

AI・ICT 技術を活用した猛禽類調査

はやし ゆうすけ みかみ たく しんどう としのり せじま よしゆき たかに あずま
林 佑亮¹・三上 卓²・進藤 俊則³・瀬島 義之¹・高荷 東⁴

¹ (株) エイト日本技術開発 中部支社(〒460-0003 愛知県名古屋市中区錦 1-11-20)

² (株) エイト日本技術開発 東京本社(徳島大学客員准教授)(〒164-9601 東京都中野区本町 5-33-11)

³ (株) エイト日本技術開発 中国支社(〒700-8617 岡山県岡山市北区津島京松 3-1-21)

⁴ (株) エイト日本技術開発 東京支社(〒164-9601 東京都中野区本町 5-33-11)

インフラ事業において、猛禽類の生息に配慮した事業を推進するため、猛禽類調査を行うケースが多い。一般的な調査手法は、目視による定点観測調査であるが、近年は営巣木に設置したビデオカメラにより巣内を監視する調査が普及している。

著者らは、簡易かつ迅速な繁殖状況の把握を行うための挙動検知システムの開発を試みた。営巣木に設置した IoT カメラ映像を用いた機械学習(教師あり学習)を行い、ホールドアウト検証により、オオタカの挙動を把握することに成功した。加えて、他の営巣地のデータによる汎化性能を確認するとともに、ファインチューニングを行うことでモデルの精度向上を図った。

Key Words : 猛禽類調査, IoT カメラ, AI, 教師あり学習, 汎化性能, ファインチューニング

1. はじめに

工事箇所近傍で猛禽類が営巣する場合、建設機械の稼働や資材等運搬車両の走行など、工事作業に伴う騒音や振動、またその存在により、猛禽類の繁殖活動への影響が懸念される。そこで、猛禽類の生息に配慮した事業を推進するため、環境保全措置として猛禽類調査を実施し、工事に対する忌避行動の有無を監視することが一般的である。これまで猛禽類調査は、2~3 日程度/月の頻度で定点観測調査によって行われてきた。しかし、樹林内を自由自在に行動する猛禽類を目視観察により把握するには限界があり、終日に観察を行っても数例または数分程度の記録に留まることも多い。このような状況から、猛禽類への工事影響を評価するにあたっては、「工事箇所周辺で猛禽類が出現したが工事を警戒する様子は見られなかった」、「巣外育雛期に無事に幼鳥の巣立ちが確認されたため事業影響は小さい」など、客観性に乏しいデータにより影響の有無を判断し、評価を行っているケースも見られる。

近年、AI 技術や IoT カメラデバイスなどの技術革新が進み、多くの分野でこれらの技術が活用されている。著者らは、ある河川整備箇所の近傍で営巣が確認された希少猛禽類オオタカへの影響を監視するため、営巣木に IoT カメラを設置し繁殖状況と工事に伴う忌避行動の有無を監視した。また、映像確認の効率化を図るため、AI 技術を活用し、「抱卵」や「給餌」といったオオタカの巣内の行動の自動把握を可能とする学習済みモデルの作成を行った¹⁾。

また、学習済みモデルの汎化性能の評価を試み、その結果を通して、ファインチューニングによる性能向上を図った。

2. 猛禽類調査

本研究の対象である河川整備事業(以下、事業 A とする)では、河道確保に伴う硬岩掘削のために発破工が計画され、発破箇所から 900m の地点でオオタカが営巣していた。「猛禽類保護の進め方(改訂版) -特にイヌワシ、クマタカ、オオタカについて-」²⁾によれば、繁殖期のオオタカの行動圏は約 1.5 km 圏内である。したがって、オオタカの行動圏内で行う発破に伴う繁殖活動への影響が懸念された。なお、発破はオオタカの繁殖期にあたる 2 月から 7 月の平日に 1 日 2 回(午前 11 時、午後 4 時)の頻度で計画された。

(1) 定点観測調査

定点観測調査は、猛禽類の営巣木の周辺に設定した複数の調査定点に調査員を各 1 名配置し、双眼鏡や望遠鏡を用いて、出現した猛禽類を観測する手法である。月 1 回 2 日間の頻度で行い、オオタカの繁殖期(概ね 2~7 月)に実施する。

事業 A の発破工に伴うオオタカへの影響を評価する必要があったが、従来の定点観測調査の実施頻度を踏まえると、毎日行われる発破工の影響を把握することは困難と考えた。

