

図3 提案モデル

元へ拡張を行う。これにより、各行動における特徴をより柔軟に学習することを試みている。

ここでは、装置から取得したデータに基づく学習で時系列を利用するためにどのような処理を行うのか、またそれを用いて提案モデルでどのように学習が行われるのかについて述べる。

3.1 取得したデータの補間

取得されるデータには、2.1節で述べたように0.1秒間隔で取得されている部分と0.5秒間隔で取得されている部分が存在する。このようにデータの間隔が不均衡な場合、時系列性を考慮した学習が困難になる。そこで、計測されたデータから未計測部分のデータを補間することで、0.1秒間隔データに整形する。これにより、先行研究[2]などに用いられたものと同様の時系列データセットを生成することができる。学習を行う際の1つの時系列長をウィンドウと定義する。入力を補間する際に欠損していた部分の割合が最も小さくなるのは、補間したい欠損部の0.5秒とその前後のデータを取得できていた0.5秒を合わせた1.5秒間の15点である。そのため、本研究では図2のように0.1秒間隔のデータ点15個(1.5秒)を1つのウィンドウとして補間を行う。また、補間はこのウィンドウ内で何点のデータが取得できているかによって処理を変える。時系列データセットからウィンドウを15点(1.5秒)、オーバーラップを5点(0.5秒)として1.5秒を切り取り1つの補間の対象となる領域とする。図2に示すように、この領域内で8点以上データが取得されている場合のみ補間を行う。これは、ウィンドウ内に外れ値が含まれていた場合に、補間の元となるデータ点よりも補間される欠損点の数が大きくなり、外れ値の影響を受けた点が多数のウィンドウを学習に使用しないためである。

本研究ではウィンドウ内の欠損の前後を直線で結んだ際の直線上に、欠損の対応している点を取る補間(線形補間)、補間多項式がデータ点間ごとに区分的に計算され、各点で多項式が滑らかになるように結ぶような補間(スプライン補間、区分的エルミート補間)の3種を使用して欠損を無くした時系列データをそれぞれモデルに学習させ、その分類性能の評価を行う。



図4 行動(左から歩行・採食・佇立・横臥)

3.2 提案モデル

RNNは、自己回帰の構造を内部に持つ時系列向けのニューラルネットワークである。しかし、学習の入力の時系列長が大きくなると、モデルの入力により近い層の学習が遅くなってしまう勾配消失問題や、ウィンドウ内で将来に係る入力を考慮できない重み衝突問題がある。そこで、これらの問題を解決できるようRNNを拡張したLSTM[6]を用いる。提案モデルの構成を図3に示す。

まず、入力層では連続する15点(1.5秒)それぞれにおける加速度 acc_x , acc_y , acc_z および角速度 $angu_x$, $angu_y$, $angu_z$ の6次元を入力とした計90次元を入力する。1つ目の隠れ層では各時間の特徴量を6次元から30次元へ拡張するようなLSTM、2つ目の隠れ層では 30×15 次元の入力時系列データの最後の30次元のみを出力とするようなLSTMを用いる。3つ目の隠れ層は全結合層であり30次元を4次元へ、最後の出力層では4次元の入力へsoftmax関数を適用することで、入力された1.5秒でされていた行動がそれぞれ歩行、採食、佇立、横臥である確率 p_0 , p_1 , p_2 , p_3 をモデルから出力し、最も確率の高かった行動を、そのウィンドウにおける行動とする。

4. 評価実験と結果および考察

4.1 実験設定

実験の対象とした牛は、神戸大学大学院農学研究科附属食資源教育研究センター(加西市, 兵庫県)で飼育されている牛のうち、4頭である。この4頭に、2.1節にて説明した首輪型装置を装着し、データの取得を行う。今回の実験で使用したデータの取得期間は2020年12月25日~12月31日の7日間の各12時から17時まで、計35時間である。行動ラベルは、放牧場内の俯瞰カメラ画像上で撮影されている牛と、GPSによる位置情報を対応付け、手作業で行動を判別し、作成した。行動ラベルは俯瞰カメラ画像で明確

表 1 補間方法ごとの結果

	LSTM with Linear		LSTM with Spline		LSTM with Hermite		SVM	
	recall	F1-score	recall	F1-score	recall	F1-score	recall	F1-score
歩行	0.357	0.390	0.357	0.441	0.298	0.407	0.316	0.408
採食	0.902	0.868	0.924	0.871	0.916	0.872	0.753	0.659
佇立	0.481	0.529	0.446	0.516	0.524	0.556	0.466	0.499
横臥	0.901	0.891	0.895	0.879	0.891	0.891	0.914	0.795

に認識することが可能である以下の 4 種類を定義する。また、図 4 にそれぞれの行動の際の画像を示す。

- **歩行**: 個体が頭を肩と同程度の高さで維持した状態で牧場内を移動している状況。
- **採食**: 個体が頭を肩より低く下げ、口を接地させている状況。
- **佇立**: 個体が頭を肩と同程度の高さで維持した状態で足を静止させている状況。
- **横臥**: 休息、または反芻のために牧場内で体を接地させている状況。

