

Multi-Channel MHLF を用いた時系列データの分類手法

橋田 修^{1,a)} 田村 慶^{1,b)}

概要: 近年、深層学習を用いた時系列データの分類に関する研究が盛んに行われており、時系列データを高精度に分類することができる深層モデルの構築が求められている。本論文では深層学習を用いた時系列データの分類に関して畳み込みニューラルネットワーク (CNN) と MACD ヒストグラムを用いた新しい分類手法を提案する。時系列データの分類において CNN を用いた分類手法が提案され、その有効性が示されている。本研究では時系列データから算出された MACD ヒストグラムと時系列データをマルチチャンネルデータとして入力する新しい手法を提案する。具体的には MACD ヒストグラムとして短期、長期の 2 種類のウィンドウを用いて異なる特徴を抽出し、深層モデルとして時系列データの分類において高い精度が報告されている LSTM-FCN モデルのマルチチャンネル化を行った。評価実験では時系列データセットとして公開されている UCR アーカイブデータセットを用いて、従来手法との比較実験を行った。実験結果として提案手法は従来手法よりも精度が高いことを確認できた。

Time Series Classification using Multi-Channel MHLF

1. はじめに

IoT (Internet of Things) への関心の高まりとともに、センサデータから収集された時系列データの利活用が注目されている。時系列データに対する分析手法の一つとして時系列データの分類問題が挙げられる。時系列データの分類問題とは、未知の時系列データに対してあらかじめ設定されたクラスラベルを推定する問題である。時系列データの分類は異常検知や将来予測、状態や個人識別など、さまざまな応用先が考えられ、それらの技術の根幹となる時系列データの分類を高精度に行うモデルの開発が求められている。

近年、時系列データの分類問題に対して深層学習をベースとした手法が盛んに提案されている [1], [2]。特に、畳み込みニューラルネットワーク (CNN) を用いた手法が効果的であることが示され、代表的なモデルとして Fully convolutional network (FCN) モデルが提案されている [3]。また、FCN モデルに Long Short-Term Memory (LSTM) を加えた LSTM-FCN モデルも提案されている [4]。FCN

モデルや LSTM-FCN モデルをベースとした分類手法は従来手法と比べて高精度であることが示されている。

また一方、時系列データだけでなく、時系列データから取り出した Moving Average Convergence and Divergence (MACD) ヒストグラム [5] を応用する研究が行われている。MACD ヒストグラムは時系列データの変化の加速度を表現している。田村ら [6] は、時系列データから MACD ヒストグラムを算出し、MACD ヒストグラムから生成したリカレンスプロットとスタックドオートエンコーダを用いて精度の向上を行えることを報告している。

本研究では時系列データと MACD ヒストグラムをマルチチャンネルデータとして結合し、深層モデルへ入力する新しい分類手法を提案する。具体的には LSTM-FCN モデルの入力部分に対して時系列データとその MACD ヒストグラムをマルチチャンネル化するための変換層を加えた新しいモデルとして Multi-Channel MACD-Histogram-based LSTM-FCN (Multi-Channel MHLF) を提案する。評価実験として UCR アーカイブデータセット [7] を用い、従来手法との比較実験を行った。実験結果において、提案手法は従来手法よりも精度が高いことが分かった。

本論文の構成は次のとおりである。第 2 章で時系列データの分類について関連研究を示し、第 3 章において LSTM-FCN モデルの説明を行う。第 4 章では提案モデルである

¹ 広島市立大学大学院情報科学研究科
Graduate School of Information Sciences, Hiroshima City University, 3-4-1, Ozuka-Higashi, Asaminami-ku, Hiroshima, JAPAN

a) shu.hashida@gmail.com

b) ktamura@hiroshima-cu.ac.jp

Multi-Channel MHLF モデルについて説明する。第5章では評価実験とその結果について示す。第6章ではまとめと今後の課題について議論する。

2. 関連研究

時系列データの分類手法の大きな種別として、距離ベースの手法 [8], [9], [10], 特徴抽出ベースの手法 [11] と深層学習ベースの手法 [3], [4], [6] が挙げられる。また、さまざまな分類モデルを組み合わせたアンサンブル手法がある。本章では、ベースラインの一つであるアンサンブル手法と深層モデルを簡単に説明する。