(2) ICT 技術を活用した猛禽類調査

事業 A におけるオオタカへの工事影響を把握するため、著者らは営巣木に IoT カメラを設置した（写真-1）。IoT カメラの映像は携帯電話のキャリア回線を通じて送信され、調査員がスマートフォンや PC から常時監視できるシステムとした。IoT カメラの電源は、営巣地の林縁部に設置したリチウムバッテリー4 台により供給し、月 1 回の頻度でバッテリーを交換した。なお、カメラの設置は、オオタカの繁殖期前の 1 月中に行った。



写真-1 IoT カメラの設置状況

a) 発破時間帯の映像確認

発破の 30 分前から発破の 30 分後まで、約 60 分間を対象にオオタカの異常・異変の有無についてリアルタイムで監視を行った。ここで、異常行動の判断基準は以下の通りとした。

【異常行動の判断基準】

- ・発破直後に、巣内の親鳥が落ち着きのない様子でしきりにキョロキョロする。
- ・発破直後に、巣内の親鳥が警戒声を発する。
- ・発破直後に、抱卵もしくは育雛中の親鳥が飛び立ち、巣を離れる。

b) 全期間の映像確認

オオタカの産卵時期、卵の孵化時期などの生活史は、地域や繁殖ペアによって異なる。今後の河川整備事業において、事業地周辺に生息するオオタカの詳細な生活史を把握しておくことが有益と考えた。そこで、発破の時間帯に限らず、電源トラブルにより、録画がされなかった時間帯を除く全ての録画映像について、巣への飛来・飛去時間、行動内容、雌雄の別、卵・雛の数を記録した。また、全期間の映像を確認することで、万が一繁殖に失敗した場合の工事との因果関係を明確にできると考えた。

c) IoT カメラによる監視結果

監視の結果、オオタカに発破が原因と疑われる異常行動は見られず、幼鳥 2 羽の巣立ちを確認した（表-1）。他の公共事業では、保全対策として繁殖期の約半年間に渡り、工事を中断するケースも存在する中、本提案により、事業を円滑に進めることに貢献できたと考える。なお、営巣地では合計 4 卵を

産卵し、3 卵が孵化した。その内、1 羽の雛については、繁殖ペア以外のオオタカにより持ち去られたことが映像により判明し、学識者からも貴重な見聞が明らかになったとの助言を得た。

事業 A における従来の定点観測調査と IoT カメラによる監視調査を比較したところ、IoT カメラによる監視調査が長時間にかけてオオタカの行動を捉えることに成功した（表-2）。

表-1 監視したオオタカの繁殖経過

主な事象	確認時期	備考
巣へ初飛来	1 月 27 日	—
産卵	4 月 16～4 月 25 日	計 4 卵を産卵
孵化	5 月 23～5 月 27 日	計 3 卵が孵化
雛の巣立ち	6 月 28～7 月 3 日	計 2 羽が巣立つ

表-2 調査方法ごとの延べ観察時間の比較

調査方法	確認例数 (合計)	観察時間 (合計)
定点観測	47 例	約 94 分 30 秒
IoT カメラ	1,683 例	456 時間 50 分 51 秒

3. AI 技術を活用した猛禽類調査

IoT カメラによる監視では、オオタカ繁殖期の約 6 ヶ月間に及ぶ膨大な映像データを蓄積するため、巣への飛来状況などを目視で確認するには多大な時間と労力を要するものであった。特に、抱卵期から育雛期には、餌運びや育雛のために親鳥が頻りに巣を出入りするため、確認作業に多大な労力を要した。こうしたカメラ調査の作業効率化の課題に対し、AI による機械学習 (Machine Learning) 技術の活用を検討した。

(1) 機械学習に用いたデータ

2. で監視したオオタカの録画映像（営巣地 A）に加え、過去に著者らが他地域で幼鳥の巣立ちまでを記録したオオタカの録画映像（営巣地 B）を機械学習に用いた（写真-2～3）。



写真-2 カメラ映像（営巣地 A）



写真-3 カメラ映像（営巣地B）

(2) ラベル付きデータの作成

①個体の判定（在巢）に加え、オオタカの繁殖行動として特徴的な②抱卵行動、③給餌行動の計3種について Microsoft 社製のアノテーションソフトウェア VoTT (Visual Object Tagging Tool) を用いてラベル付きデータを作成した。個体の判定（在巢）は、造巣期の巣への飛来確認による繁殖兆候を把握するため、抱卵及び給餌行動は、繁殖の成否に大きく関わる行動であることを踏まえ、機械学習の対象とした。営巣地A及びBともに、上述の①～③の3種類の行動について、それぞれ2,500枚のラベル付きデータを作成した。

