

## AI on Animals:

## 野生動物の行動を観測するAI搭載型センサデバイス



技術解説

前川 卓也\*

AI on Animals:

AI-enabled Sensor Device for Monitoring Behaviors of Wild Animals

Key Words : Bio-logging, Activity/behavior recognition, Machine learning

## 1. はじめに

新しい学問領域の進展は、顕微鏡や望遠鏡など、新しい観測装置の発明とともにあった。海中や大空、極地、ジャングルなどの研究者が定常的に立ち入ることが困難な環境に生息する野生動物の生態は、人類にとってまだまだ未知なる研究フロンティアである。バイオリギングは、動物に搭載したセンサデータデバイスを用いて、人により直接観測が難しい動物の生態をきめ細やかに記録する技術であり、そのような環境の動物の生態を観測する技術として注目を集めている。

バイオリギングの黎明期においては、水圧計などの単純なセンサを用いた計測がおこなわれてきた。しかし海洋生物や鳥類に添付するデバイスには重量の制限があり、大型のバッテリーを搭載することは困難である。そのため、さまざまなモダルのセンサを同時に計測する場合や、消費電力の大きなセンサ(カメラなど)で録画する場合は、そのバッテリー持続時間が問題となってきた。

このバッテリーの問題を解消するべく、これまでは単純な閾値処理を用いてセンサのON/OFF制御がおこなわれてきた<sup>1),2)</sup>。たとえば、水深センサを用いて、深度が10mを超えたら他のセンサもONにするなどの省電力制御が考えられる。しかし、このような単純な制御では動物のきめ細やかな生態を捉

えた制御は難しい。

## AI バイオリギング

そこで筆者らはバイオリギングデバイスに搭載した小型のAIにより、カメラなどの高コストなセンサやモジュールを知的に制御するAIバイオリギングを提唱している<sup>3)</sup>。AIバイオリギングでは、加速度センサなどの低消費電力なセンサから得られたデータを用いて、機械学習などによりデバイスが装着された動物の行動をリアルタイムに認識する。そして、認識結果に応じて高コストなモジュールを制御する。例えば、生物学者が動物の採餌行動に興味がある場合、加速度センサによりリアルタイムに採餌行動を検出し、採餌行動が行われたときのみ、カメラの電源をONにする。

筆者らは、これまでに海鳥、ウミガメ、魚、クマなどの目視による長期間観測が困難な動物のAIバイオリギングによる行動観測を行ってきた(図1)。本稿では、筆者らのこれまでの取り組みのうち、教師あり学習および教師なし学習を用いたAIバイオリギングの枠組みを紹介する。

## 2. 教師あり学習を用いた AI バイオリギング

## 2.1 教師あり学習による行動認識

教師あり学習とは機械学習手法の一つであり、人間が教師として事前に与えたデータに基づき計算機が学習を行う枠組みを指す。この教師あり学習を動物行動の認識に利用することで、適応的なカメラ制御を実現する<sup>3)</sup>。

教師あり学習を用いた行動認識の手順は学習フェーズと認識フェーズに分けられる。学習フェーズでは、動物を観測したセンサデータが与えられたとき、それに対してエキスパート(動物生態学者など)が人手でラベル付けをおこなう。センサデータは時系列データ(時刻順に数値が並んだデータ)を想定し



\* Takuya MAEKAWA

1980年7月生まれ  
大阪大学大学院 情報科学研究科 マルチメディア工学専攻博士後期課程  
(2006年)  
現在、大阪大学大学院 高等共創研究院  
教授 博士(情報科学)  
専門/IoT (Internet of Things)、ユビキタス・コンピューティング、ウェアラブルコンピューティング  
TEL : 06-6879-4510  
E-mail : maekawa.takuya.ist@osaka-u.ac.jp