代表的なアンサンブル手法として Hierarchical Vote Collective of Transformation-based Ensembles (HIVE-COTE) [13] が提案されている。HIVE-COTE は時系列データの分類のためのさまざまな分類モデルを用い、それらの分類モデルをアンサンブルにより分類している。HIVE-COTE は、深層学習を用いない従来手法として分類精度が最も高いモデルであることが報告されている。

深層学習をベースとした手法として CNN をベースとした手法が提案されている。Wang ら [3] は深層学習を用いた時系列データの分類モデルとして Multi-layer Perceptron, FCN, Residual Networks (ResNet) の3つのモデルを提案している。FCN モデルは3つの畳み込み層と Global Average Pooling (GAP) 層 [14] を用いた単純なモデルで十分に高い精度を持っていることが示されている。Karim ら [4] は FCN モデルに LSTM を組み合わせたモデルとして LSTM-FCN モデルを提案している。これは入力層から GAP 層へ LSTM を用いたコネクションが加えられており、FCN モデルとは異なる特徴を抽出している。UCR アーカイブデータセットを用いた実験では最も精度の高いモデルであることが報告されている。本研究では、LSTM-FCN モデルを応用し、複数チャンネルを持つデータを入力する新たなモデルを提案する。

MACD ヒストグラムは時系列データの分類において分類精度の向上に活用できることが報告されている [6]。MACD ヒストグラムは時系列データの変化の加速度として抽出され、時系列データの局所的な特徴を持った時系列データとして表現することができる。本研究ではその特性を利用し、時系列データから MACD ヒストグラムを算出後、入力データにおいて時系列データと MACD ヒストグラムをマルチチャンネルデータとして表現することで、分類精度の向上を図った。

3. CNN に基づく深層モデル

本章では CNN に基づく深層モデルを説明する。

3.1 時系列データに対する畳み込み層の適用

本研究では時系列データは単要素の系列データのみを扱




図1 時系列データに対する畳み込み層の動き
Fig. 1 Convolutinal layer for time series data

う。時系列データに対する畳み込みとは1次元配列に格納されている時系列データに対し、1次元配列として表現されているフィルタを適用することである。

CNN を時系列データに応用するとき、畳み込み層は入力データに対してフィルタを適用し、局所的な特徴を抽出する。畳み込み層はさまざまな手法に取り組みられており、あらゆるデータに対して精度の高い手法として研究が盛んに行われている [15], [16]。時系列データを扱うため、畳み込み層内のフィルタは入力された時系列データの時間軸方向へのみスライドさせ、各ステップごとにフィルタを通して特徴マップを抽出する (図1)。

3.2 LSTM-FCN

LSTM-FCN モデルは FCN モデルをベースにした時系列データに対する分類モデルである。LSTM-FCN モデルは LSTM 層を持った接続を持ち、LSTM 層の入力に対して次元シャッフルを行っている。入力された時系列データに対して3層の畳み込み層と GAP 層による特徴抽出と次元シャッフルが適用された LSTM 層による特徴抽出を行っている。そして最後に、それぞれの特徴ベクトルを結合し、全結合層から出力層を構成している。

次元シャッフルは系列長 N 、特徴量 M の時系列データに対して時間軸と特徴軸の転置を行い、系列長 M 、特徴量 N のデータ形式に変換する手法である。この手法を用いることで系列長の短い時系列データに対するオーバーフィッティングを抑制している。

4. Multi-Channel MHLF

本章では提案手法である、Multi-Channel MACD-Histogram-based LSTM-FCN (以下、Multi-Channel MHLF) モデルについて説明する。

4.1 MACD ヒストグラム

MACD ヒストグラムは指数移動平均 (Exponential Moving Average, EMA) を用いて、複数のウィンドウにより平滑化された系列データから算出される。EMA の算出につ