ラベル付けを行い実験に使用可能となった最終的な延べ時間は 15753 秒 (4 時間 22 分 33 秒) となっている。

次に、加速度および角速度データを時系列データとして利用できるようにする。補間は、3.1 節にて列挙した 3 つの既存手法を用いて行う。補間後は、補間に使用した間隔と同様の 15 個 (1.5 秒) をひとつの時系列データとして扱う。

モデルは 3.2 節にて提案したものを利用している。また、中間層で用いた活性化関数は Rectified Linear Unit (ReLU) である。この行動ラベルごとの確率の最も大きい行動をウィンドウ内で行われた行動とし、モデルを学習させる。学習後、モデルにテストデータを入力し分類の性能を評価する。モデルの入力データには前処理としてデータの 6 次元それぞれに対して正規化を行っており、これにより異なる単位のデータを同様に扱うことを可能としている。時系列データセット数はラベル間で偏りが生じており、歩行が 434 個、採食が 4452 個、佇立が 1924 個、横臥が 3692 個となっている。これを教師データ 70%、テストデータ 30% となるよう分割した後、教師データ内の 20% を検証データとして用いた。学習ではエポック数を 200、バッチサイズを 128 としている。学習における損失関数は交差エントロピー誤差を使用しており、これによって得られた検証データの損失誤差が小さくなるように学習が進められる。また、データの分割の組み合わせを 5 通り用意し実験を行った。実験結果はこれら 5 通りの平均となっている。なお、このモデルの設計や学習の設定には Keras を用いている。

SVM に基づく分類も行う。こちらは時系列データとして学習を行わないため欠損を補間せず、最もデータ数が少なかった行動 (歩行) に合わせるように他の行動データをダウンサンプリングし、行動のデータそれぞれを 1566 個とした。その後、教師データ 70%、テストデータ 30% となるよう分割し、入力を加速度および角速度の 6 次元、出力を行動ラベルとして学習を行った。ハイパーパラメータは 5 分割交差検証を用いたグリッドサーチによって学習の際に最適に設定されており、その結果、カーネル関数は Radial basis function (RBF) カーネル、 $\gamma=0.15$ 、 $C=10$ であ

る。ここで γ はカーネル関数内のパラメータであり、大きいほど複雑な決定境界を生成する。また、 C は誤りをどの程度許容して学習するかを示すパラメータであり、大きいほど誤りを許容しない。なお、このモデルの学習には scikit-learn を用いている。

4.2 実験結果

評価指標は適合率 (precision)、再現率 (recall)、F1 値 (F1-score) を用いる。これらの評価指標は真陽性を TP 、偽陽性を FP 、偽陰性を FN 、真陰性を TF とした時に次のように定義される。

$$\text{precision} = \frac{TP}{TP + FP}$$

$$\text{recall} = \frac{TP}{TP + FN}$$

$$F1 - \text{score} = \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}}$$

3 種の補間を行った提案モデル及び SVM の分類性能を表 1 に示す。また、それぞれの再現率を混合行列として図 5 に示す。

まず表 1 について考察を行う。3 種の補間方法を用いた LSTM に基づく提案モデルでの分類性能について、区分的エルミート補間を用いた場合は線形補間を用いた場合と比較した際に全ての行動で F1 値を上回っている。本実験は前後に最大 5 つずつ存在するデータ点からの補間となるため、線形補間では直線で 5 点以上を結んで補間する。この補間によって各行動の分類性能が落ちてしまっているということから、補間を行う 1.5 秒内の加速度、角速度に牛の各行動の周期特性が大きく含まれていると考えることができる。また、区分的エルミート補間とスプライン補間では、歩行のみスプライン補間が F1 値で上回っている。一般的にエルミート補間はスプライン補間に比べ滑らかな補間とはならず、振動に基づいた分布をしているデータを補間する際には、振幅を小さく補間してしまう。この性質から、歩行の時系列データは他の行動に比べ、より振動的であることが推測される。提案モデルと SVM を用いたモデルの結果を比較すると、歩行を除く 3 つの行動ではいずれの補間方法でも提案モデルが F1 値で SVM を用いたモデルを上回っていることから、加速度および角速度を直接を用いた牛の行動分類では時系列を考慮した分類が適していると分かる。しかし、提案モデルでの学習では行動毎のデータ数に偏りがあり、特に歩行のデータが不足している。これにより、データ数の多い採食、横臥に対して分類性能を向上させるこ