図1 開発したバイオリギングデバイス、デバイスを動物に装着した際の様子（ウミネコの写真：名古屋大学杉山響己氏提供）

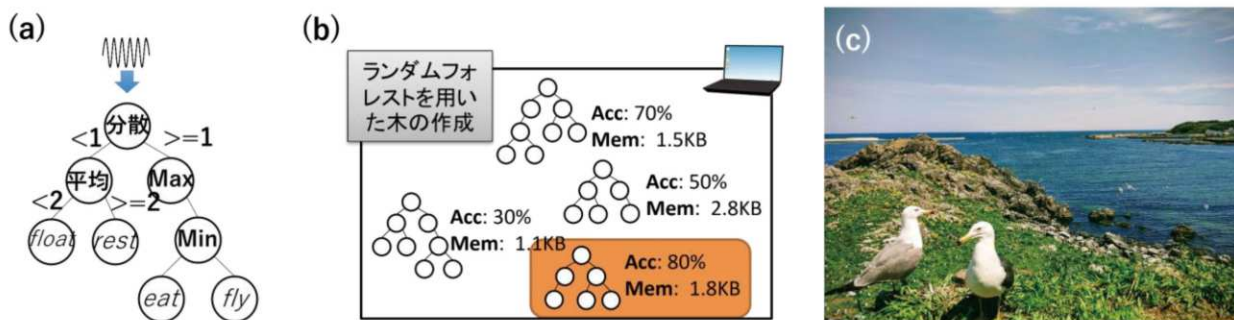


図2 決定木による行動認識の仕組みと燕鳥のコロニーの様子

ているため、ラベルは対応する行動名および、その開始時刻と終了時刻から構成される。

そして、ラベル付けされたセンサデータに対して、特徴抽出処理をおこなう。特徴抽出とは、元のデータから、目的の分類に有用な特徴情報を抽出する処理のことで、たとえば動物に添付した加速度データからは、振幅や周波数などの特徴情報が一般的に抽出される。行動ごとに動きの大きさや周波数は異なるため、そのような特徴を用いて行動の分類が可能となる。そして、ラベル付けされた特徴情報を用いて行動を分類する行動分類モデルを学習する。

認識フェーズでは、学習済みの行動分類モデルを用いて、人間の教師情報なしで、自動的に行動を認識（分類）する。センサから行動を捉えたセンサデータが観測されると、学習フェーズと同様に特徴抽出を行う。そして、行動分類モデルを用いて、行動ラベルを推定することで、計算機による自動的な行動認識を達成する。

## 2.2 バイオリギングデバイス上での行動認識

しかし、一般的にバイオリギングデバイス上に搭載されるマイコンは極めて貧弱であり、そのようなマイコン上でも動作する行動認識手法を実現する必要がある。一般的に、多くの分類器では分類に必要

となる特徴をあらかじめすべて計算してそれらを連結した特徴ベクトルを構成しておく必要があるため、計算コストが非常に大きい。そこで筆者らは、動物が現在おこなっている行動の認識に必要な特徴のみを計算するような分類器の構成とした。

具体的には、決定木とよばれる分類器を用いて分類をおこなう。図2aに示すように、決定木は木構造で表現される階層的な分類ルールである。まず、木の根ノードから開始し、ノードに対応する特徴値が特定の閾値より大きいか否かで、どちらの子ノードを次に迎えるかが決まる。たとえば図2aの例では、根ノードは「分散」という特徴に対応し、特徴ベクトル内の分散の特徴値が1より小さければ左の子ノードを、そうでなければ右の子ノードを迎える。この判定を、最終的に葉ノード（子を持たないノード）に到達するまで繰り返しおこなう。葉ノードは分類結果のクラスの情報を保持しており、最終的に辿り着いた葉ノードに対応するクラスが分類結果となる。たとえば図2aの例で、分散の特徴値が1より小さく、さらにその左子ノードである「平均」の特徴が2より小さければ、「float」という分類結果となる。