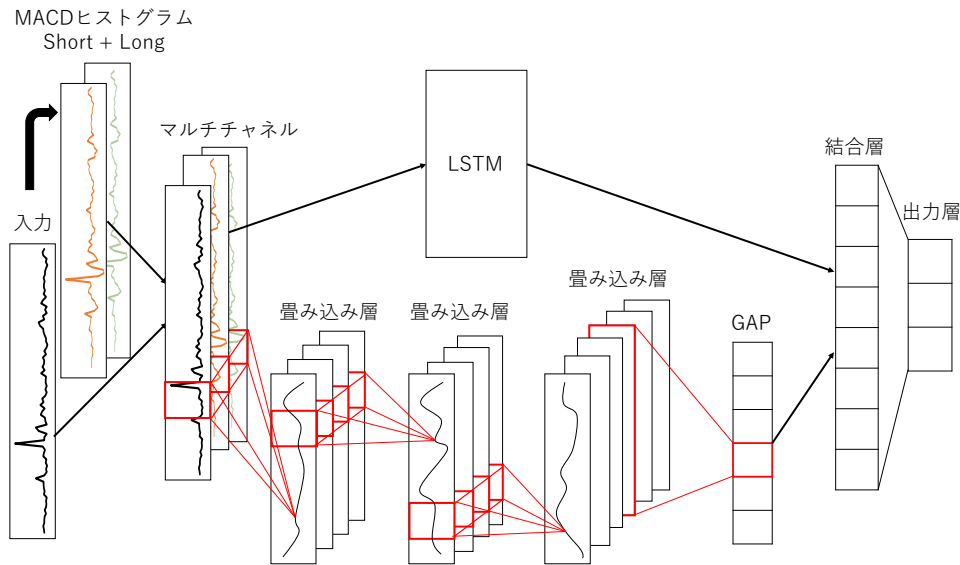


図 2 Multi-Channel MACD-histogram-based LSTM-FCN
Fig. 2 Multi-Channel MACD-histogram-based LSTM-FCN

いて次に示す。

$$EMA(\omega)[X]_i = \alpha \times x_i + (1 - \alpha) \times EMA(\omega)[X]_{i-1} \quad (1)$$

ここで i は時系列データ X におけるインデックスであり、 x_i は時系列データ X の i 番目の値を示している。 $\omega \in \mathbb{Z}$ (\mathbb{Z} は整数全体の集合を表す) はウィンドウサイズ、 $\alpha \in \mathbb{R}$ (\mathbb{R} は実数全体の集合を表す) は平滑化係数であり、 $\alpha = 2/(\omega + 1)$ と定義される。また $EMA(\omega)[X]_i$ はパラメータ ω で算出した時系列データ X の EMA の第 i 番目の値を示している。

MACD はそれぞれ異なるウィンドウとして $\omega_1 < \omega_2$ となるような 2 つのウィンドウを用いた EMA の差分であり、時系列データの速度として表現される。

$$MACD(\omega_1, \omega_2)[X]_i = EMA(\omega_1)[X]_i - EMA(\omega_2)[X]_i \quad (2)$$

次に、MACD からこれまでのウィンドウとは異なるウィンドウ ω_3 を用いて EMA により $Signal$ を算出する。

$$Signal(\omega_1, \omega_2, \omega_3)[X]_i = EMA(\omega_3)[MACD(\omega_1, \omega_2)[X]_i] \quad (3)$$

MACD ヒストグラムは MACD と $Signal$ の差分である。よって MACD ヒストグラムは次のように定義される。

$$Histogram(\omega_1, \omega_2, \omega_3)[X]_i = MACD(\omega_1, \omega_2)[X]_i - Signal(\omega_1, \omega_2, \omega_3)[X]_i \quad (4)$$

4.2 Multi-channel MHLF モデル

図 2 に Multi-channel MHLF モデルの概要を示す。Multi-channel MHLF モデルは LSTM-FCN モデルをベー

スとし、マルチチャンネルデータを入力する。Multi-Channel MHLF モデルでは入力時系列データから 2 種類の MACD ヒストグラムを算出し、時系列データと MACD ヒストグラムを結合しマルチチャンネル化する。入力したマルチチャンネルデータは LSTM-FCN の 2 通りのパスを通り、特徴量が抽出される。2 通りの特徴抽出から得られたそれぞれの特徴ベクトルを結合し、ソフトマックス関数が適用された全結合層である出力層へ入力される。

LSTM-FCN モデルと異なる点として、MACD ヒストグラムを用いたマルチチャンネルデータを入力する点と次元シャッフルを行わないことが挙げられる。次元シャッフルは時系列データ分類の学習に際して特殊な構造を用いた手法であるが、事前実験において、MACD ヒストグラムを用いたモデルでは精度の向上が見られなかった。そのため、提案手法では次元シャッフルを用いていない。

