 背鰭は左向きのみ, 尾鰭は腹側など一定方向の画像データを用いる試行 C 以上の学習データが必要であると考えられた.

また、野生下においては、基本的な背景は海洋であり、AIの誤認識を誘発する可能性は低いと考えられることから、試行Gのような煩雑な作業は不要と考えられる。今後は試行C以上の野生下画像データを用いた検討が必要であるが、野生下における膨大な画像データの正確な自動識別が可能となると期待された。

5. 謝 辞

個体識別画像取得のために識別個体の撮影にご協力いただきました登別マリンパークニクス飼育員の皆様に感謝申し上げます。

英文 Abstract の構成につきましてコメント頂きました国際文化学部国際コミュニケーション学科の Mark Hamilton 教授に感謝いたします。

6. 引用文献

- 1) 村山司 (2008) 鯨類学, 東海大学出版会.
- 2) Tsutsui S, Tanaka M, Miyazaki N, Furuya T. (2001) Pacific white-sided dolphins (*Lagenorhynchus obliquidens*) with anomalous colour patterns in Volcano Bay, Hokkaido, Japan. *Aquatic Mammals*, 27, 172-182.
- 3) 北夕紀, 小池麻美, 笹森琴絵. (2018) 室蘭市噴火湾に来遊するカマイルカ (*Lagenorhynchus obliquidens*) の個体群動態. 東海大学紀要生物学部, 7, 15-20.
- 4) 菅原研次 (2003) 情報工学入門シリーズ 20 人工知能 [第2版], 森北出版株式会社
- 5) 鈴木達也, 西尾真由子. (2019) 橋梁定期点検における部材損傷度判定への深層学習の適用に関する検討. 土木学会論文集 F3 (土木情報学), 75, 48-59.
- 6) Schröter, H., Nöth, E., Maier, A., Cheng, R., Barth, V., Bergler, C. 2019. Segmentation, Classification, and Visualization of Orca Calls Using Deep Learning. ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings, 2019, 8231-8235.
- 7) 田畑佑, 党紀, 春田大二郎, Ashish S, 松永昭吾, 全邦釘. (2018) UVA 撮影と深層学習を用いた橋梁損傷の自動検知に関する検証. 土木学会論文集 F4 (建設マネジメント), 74, 62-74.
- 8) 有賀友紀, 大橋俊介. (2019) R と Python で学ぶ [実践的] データサイエンス & 機械学習. 株式会社技術評論社.
- 9) 加藤暁音, 小木万布, 酒井麻衣, 廣瀬慶子, 森阪匡通. (2010) いるかいなか, 御蔵島観光協会.
- 10) Sakai M, Kita YF, Kogi K, Shinohara M, Morisaka T, Shiina T, & Inoue-Murayama M. (2016). A wild Indo-Pacific bottlenose dolphin adopts a socially and genetically distant neonate. *Scientific reports*, (6): 23902.
- 11) 加藤秀弘. (2000) 事典「クジラの尾ビレ」—小笠原・沖縄一, 財団法人東京都海洋環境保全協会小笠原海洋センター
- 12) 大泉宏, 幅祥太, 中原史生, 三谷曜子, 北夕紀, 斎野重夫, 吉岡基. (2020) 根室海峡で確認された日本初記録のシャチ (*Orcinus orca*) 白色個体. 日本哺乳類学会, 60, 243-248.
- 13) Mitani Y, Kita YF, Saino S, Yoshioka M, Ohizumi H, Nakahara F. (2021) Mitochondrial DNA Haplotypes of Killer Whales around Hokkaido, Japan. *Mammal Study*, 46, 205-211.