このように、決定木を用いた分類では根ノードから葉ノードまでたどったノードに関する特徴値のみを必要とするため、あらかじめすべての特徴を計算

する必要がない。すなわち、センサデータが観測された際に、そこから必要とされる特徴値のみを計算すればよい。また、各ノードにおける分類ルールも値の大小を比較するだけであるため、非常に計算コストが低い。そのため、筆者らは決定木をデバイス上に搭載する分類器として選んだ。ただし、決定木に用いられる特徴には非常に計算コストの高いものや、計算プログラム自体のデータサイズが大きいものも存在するため、決定木の構成自体も工夫する必要がある。低消費電力なマイコンは、その記憶領域も限られており、特徴計算をおこなうプログラムをすべて格納することは困難である。そのため、決定木は必要最低限の特徴（に対応するノード）から構成されるべきである。そこで筆者らは、ランダムフォレストアルゴリズムとよばれる、ランダム性を持たせて大量の決定木を生成する手法を基に、プログラムのデータサイズが大きい特徴が決定木の中で利用される確率を減らすように大量の決定木を生成した（図 2b）。そして、それぞれの決定木のデータサイズと分類精度（あらかじめ用意した検証用データを利用して計算）を両立した木を、デバイスに搭載する木として選ぶ。アルゴリズムの詳細は、文献 3) を参照されたい。

## 2.3 青森県蕪島における検証実験

共同研究先の生態学者である、名古屋大学 依田憲教授らの協力のもと、青森県蕪島に生息するウミネコ (*Larus crassirostris*) を対象として、ロガーの検証実験をおこなった（図 2c）。事前にウミネコから計測された加速度センサに対して、興味深いと思われる区間およびそれ以外の区間をラベリングしてもらった。飛行や滞在に関わる行動はそれ以外の区間に対応し、採餌などをおこなっている可能性のある区間が興味深い行動に対応している。そして、興味深い行動とそれ以外を加速度データを用いて分類するよう決定木を学習し、興味深い行動が認識されたときのみ、ロガーのカメラを起動するようにした。図 1 に、ロガーの外観とロガーをウミネコに搭載した際の画像を示す。ロガーには GPS、加速度センサ、カメラ、水深センサ、気圧計などが搭載されている。

また、図 3a にロガーによって実際に撮影された動画のスクリーンショットを示す。図 3a は、ウミネコが海上を飛行中に虫を捕獲しているシーンであ




図 3 AI バイオロギングデバイスにより撮影されたウミネコの行動の例

る。このようなウミネコの海上の行動は初めて観察されたものであり、ウミネコの採餌に関わるエネルギー消費を考慮した戦略の存在を示唆している。この行動は、新行動の発見として鳥学会の学会誌にも掲載された<sup>4)</sup>。また図 3b は、ウミネコが他の個体が捕獲した魚を奪取したシーン（労働寄生）である。なお、実験にて撮影された動画の一部は以下の YouTube チャンネルにおいても公開している。  
<https://www.youtube.com/@aionanimals870>

計測された加速度データの分析によると、ウミネコの日中の行動において、捕食行動の占める割合はわずか 2% 程度であり、ランダムにカメラを起動する方法などでは、捕食行動を捉えることは困難である。一方で、提案手法では、録画した映像のうち約 30% が採餌と思われる行動を記録していた。提案手法のように、対象行動を認識した上で撮影をおこなうことで、これまでに発見されていなかった行動を捉えられる確率を大幅に向上させることができる。

## 3. 教師なし学習を用いた AI バイオロギング

### 3.1 異常検知手法を用いた希少行動の検出

上述の教師あり学習を用いた手法は、データ収集とラベリングのコストが膨大であるという欠点があった。また、研究者が事前に想定した対象行動を捉えるために開発されたものであるため、これまで観測したことのない予期せぬ希少な行動を捉えるためには適用できない。観測が困難な希少な行動には、これまでに知られていない生物学的発見が潜んでいる可能性があり、学術的にも有用である。