4.3 複数の MACD ヒストグラムを用いたマルチチャンネルデータ

MACD ヒストグラムは複数のパラメータ ($\omega_1, \omega_2, \omega_3$) を用いて算出される。このパラメータを調整することで時系列データの短期的な変動、もしくは長期的な変動の特徴を表現することができる。

図 3 に時系列データから算出した短期的な MACD ヒストグラム (Short-term MACD-histogram) と長期的な MACD ヒストグラム (Long-term MACD-histogram) の例を示す。短期的な MACD ヒストグラムは時系列データの小さな変動を顕著に抽出しているため、微変動が多く、長期的な MACD ヒストグラムは時系列データの長期的な変動を抽出するため、なだらかな変化が抽出されている。

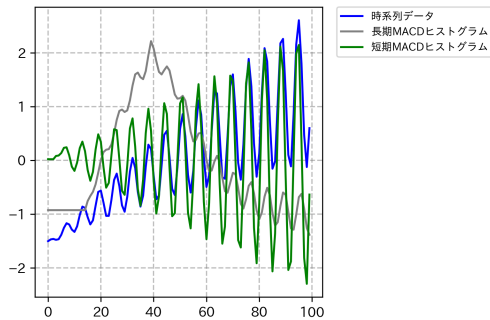


図 3 短期 MACD ヒストグラムと長期 MACD ヒストグラムの例
Fig. 3 A example of short and long MACD-histogram.

短期、長期での MACD ヒストグラムは互いに、時系列データの特徴を異なる形で表現することが可能である。

提案手法では時系列データと 2 種類の MACD ヒストグラムをマルチチャンネル化してモデルに入力する。Multi-Channel MHLF モデルでは、時系列データと 2 種類の MACD ヒストグラムをマルチチャンネル化し、系列長 N 、チャンネル数 3 の時系列データとなる。前処理としてそれぞれの系列データを標準化した後、モデルへと入力している。

5. 評価実験

提案手法を UCR アーカイブデータセットを用いて評価を行った。

5.1 UCR データセット

評価実験では時系列データの分類におけるベンチマークデータセットとして用いられている UCR アーカイブデータセット [7] を使用する。UCR アーカイブデータセットには 85 種類の時系列データセットが含まれている*1。本実験ではそれぞれのデータセットに対して訓練データを用いて学習し、それぞれのデータセットに含まれるテストデータセットに対する分類精度を基に比較実験を行う。

また、UCR アーカイブデータセットは時系列データセットごとにカテゴリが定義されている。カテゴリは 7 つに分けられており、“Device”, “ECG”, “Image”, “Motion”, “Sensor”, “Simulated”, “Spectro” がある。これらのカテゴリに対する精度を比較することでモデルの適正を発見することができる。評価実験では、それぞれのカテゴリと全体での分類精度の比較を行った。

5.2 ハイパパラメータ

Multi-channel MHLF のパラメータについて示す。短期 MACD ヒストグラムと長期 MACD ヒストグラムのパラメータはそれぞれ、 $(\omega_1, \omega_2, \omega_3) = (3, 5, 4)$, $(13, 26, 9)$ とし設定した。FCN, LSTM-FCN と提案手法を構成してい

*1 現在は 120 個のデータセットが登録されている。

る、3 層の畳み込み層のフィルタ数は 128, 256, 128 とし、フィルタサイズは 8, 5, 3 と設定した。また、LSTM-FCN の LSTM 層ではニューロン数は 32 とし、ドロップアウト率は 0.8 とした。これらのパラメータは LSTM-FCN を参照し、同様のパラメータを設定した。

5.3 評価実験 1

5.3.1 比較モデル

時系列データの分類モデルとして次のモデルを用いた。

HIVE-COTE

Lines ら [13] によって提案されているアンサンブル分類手法である。深層学習を用いないモデルの中で最も高精度なモデルとして報告されている。

Multi layer perceptron (MLP)

Wang ら [3] によって提案されている多層パーセプトロンを用いた分類モデルである。3 層の全結合層とドロップアウトにより構成されている。

Fully convolutional networks (FCN)

Wang ら [3] によって提案されている畳み込み層を用いた分類モデルである。3 層の畳み込み層と GAP 層により構成されている。各畳み込み層には Batch Normalization と ReLU 関数が適用されている。

Residual Networks (ResNet)

Wang ら [3] によって提案されているショートカット接続を持った分類モデルであり、文献 [18] がベースとなっている。9 層の畳み込み層と GAP 層により構成されている。各畳み込み層には Batch Normalization と ReLU 関数が適用されており、3 層ごとにショートカット接続されている。