(3) 学習済みモデルの作成

まず、営巣地Aについて学習済みモデルの構築を行った。モデルの構築には、株式会社AIDの協力を得て、フレームワーク「PyTorch」³⁾、機械学習モデル「YOLOv5」⁴⁾を用いた。モデルの評価にはホールドアウト検証を行うことを想定し、①～③それぞれについて、(2)で作成したラベル付きデータの中から80%にあたる2,000枚を訓練データとして、学習済みモデルを作成した。

(4) ホールドアウト検証

構築した学習済みモデルの評価を行うため、ラベル付きデータのうち、残り20%の500枚をテストデータとして、交差検証を行った(表-3)。

表-3 営巣地Aの交差検証結果

		予測結果				合計
		在巢	抱卵	給餌	未検出	
実際の結果	在巢	444	8	7	41	500
	抱卵	21	468	1	10	500
	給餌	50	9	340	101	500

交差検証結果は、教師あり機械学習における分類モデルの性能評価方法に用いられる「正解率」、「再現率」、「偽陽性率」を、予測結果と実際の結果の混合行列(表-4)及び式(1)～(3)により算出し、評価した(表-5)。

$$\text{正解率} = \frac{TP+TN}{TP+FP+FN+TN} \quad (1)$$

$$\text{再現率} = \frac{TP}{TP+FN} \quad (2)$$

$$\text{偽陽性率} = \frac{FP}{TN+FP} \quad (3)$$

表-4 混合行列

		予測結果	
		Positive	Negative
実際の結果	Positive	True Positive (TP) Positiveと予測し正解 【在巢と予測し正解】	False Negative (FN) Negativeと予測し不正解 【在巢以外と予測し不正解】
	Negative	False Positive (FP) Positiveと予測し不正解 【在巢と予測し不正解】	True Negative (TN) Negativeと予測し正解 【在巢以外と予測し正解】

【】には、在巢をPositiveとした際の成否判定を記載

表-5 営巣地Aの交差検証結果の評価

行動内容	正解率	再現率	偽陽性率
在巢	0.92	0.89	0.07
抱卵	0.97	0.94	0.02
給餌	0.89	0.68	0.01

交差検証結果の評価において①在巢、②抱卵、③給餌は繁殖活動の継続を示すポジティブな行動であることから、まず、再現率の評価が重要となる。再現率は、①在巢が0.89、②抱卵が0.94を示しており高いモデル精度といえる。しかし、雛や獲物が映り込むなど、行動が複雑化する③給餌は、0.68と再現率は低かった。また、繁殖活動の監視を効率化する上で、「抱卵していない」のに「抱卵している」といった誤判定は、繁殖にとって負の事象を正として判定していることから好ましくない。そこで、偽陽性率も重要な評価要素である。偽陽性率は、①在巢が0.07、②抱卵が0.02、③給餌が0.01という値から、今回の学習済みモデルはこの点についても高い精度であったと評価できる。

(5) 汎化性能

作成した学習済みモデルの汎化性能を確認するため、営巣地Bをテストデータとして、(3)で作成した営巣地Aによる学習済みモデルの汎化性能を確認した。その結果を表-6～7に示す。

表-6 営巣地Bの汎化性能結果

		予測結果				合計
		在巢	抱卵	給餌	未検出	
実際の結果	在巢	65	89	0	346	500
	抱卵	4	8	0	488	500
	給餌	153	3	0	344	500

表-7 営巣地Bの汎化性能結果の評価

行動内容	正解率	再現率	偽陽性率
在巢	0.61	0.13	0.16
抱卵	0.61	0.02	0.09
給餌	0.67	0.00	0.00

再現率は、①在巢が 0.13、②抱卵が 0.02、③給餌が 0.00 と極めて低い精度となっており、満足する結果は得られなかった。この原因としては、営巣地 A が側面から撮影しているのに対し、営巣地 B では真上から撮影しており、画角が異なることでオオタカを同一の物体として判定しなかったと考える。