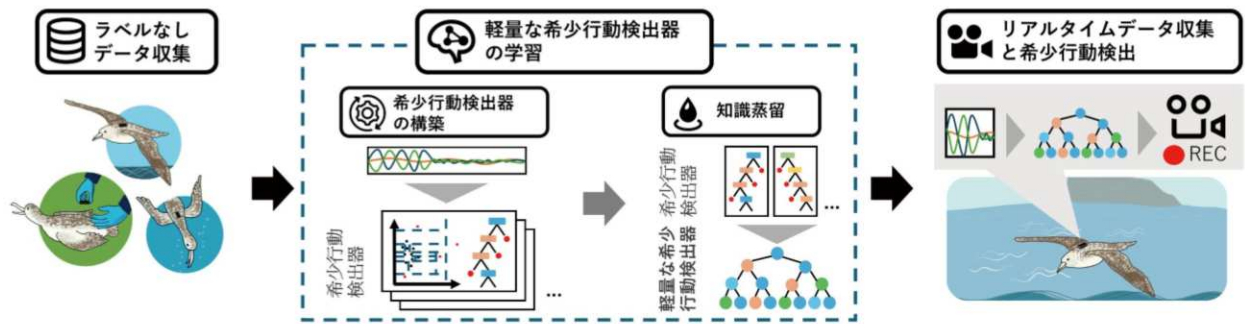


図4 軽量な希少行動検出器の構築方法

そこで研究者によるラベルありデータなしに希少な行動を捉えるため、ラベルなしデータからパターンの自動発見が可能な教師なし学習を利用する。希少行動を外れ値とみなし、教師なし外れ値検出技術を活用して低コストな加速度などのセンサのデータから、動物の希少行動を自動的に検出し、その行動のビデオを記録する<sup>5)</sup>。本アプローチによって検出された動物の行動は、希少な行動とみなされるため、記録されたビデオがこれまでに目撃されたことのない行動を捉えている確率が高い。提案する手法を実装したバイオリギングデバイスを動物に装着して自然環境に放つと、バイオリギングデバイスは自動的に野生の環境で興味深い動物のイベントを含む動画を自動的に記録する。その後、研究者はセンサデータと併せて動画を分析することで、新たな動物行動に関する仮説を提案することができる。

しかし、一般的な外れ値検出手法はメモリや計算コストが高いため、バイオリギングデバイスに搭載されるメモリや計算能力に制限のある低消費電力のマイコンでこれらの方法を実行するのは難しい。この問題を解決するため、筆者らは、あらかじめ対象動物のラベルなしデータを用いてコンピュータサーバ上で外れ値検出器を学習させたあと、知識蒸留を用いて軽量な外れ値検出器を構築する。知識蒸留では、元の外れ値検出器を教師モデルとして、軽量な外れ値検出器を生徒モデルとして構築する。このとき、教師モデルの振る舞いを模倣するように生徒モデルを学習する。そして、この生徒モデルの外れ値検出器をバイオリギングデバイスに実装することで、リアルタイムに希少行動を検出する。

図4に、提案するアプローチの概要を示す。提案するアプローチは3つのステップから構成される：(1) 希少行動検出器を学習するためのラベルな

しデータ収集、(2) 軽量な希少行動検出器の学習、(3) リアルタイムデータ収集と希少行動検出。第2ステップは、2つのサブステップから構成される：(2-1) 希少行動検出器の構築と(2-2) 知識蒸留である。最初のステップでは、対象種の個体から、加速度センサのような低コストのセンサからラベル付けされていないセンサデータを収集する。

第2ステップでは、センサデータにおける外れ値を希少行動と定義し、サーバコンピュータ上のラベルなしデータに対して、希少行動検出器として異常値検出器を訓練する。本研究では、異常値検出器として Isolation Forest を用いた。次に、教師モデルとして元の希少行動検出器を使用し、生徒モデルとして軽量な希少行動検出器を構築するために知識蒸留を利用する。生徒モデルである軽量な希少行動検出器は、Isolation Forest (教師モデル) と同じ結果を出力するように訓練し、生徒モデルで使用される特徴量は教師モデルと同じである。具体的には、ラベル付けされていない特徴ベクトルを入力とした際の Isolation Forest の出力 (異常か否かの2値ラベル) を、生徒モデルを訓練するためのラベルとして採用した。生徒モデルとしては上述の研究と同様に決定木を用いた。第3ステップとして、対象動物に装着したバイオリギングデバイスに軽量な希少行動検出器を実装する。アルゴリズムの詳細は、文献<sup>5)</sup>を参照されたい。

### 3.2 新潟県粟島における実証実験

新潟県の粟島のコロニーに生息するオオミズナギドリ (*Calonectris leucomelas*) を用いて実証実験を行った。同じコロニーにて収集したラベルなし加速度センサデータを用いて、希少行動検出器を訓練した。加速度センサを用いることで、希少行動による