LSTM-FCN

Karim ら [4] によって提案されている FCN モデルをベースとした分類モデルである。FCN モデルと同様に 3 層の畳み込み層と GAP 層により構成されており、入力層から GAP 層の出力まで、LSTM 層を持ったコネクションが用いられている。

ALSTM-FCN

Karim ら [4] によって提案されている LSTM-FCN モデルをベースとし、Attention 機構 [19] を取り入れた分類モデルである。

Short-MHLF

本研究における提案手法である MHLF に対して短期 MACD ヒストグラムのみを入力したモデルである。

Long-MHLF

本研究における提案手法である MHLF に対して長期 MACD ヒストグラムのみを入力したモデルである。

Multi-Channel MHLF

本研究における提案手法である。

5.3.2 実験結果

本実験ではテストデータに対する正解率を用いて比較し、各モデルの分類精度はそれぞれの論文を参照している。実験結果として、全データセットでの実験結果のまとめを表1に示す。本実験では分類モデルの評価値として3つの指標を用いた。

平均正解率は各データセットのテストセットに対する正解率を測定し、全85データセットに対して平均値を算出した値である。平均ランクは各データセットごとに分類モデルを順位付けし、順位を全85データセットに対して平均化した値である。平均ランクは数値が小さいほど他のモデルよりも分類精度の高いモデルとして評価でき、データセットごとの問題の難易度にかかわらず、分類モデルを比較することができる。最高精度数は正解率が1位であったデータセットの数をカウントした値である。また、評価値が同値の場合は順位タイとしてランキングした。

表1より平均正解率は提案手法が最も精度が高く、ALSTM-FCNモデルと比較すると多少の精度の改善があり、平均ランクでは最もランキングの高いモデルが提案手法であることが分かる。つまり、85個のデータセットの全体において従来手法と比べて高い分類精度があることを示している。また、最高精度数においても提案手法が最も多い。実験結果として、提案手法であるMulti-channel MHLFモデルは従来手法と比較して最も精度の高いモデルであることを示すことができた。

また、UCRアーカイブデータセットの一部のカテゴリに対する比較結果を表2、表3に示す。

表2に“Motion”カテゴリの結果を示す。このカテゴリではMACDヒストグラムとマルチチャネルをベースとした手法は最も効果的な手法であることが分かる。“Motion”カテゴリでは、Short-MHLFとLong-MHLFでは高い精度が見られなかったことから、マルチチャネルデータが精度に大きく関わっていることが分かる。

表3に“Spectro”カテゴリの結果を示す。この結果からALSTM-FCNモデルの分類精度が高いことが分かった。“Spectro”カテゴリ内ではMACDヒストグラムを用いた手法が適していないことが示されている。

一部のカテゴリについて、それぞれの分類モデルを比較した。結果として、MACDヒストグラムとマルチチャネルを用いた手法は時系列データの特徴によっては効果的な手法であることが分かった。しかし、カテゴリによっては精度の向上がみられない場合もあり、安定した精度の向上が今後の課題として挙げられる。

6. まとめ

本稿では新たな時系列データの分類モデルを提案した。提案手法では時系列データから算出されたMACDヒストグラムを用いてマルチチャネルな入力を実現し、分類精度

の向上を図った。具体的には時系列データから算出された2種類のMACDヒストグラムを用いた。これらのMACDヒストグラムは短期ウィンドウと長期ウィンドウを用いて、時系列データから異なる特徴を抽出したものである。短期MACDヒストグラムは時系列データの短期的な変動を顕著に表現し、長期MACDヒストグラムは時系列データの長期的な変化をなだらかに抽出することができる。これらの異なる特徴を利用し、時系列データの2種類のMACDヒストグラムをマルチチャネルとしてLSTM-FCNベースな深層モデルへと入力した。実験では、UCRデータセットを用いた比較実験を行い、全体を通して分類精度の向上が示された。しかし、カテゴリごとに提案手法の精度が高くない場合もあり、精度の向上がみられないケースがあった。今後の課題として、より汎用的なモデルを目指し、MACDヒストグラムのパラメータ調整について考察する。

