

## 畳み込みニューラルネットワークのバギングに基づく 実験動物の探索行動自動判定の試み

岩本 洋紀<sup>†</sup> 永石 和久<sup>†</sup> 西山 悟史<sup>‡</sup> 都地 昭夫<sup>†</sup> 北西 由武<sup>†</sup>

<sup>†</sup>塩野義製薬株式会社 <sup>‡</sup>シオノギテクノアドバンスリサーチ株式会社

### 1. はじめに

医薬品研究開発における非臨床研究では、実験動物（ラットやマウスなど）を用いた薬理評価が行われる。Novel Object Recognition Task (NORT) は動物の記憶・学習などを評価するものであり、動物へのストレスが少ないことや応用形を考えやすいことなどから、汎用される評価系の一種である[1]。

NORT の概要を図 1 に示す。NORT は獲得試行・識別試行と呼ばれる 2 段階の試行からなる試験である。獲得試行では、動物に同じ物体を 2 つ提示し、それらを記憶させる。その後一定期間（典型的には 1 日）後に、1 つを異なる物体に変更して識別試行を実施する。通常ラットやマウスは見たことのないモノに興味を示す性質があるため、記憶機能が正常であれば、新奇物体により強い興味を示すと期待される。したがって、識別試行での 2 物体への興味の差異を定量化することで、動物の記憶機能を評価することができる。

NORT では探索と呼ばれる行動を通し、物体への興味の強さを評価する。これは図 2 で示すように物体を鼻先でなぞるような行動であり、実験時間のうち探索行動を示した合計時間を、その物体への興味の指標とする。通常、探索時間は熟練者の目視により測定するが、1 回の評価に要する目視時間は数十時間に及び、作業負担が非常に大きい。そのため、探索行動の自動判定システムが求められている。

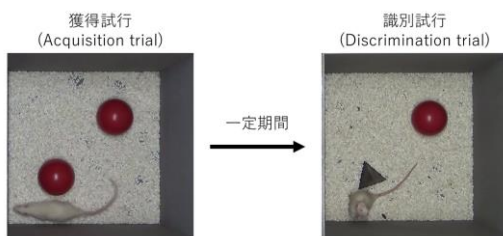


図 1: Novel Object Recognition Task (NORT)

An attempt to automatically determine laboratory animals' exploratory behavior based on bagging of convolutional neural network,

<sup>†</sup> Hiroki Iwamoto, Kazuhisa Nagaishi, Akio Tsuji, Yoshitake Kitanishi: Shionogi & Co., Ltd.

<sup>‡</sup> Satoshi Nishiyama: Shionogi TechnoAdvance Research CO., LTD.




図 2: 探索行動の例

実験動物トラッキングのための研究は複数行われている。Mathis らは深層学習ベースの動物トラッキングソフトウェア・DeepLabCut[2]を開発し、動画内の各部位（鼻先、脚、尾など）の高精度検出を可能にした。しかし、トラッキングによる手法では各部位の座標推定しかできず、探索行動以外の行動（物体によじ登る、単に近くに居るのみ、など）との区別が困難である。そこで本研究では、物体周辺のフレーム画像を入力とし、ラットの探索行動を判定する機械学習モデルを開発することを目指す。提案手法では、訓練データをブートストラップサンプリングして作成した複数のデータセットを用いてバギングを行うことにより、ラベルに曖昧性をもつデータセットに対して予測性能向上を試みた。

### 2. 提案手法

#### 2.1. 畳み込みニューラルネットワーク

畳み込みニューラルネットワーク

(Convolutional Neural Network; CNN) により、探索/非探索の二値分類モデルを構築する。ネットワークアーキテクチャには ConvNext[3]を使用した。入力画像は、図 2 のように物体周辺を切り抜き 224×224 にリサイズしたものである。

#### 2.2. バギングによるアンサンブル

ブートストラップサンプリングにより学習/検証データを組み替えながら、上述の CNN モデルを 10 個構築する。推論時には、それらの多数決で各フレームを探索/非探索に分類する。最終的に、探索判定されたフレームの総数にフレームレートを乗ずることで合計探索時間を求める。

### 3. 結果と考察

#### 3.1. データセット

合計 225 分、延べ 49 匹のラット NORT 動画を使用した。データの内訳を表 1 に示す。獲得試

行は1匹あたり3分、識別試行は1匹あたり5分の動画からなる。図1で確認できる通り、獲得試行では赤球2つ、識別試行では赤球と黒錐を提示した。全体を通して、熟練者の目視により探索/非探索がラベル付けされている。なお、テストデータに含まれる2種類の物体の割合を均等にするため、テストデータには識別試行のみを使用した。

表 1: データセット

	獲得試行	識別試行	合計
学習	30分 (10匹)	75分 (15匹)	105分 (25匹)
テスト	0分	120分 (24匹)	120分 (24匹)
合計	30分 (10匹)	195分 (39匹)	225分 (49匹)

学習データ量削減のため、DeepLabCutによりラットが物体周囲にいるフレームを特定し、各フレームの物体周辺を切り抜いて入力画像とした。学習データの80%をブートストラップサンプリングしながら、10個のCNNモデルを作成した。また、各CNNモデルで学習に使わなかった20%のデータは、検証データとしてearly stoppingや検出閾値決定に用いた。テストデータについては、全フレームの物体周辺画像を推論して合計探索時間を予測した。

### 3.2. 結果と考察

上記データセットを用いて提案手法を評価した。比較対象として、DeepLabCutを用いた単独な探索判定も行った。これは、画面内の物体領域に鼻先が入ったときに探索と判定するものである。テストデータにおける合計探索時間の予測値、および熟練者による判定値の比較結果を図3に示す。平均絶対パーセンテージ誤差 (mean absolute percentage error; MAPE) は、DeepLabCutで92.2%だったのに対し、提案手法では16.7%であり、トラッキングによる手法では予測困難だった探索時間を一定の精度で予測できていることが分かる。

図4は提案手法およびバギング前の10個のCNNモデルのMAPEである。バギング前モデルのMAPEの中央値は19.2%であり、バギングによって予測誤差を低減していることが分かる。

今回使用したNORTの動画データでは、特に探索/非探索の境界などにおいて、熟練者のラベル付けにも一定の曖昧性があると考えられる。バギングによって少しずつ判定ルールの異なるモデル群を作成し、それらの多数決をとることで、テストデータに対する平均的な予測精度を向上

させていると考えられる。

## 4. おわりに

本研究では、物体周辺画像を入力としてラットの探索行動を判定する機械学習モデルを開発した。トラッキングによる手法と比較し、提案手法は探索合計時間を良い精度で予測できており、探索行動とそれ以外の行動をよく区別できていると考えられる。また提案手法では、バギングによるアンサンブルを取り入れることで、評価者によるラベル付けの曖昧性の影響を低減し、予測精度を高めることに成功した。今後はネットワークアーキテクチャやハイパーパラメータの最適化などにより更なる性能改善を行い、目視作業自動化により作業者の負担軽減を実現したい。




図 3: 合計探索時間の予測結果




図 4: バギングによる誤差低減の様子

## 参考文献

- [1] Antunes, M., and Grazyna Biala. "The novel object recognition memory: neurobiology, test procedure, and its modifications." *Cognitive processing* 13 (2012): 93-110.
- [2] Mathis, Alexander, et al. "DeepLabCut: markerless pose estimation of user-defined body parts with deep learning." *Nature neuroscience* 21.9 (2018): 1281-1289.
- [3] Liu, Zhuang, et al. "A convnet for the 2020s." *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. 2022.