(6) ファインチューニング

(5)の結果を受け、営巣地 A の学習済みモデルに、営巣地 B のラベル付きデータを用いてファインチューニングを行った。①在巢、②抱卵、③給餌の行動に対して、それぞれ、営巣地 A 及び B とともに 2,500 枚のラベル付きデータを用いて、新たな学習済みモデルを作成し、営巣地 A 及び B それぞれのテストデータで再度、検証を行った(表-8~11)。

表-8 営巣地 A の交差検証結果 (ファインチューニング)

		予測結果				合計
		在巢	抱卵	給餌	未検出	
実際の結果	在巢	470	10	9	11	500
	抱卵	5	495	0	0	500
	給餌	85	10	374	31	500

表-9 営巣地 A の交差検証結果 (ファインチューニング) の評価

行動内容	正解率	再現率	偽陽性率
在巢	0.92	0.94	0.09
抱卵	0.98	0.99	0.02
給餌	0.91	0.75	0.01

表-10 営巣地 B の交差検証結果 (ファインチューニング)

		予測結果				合計
		在巢	抱卵	給餌	未検出	
実際の結果	在巢	482	0	0	18	500
	抱卵	24	398	73	5	500
	給餌	10	0	490	0	500

表-11 営巣地 B の交差検証結果 (ファインチューニング) の評価

行動内容	正解率	再現率	偽陽性率
在巢	0.97	0.96	0.03
抱卵	0.93	0.80	0.00
給餌	0.94	0.98	0.07

表-5 及び表-9 のとおり、学習済みモデルをファインチューニングしたことで、営巣地 A の交差検証結果において、再現率が①在巢 0.89→0.94、②抱卵 0.94→0.99、③給餌 0.68→0.75 と向上した。給餌行動は、雛に対し体勢を低くする形相で行うため、営

巣地 A の側面から撮影したカメラ映像に対し、背中が映り込むことが多くなる。営巣地 B の映像が個体の背面を捉えた映像が多いため、より背面の形相を判定しやすくなったものと推察される。

また、表-7 及び表-11 のとおり、営巣地 B の訓練データを加えることで、再現率が①在巢 0.13→0.96、②抱卵 0.02→0.80、③給餌 0.00→0.98 と精度が向上した。

4. おわりに

本論文は、猛禽類調査に IoT カメラ及び AI 技術を導入することで、繁殖状況の的確な把握及び効率化を図る取り組みの経過をまとめたものである。従来の猛禽類調査は、目視で行うことから、猛禽類が樹林内に滞在している際に、その動向が把握できないなどの問題がある。このため、営巣地の近傍で行われる工事が猛禽類に影響しているのかどうかは、巢外育雛期の巣立ち雛の確認や、偶然にも工事箇所近傍に出現した猛禽類の行動状況から評価せざるを得ない。こうした中、本研究の意義としては、繁殖活動の拠点である巣内の状況を事細かく把握することにより、工事作業時の挙動や卵・雛の数、外敵による雛の持ち去りといった細部の情報を収集できることである。また、映像確認に係る作業を自動化することで、巣内で発生した事態の早期把握が期待される。忌避行動の原因が工事による可能性がある場合には、追加の保全対策により、猛禽類の生息に配慮した事業推進が期待できる。工事影響がないことをカメラにより監視することで、事業を中断することなく円滑に推進することにも期待される。

本論文における AI アルゴリズムは、2 箇所のオオタカの繁殖ペアの挙動を学習させたものであり、他の営巣地での精度は保証されたものではない。今回、営巣地 A の学習済みモデルへ営巣地 B のファインチューニングを行ったことで、モデルの精度向上が確認された。今後、他の営巣地での汎化性能を確認するとともに、更なるファインチューニングを図ることで、汎用性の高いモデル構築を目指す。

謝辞：株式会社 AID の代表取締役社長石川氏、赤松氏には、学習付きモデルの作成に関し、多大なご協力を授かりました。厚く御礼を申し上げ、感謝の意を表します。

参考文献

- 1) 林佑亮, 三上卓, 増原碩之: 猛禽類調査における挙動検知システム構築への取り組み, AI・データサイエンス論文集, 4 巻(2023)2 号, p128-134, 土木学会, 2023
- 2) 環境省自然環境局野生生物課: 猛禽類保護の進め方(改訂版)―特にイヌワシ, クマタカ, オオタカについて―, 平成 24 年 12 月
- 3) PyTorch: <https://pytorch.org/>
- 4) yolov5: <https://github.com/ultralytics/yolov5>