謝辞 本研究の一部は、JSPS科研費JP18K11320、広島市立大学・特定研究費により行われた。

参考文献

- [1] Fawaz, H. I., Forestier, G., Weber, J., Idoumghar, L. and Muller, P.-A.: Deep learning for time series classification: a review, *Data Mining and Knowledge Discovery*, Vol. 33, No. 4, pp. 917–963 (2019).
- [2] Cui, Z., Chen, W. and Chen, Y.: Multi-scale convolutional neural networks for time series classification, *arXiv preprint arXiv:1603.06995* (2016).
- [3] Wang, Z., Yan, W. and Oates, T.: Time Series Classification from Scratch with Deep Neural Networks: A Strong Baseline, *CoRR*, Vol. abs/1611.06455 (online), available from (<http://arxiv.org/abs/1611.06455>) (2016).
- [4] Karim, F., Majumdar, S., Darabi, H. and Chen, S.: LSTM fully convolutional networks for time series classification, *IEEE Access*, Vol. 6, pp. 1662–1669 (2017).
- [5] Murphy, J. J.: *Technical analysis of the financial markets: A comprehensive guide to trading methods and applications*, Penguin (1999).
- [6] Keichi, T. and Takumi, I.: MACD-histogram-based recurrence plot: A new representation for time series classification, *Computational Intelligence and Applications (IWCIA), 2017 IEEE 10th International Workshop on*, IEEE, pp. 135–140 (2017).
- [7] Dau, H. A., Keogh, E., Kamgar, K., Yeh, C.-C. M., Zhu, Y., Gharghabi, S., Ratanamahatana, C. A., Yanping, Hu, B., Begum, N., Bagnall, A., Mueen, A. and Batista, G.: The UCR Time Series Classification Archive (2018).
- [8] Cover, T. M., Hart, P. et al.: Nearest neighbor pattern classification, *IEEE transactions on information theory*, Vol. 13, No. 1, pp. 21–27 (1967).
- [9] Ding, H., Trajcevski, G., Scheuermann, P., Wang, X. and Keogh, E.: Querying and mining of time series data: experimental comparison of representations and distance measures, *Proceedings of the VLDB Endowment*, Vol. 1, No. 2, pp. 1542–1552 (2008).
- [10] Tamura, K., Sakai, T. and Ichimura, T.: Time series classification using macd-histogram-based sax and its performance evaluation, *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, IEEE, pp. 002419–002424 (2016).

表 1 全データセットにおける比較結果
Table 1 The comparison result of all datasets

	HIVE-COTE	MLP	FCN	ResNet	LSTM-FCN	ALSTM-FCN	Short-MHLS	Long-MHLS	Multi-channel MHLF
平均正解率	0.8471	0.7516	0.8440	0.8385	0.8724	0.8786	0.8737	0.8741	0.8794
平均ランク	5.129	8.106	5.988	6.271	3.859	3.271	3.235	3.553	2.906
最高精度数	17	2	7	9	14	23	26	17	28

表 2 “Motion” カテゴリにおける比較結果
Table 2 The comparison result of “Motion” dataset

Dataset	HIVE-COTE	MLP	FCN	ResNet	LSTM-FCN	ALSTM-FCN	Short-MHLS	Long-MHLS	Multi-channel MHLF
Yoga	0.9177	0.8550	0.8450	0.8580	0.9177	0.9190	0.9153	0.9153	0.9363
CricketX	0.8231	0.5690	0.8150	0.8210	0.8077	0.8051	0.8103	0.8256	0.8333
CricketY	0.8487	0.5950	0.7920	0.8050	0.8179	0.8205	0.8103	0.8410	0.8462
CricketZ	0.8308	0.5920	0.8130	0.8130	0.8103	0.8308	0.8359	0.8513	0.8795
GunPoint	1.0000	0.9330	1.0000	0.9930	1.0000	1.0000	1.0000	1.0000	1.0000
Haptics	0.5195	0.4610	0.5510	0.5060	0.5747	0.5649	0.5649	0.5812	0.6039
InlineSkate	0.5000	0.3510	0.4110	0.3650	0.4655	0.4927	0.4527	0.5055	0.5327
ToeSegmentation1	0.9825	0.6010	0.9690	0.9650	0.9825	0.9868	0.9912	0.9781	0.9825
ToeSegmentation2	0.9538	0.7460	0.9150	0.8620	0.9308	0.9308	0.9538	0.9692	0.9769
UWaveGestureLibraryX	0.8398	0.7680	0.7540	0.7870	0.849	0.8481	0.8166	0.8146	0.8289
UWaveGestureLibraryY	0.7655	0.7030	0.7250	0.6680	0.7672	0.7658	0.7286	0.7401	0.7468
UWaveGestureLibraryZ	0.7831	0.7050	0.7290	0.7550	0.7973	0.7982	0.7719	0.7591	0.7795
UWaveGestureLibraryAll	0.9685	0.9540	0.8260	0.8680	0.9618	0.9626	0.8758	0.8989	0.8961
Worms	0.5584	0.3430	0.6690	0.6190	0.6685	0.6575	0.7293	0.6851	0.7238
WormsTwoClass	0.7792	0.5970	0.7290	0.7350	0.7956	0.8011	0.7901	0.7569	0.8011
平均正解率	0.8047	0.6515	0.7695	0.7613	0.8098	0.8123	0.8031	0.8081	0.8245
平均ランク	3.6667	8.4667	6.7333	7.2667	3.6667	3.2000	4.2667	3.7333	2.2000
最高精度数	3	0	1	0	3	3	3	1	8