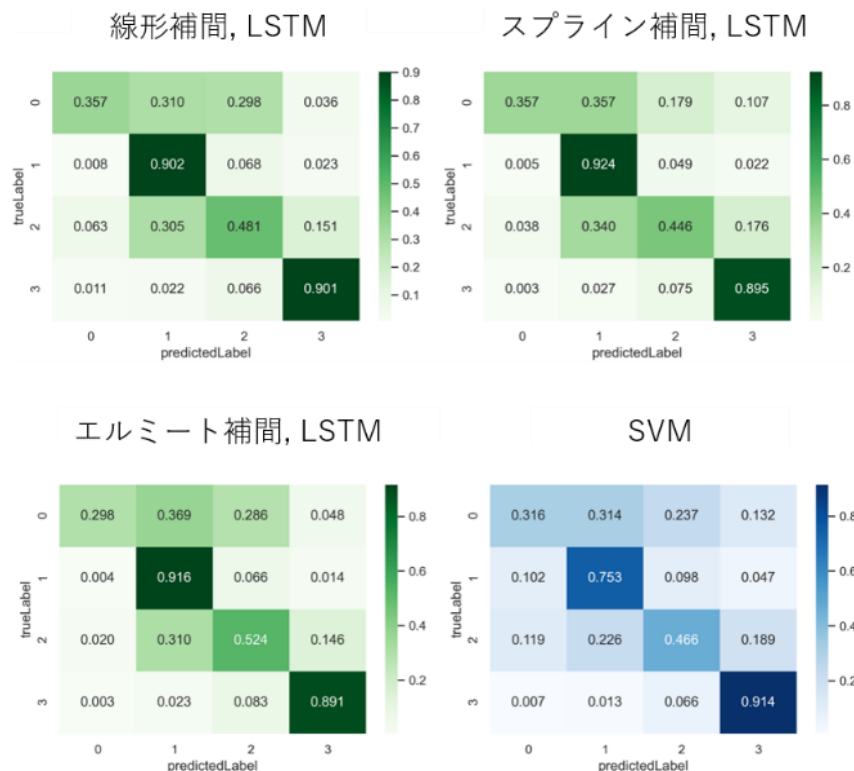


図 5 再現率の混合行列

とでモデル内の損失誤差が下がってしまうので、歩行の分類性能が向上しなかったと考えられる。一方で、同様に時系列データ数の少ない佇立の行動分類の性能は 10%以上向上している。時系列を考慮した学習では、行動の中で首の動きが少ないほど、補間がより正しく行われていると考えられる。

次に、図 5 から各行動間の再現率を用いた考察を行う。ここで混合行列のラベル番号は歩行が 0、採食が 1、佇立が 2、横臥が 3 となっている。図より、どのモデルを用いても大きな分類の傾向の変化は現れなかった。また歩行について、モデルに関わらず横臥を除く行動と誤分類されることが多い。これは、歩行と佇立が首を同程度に保つ行動である事や採食中も微小ではあるものの前進している事といった牛の体勢の類似性による影響を受けていると考えられる。また、提案モデルでの歩行の再現率は、現状 SVM による分類性能と大差ないが、これも歩行のデータが不足していることにより、学習の偏りが生じていることが原因であると考えられる。現在採食として取得されているデータを、脚を完全に静止させている採食と前進に伴う採食に分けることによるデータ数の偏りの緩和や、歩行のデータ数の拡張による正確な誤分類の原因の発見が期待できる。

5. おわりに

本論文では、欠損の規模の大きい時系列データセットを補間し LSTM を用いて学習させるモデルを提案した。補間では従来から使用されている既存の 3 種の補間手法を使用し、これによって時系列データを学習に使用することができた。また、3 種の補間方法それぞれによる分類性能への大きな影響は見受けられなかったが、区分的エルミート補間を用いた場合は、全ての行動の分類で線形補間の場合の

性能を上回ったことにより、この補間方法の有効性を示すことができた。

提案モデルと SVM を使用したモデルでの分類性能を比較した結果、時系列を考慮できる提案モデルでは分類性能が向上することがわかった。グリッドサーチを使用したハイパーパラメータの最適化を行っている SVM に対し、手探りでチューニングを行った提案モデルで分類性能が上回っていることから、時系列を補間して行動分類を行うことに優位性はあると言える。また提案モデルの改良を今後も続けることで更なる分類性能の向上が期待される。

参考文献

- [1] M. Deng and Z. Zhao (2019), "The Cow Attitude Recognition Algorithm Based on Multi-sensor Information Fusion", *2019 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA)*, pp. 283–288.
- [2] A. Rahman, D. Smith, J. Hills, G. B. Hurley, D. Henry, R. Rawnsley (2016), "A Comparison of Autoencoder and Statistical Features for Cattle Behavior Classification", *2016 International Joint Conference on Neural Networks (IJCNN)*, pp. 2957–2960.
- [3] Y. Peng, N. Kondo, T. Fujiura, T. Suzuki, Wulandari, H. Yoshioka, E. Itoyama (2019), "Classification of multiple cattle behavior patterns using a recurrent neural network with long short-term memory and inertial measurement units", *Computers and Electronics in Agriculture*, Vol. 157, pp. 247–253.
- [4] NTT テクノクロス株式会社, U-motion [online] <https://www.ntt-tx.co.jp/products/u-motion/>.
- [5] 株式会社 The Better, LiveCare [online] <https://www.livecare.co.jp>.
- [6] S. Hochreiter, J. Schmidhuber (1997), "Long Short-Term Memory", *Neural Comput* 1997, 9 (8), pp. 1735–1780.