図5 バイオロギングデバイスを装着したオオミズナギドリ

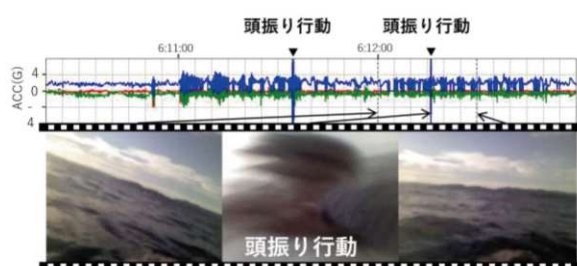


図6 自動的に撮影されたオオミズナギドリの希少行動の例

体の動きを捉えることが期待できる。図5にデバイスを装着したオオミズナギドリの例を示す。

実験の結果飛行中に首を振る行動が外れ値として自動的に検出されており、その様子の動画が撮影されていた(図6)。分析の結果、鳥が海面から飛び立った直後に頭を振っているように考えられたため、飛行行動開始時刻から頭を振る行動までの経過時間を測定したところ、飛行行動の開始時に頭を振る行動が集中的に行われていることが示唆された。

海鳥は通常、塩分濃度の高い海水にさらされている。ペンギンなどの一部の海鳥は、頭を振ることで鼻塩腺や、頭や嘴に付着した水分などを取り除くことが知られている。今回の結果から、オオミズナギドリは飛行開始後すぐに頭を振ることが多いことがわかった。オオミズナギドリは、水浴びや海での採餌により、鼻塩腺内や頭に付着した水分を除去するためにこの行動をとった可能性がある。このような外部物質を飛行を開始した段階で除去することで、体全体の質量が減少し、以降の飛行効率が向上する可能性がある。

#### 4. おわりに

本稿では、バイオロギングデバイスに搭載した小型のAIにより、カメラなどの高コストなセンサやモジュールを知的に制御するAIバイオロギングを

紹介した。また、教師あり学習および教師なし学習を用いたAIバイオロギングデバイスと実証実験についても紹介した。AIバイオロギングにより、バイオロギングデバイスの限られたリソースを適切に割り振ることで、様々な動物の行動の発見に繋がった。

筆者らは、海鳥以外にもウミガメや鮭などの海中に生息する様々な動物に対してもAIバイオロギングの展開を進めている。研究者の代わりに長期間にわたって自律的に情報収集をする動物装着型AIデバイスを海中などの自然環境に放つことで、将来的に人類による探索領域の大幅な拡大を実現することができるかもしれない。

なお、AIバイオロギングにより撮影された動画などを以下のYouTubeチャンネルにて公開しているため、是非とも見て頂きたい。

<https://www.youtube.com/@aionanimals870>

#### 参考文献

- 1) Kays, R., Crofoot, M. C., Jetz, W. & Wikelski, M. Terrestrial animal tracking as an eye on life and planet. *Science*, 348, aaa2478 (2015).
- 2) Kooyman, G. L. Techniques used in measuring diving capacities of Weddell Seals. *Polar Rec.* (Gr. Brit) 12, 391–394 (1965).
- 3) Korpela, J. M., Suzuki, H., Matsumoto, S., Mizutani, Y., Samejima, M., Maekawa, T., Nakai, J. & Yoda, K. Machine learning enables improved runtime and precision for bio-loggers on seabirds. *Communications Biology*, 3(1), 633 (2020).
- 4) 水谷友一, 鈴木宏和, 前川卓也, Joseph Korpela, 宮竹貴久, 越山洋三, 依田憲: 海上飛行中のウミネコによる昆虫捕食とその同定, 日本鳥学会誌, vol. 70, pp. 53-60, (2021年).
- 5) Tanigaki, K., Otsuka, R., Li, A., Hatano, Y., Wei, Y., Koyama, S., Yoda, K. & Maekawa, T. Automatic recording of rare behaviors of wild animals using video bio-loggers with on-board light-weight outlier detector. *PNAS Nexus*, 3(1), pgad447 (2024).