表 3 “Spectro” カテゴリにおける比較結果
Table 3 The comparison result of “Spectro” dataset

Dataset	HIVE-COTE	MLP	FCN	ResNet	LSTM-FCN	ALSTM-FCN	Short-MHLS	Long-MHLS	Multi-channel MHLF
Beef	0.9333	0.8330	0.7500	0.7670	0.9000	0.9333	0.9333	0.9000	0.9333
Coffee	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
Ham	0.6667	0.7140	0.7620	0.7810	0.7714	0.8381	0.7905	0.8381	0.8190
Meat	0.9333	0.9330	0.9670	1.0000	0.9167	0.9833	0.9333	0.9833	0.9500
OliveOil	0.9000	0.4000	0.8330	0.8670	0.8667	0.9333	0.9333	0.9333	0.9333
Strawberry	0.9703	0.9670	0.9690	0.9580	0.9838	0.9838	0.9821	0.9804	0.9804
Wine	0.7778	0.7960	0.8890	0.7960	0.8704	0.9074	0.9259	0.8148	0.8704
平均正解率	0.8831	0.8061	0.8814	0.8813	0.9013	0.9399	0.9283	0.9214	0.9266
平均ランク	5.2857	6.8571	5.5714	5.2857	4.7143	1.4286	2.7143	2.8571	2.8571
最高精度数	2	1	1	2	2	4	3	3	2

[11] Lines, J., Davis, L. M., Hills, J. and Bagnall, A.: A shapelet transform for time series classification, *Proceedings of the 18th ACM SIGKDD international conference on Knowledge discovery and data mining*, ACM, pp. 289–297 (2012).

[12] Lin, J., Keogh, E., Wei, L. and Lonardi, S.: Experiencing SAX: A Novel Symbolic Representation of Time Series, *Data Min. Knowl. Discov.*, Vol. 15, No. 2, pp. 107–144 (online), DOI: 10.1007/s10618-007-0064-z (2007).

[13] Lines, J., Taylor, S. and Bagnall, A.: HIVE-COTE: The hierarchical vote collective of transformation-based ensembles for time series classification, *2016 IEEE 16th International Conference on Data Mining (ICDM)*, IEEE, pp. 1041–1046 (2016).

[14] Lin, M., Chen, Q. and Yan, S.: Network in network, *arXiv preprint arXiv:1312.4400* (2013).

[15] Kim, Y.: Convolutional Neural Networks for Sentence Classification, *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, Doha, Qatar, Association for Computational Linguistics, pp. 1746–1751 (online), DOI: 10.3115/v1/D14-1181 (2014).

[16] Collobert, R., Weston, J., Bottou, L., Karlen, M., Kavukcuoglu, K. and Kuksa, P.: Natural language processing (almost) from scratch, *Journal of machine learning research*, Vol. 12, No. Aug, pp. 2493–2537 (2011).

[17] Ioffe, S. and Szegedy, C.: Batch normalization: Accelerating deep network training by reducing internal covariate shift, *arXiv preprint arXiv:1502.03167* (2015).

[18] He, K., Zhang, X., Ren, S. and Sun, J.: Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778 (2016).

[19] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. and Polosukhin, I.: Attention is all you need, *Advances in neural information processing systems*, pp. 5998–6008 (2017).