

放牧牛の IMU データを用いた 位置推定における LightGBM の有効性評価

Performance Evaluation of LightGBM for Position Estimation of Grazing Cattle Using IMU Data

玉崎 伶河¹⁾
Ryoga Tamasaki

大山 憲二¹⁾
Kenji Oyama

大川 剛直¹⁾
Takenao Ohkawa

1 はじめに

放牧牛の効率的な管理のために必要な技術の一つとして位置推定が挙げられる。屋外での位置推定には GPS が一般的だが、高い電力消費が課題である。そこで、低消費電力な IMU センサを用いて相対変位を推定し、累積することで位置推定する方法が注目されている。IMU を用いた Dead Reckoning (DR) は学習データを必要としない一方、歩行検出や歩幅設定に調整を要し、精度や安定性に課題を残す。一方、LSTM (Long Short-Term Memory) など深層学習は高精度を期待できるが、多くの学習データを必要とし、モデルの解釈も困難である [2]。

本稿では、計算効率と予測性能を両立する LightGBM (LGBM) [1] に着目し、IMU データから牛の相対変位を推定する手法「S2M-LGBM (Static-to-Moving LightGBM)」を提案する。具体的には、まず動いているかどうかを分類し、動いていると判定された区間のみを対象に回帰によって相対変位を推定する二段階のアプローチである。提案手法を放牧牛実データに適用し、精度、解釈性、コストの観点から DR および LSTM と比較評価を行い、その有効性を検証する。

2 提案手法

2.1 モデル概要

本研究では、放牧牛に装着した IMU センサから得られる加速度・角速度・地磁気の 9 軸データを用いて、1 秒ごとの相対変位 $\Delta \hat{\mathbf{p}}_t =$

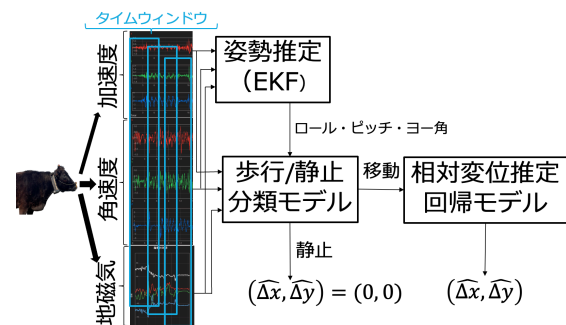


図1 提案手法の概要図

$(\hat{\Delta x}_t, \hat{\Delta y}_t)$ を推定する手法「S2M-LGBM」を提案する。提案手法の概要を図1に示す。具体的な手順を以下に示す。

1. 時系列センサデータから窓特徴量を抽出する。
2. 1. で作成した特徴量を用いて、牛の移動・静止を分類する。
3. 2. で移動と判定された区間に対して、相対変位を回帰により推定する。

LGBM は時系列データを直接扱えないため、手順1ではセンサデータに対して前後 w 秒のタイムウィンドウを適用し、統計・周波数情報などからなる窓特徴量を作成する。特徴量の具体的な構成は次節で詳述する。

手順2では、上記の特徴量を用いて、1秒ごとに放牧牛が移動しているか静止しているかを2値分類する。これは、放牧牛の大半の時間が静止状態であるという不均衡なデータ構造に対応するためであり、誤判定による変位推定の誤差伝播を防ぐ。

手順3では、分類結果が「移動」と判定され

1) 神戸大学 Kobe University

た時間区間に限定して、同じ特徴量を用いて相対変位を回帰により推定する。

分類および回帰モデルのいずれにも LGBM を採用することで、精度と計算効率を両立しつつ、特徴量の重要度に基づくモデル解釈も可能とした。

2.2 特徴量エンジニアリング

IMU センサから取得される加速度、角速度、地磁気の 9 軸成分に対して、前後 w 秒のタイムウィンドウを用いて特徴量を計算する。すべての軸に対して平均と標準偏差を算出したほか、加速度および角速度のノルムに対しては主周波数および 0.5Hz 以下のパワーを含む周波数領域の特徴量も抽出する。また、姿勢推定により得られるロール・ピッチ・ヨー角についても、それぞれ平均と標準偏差を計算し特徴量に加える。

3 実験

3.1 実験設定と評価方法

実験は神戸大学農学研究科附属食資源教育研究センターの放牧場 (約 80 m × 140 m) で実施した。放牧牛に IMU センサ (加速度・角速度: 10Hz) と GPS (地磁気と共に 1Hz) を装着してデータを収集した。

2025 年 3 月 18 日から 22 日に収集したデータのうち、最終日をテスト用、他を学習用とした。移動・静止の正解ラベルと相対変位の正解データは GPS から作成し、GPS の 1 秒間の位置変化量が閾値以上かつ、GPS のノイズを考慮して 3 秒間継続した区間を「移動」と定義した。推定は 5 分ごとの区間で行い、DR, S2M-LSTM (分類, 回帰ともに LSTM), 分類なし LGBM を比較手法として RMSE で評価した。また、 w は経験的に 3 秒とした。

3.2 実験結果と考察

表 1 に示す通り、回帰性能において提案手法 S2M-LGBM は比較手法の中で最も高い精度を示した。静止区間を除外しない LGBM と比べて誤差が抑制されており、二段階推定の有効

表 1 RMSE のパーセンタイル比較 (単位: m)

Percentile	DR	S2M-	LGBM	S2M-
		LSTM		LGBM
50%	3.02	2.54	4.52	2.32
90%	37.93	9.42	9.21	6.16




図 2 移動・静止分類モデルに対する SHAP 値 (上位 5 個)

性が確認できる。S2M-LSTM を上回ったのは、限られた学習データでは LSTM の性能を十分に引き出せなかったためと推察される。

分類モデルの解釈性として、図 2 から最も影響を与えた特徴量がピッチ角の標準偏差であることがわかる。これは牛の頭部の動きが移動判定の重要な指標であることを示唆している。

S2M-LGBM は精度、コスト、解釈性の観点で優れた性能を示し、その有効性を実証した。

謝辞

本研究の一部は JSPS 科研費 21H04914 の助成による。

参考文献

- [1] G. Ke, Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye, and T.-Y. Liu, "LightGBM: A highly efficient gradient boosting decision tree," in *Proc. 31st Conf. Neural Information Processing Systems (NIPS)*, 2017, pp. 3149–3157.
- [2] C. Chen and X. Pan, "Deep Learning for Inertial Positioning: A Survey," *IEEE Trans. Intell. Transp. Syst.*, vol. 25, no. 4, pp. 1234–1245, 2024.