

Multi-Channel MHLF を用いた時系列データの分類手法

橋田 修一^{1,a)} 田村 慶一^{1,b)}

受付日 2019年11月13日, 再受付日 2020年1月6日,
採録日 2020年1月22日

概要: 近年, 深層学習を用いた時系列データの分類問題に関する研究がさかに行われており, 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開発が求められている. 本論文では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として Multi-Channel MACD-Histogram-based LSTM-FCN (Multi-Channel MHLF) を提案する. 先行研究において, 時系列データの分類問題に対して CNN を用いた分類手法が提案されており, その有効性が示されている. 本研究では時系列データと時系列データから抽出した MACD ヒストグラムとをマルチチャンネルデータとして入力する手法を検討する. Multi-Channel MHLF は MACD ヒストグラムとして短期と長期の 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 モデルにマルチチャンネルデータを入力する手法となっている. 評価実験では時系列データの分類問題のためのベンチマーク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. 実験の結果, 提案手法は従来手法よりも分類精度が高いことが確認できた.

キーワード: 時系列データ分類, LSTM-FCN, MACD ヒストグラム, LSTM, 畳み込みニューラルネットワーク

Time Series Classification Using Multi-Channel MHLF

SHUICHI HASHIDA^{1,a)} KEIICHI TAMURA^{1,b)}

Received: November 13, 2019, Revised: January 6, 2020,
Accepted: January 22, 2020

Abstract: Recently, time series classification methods with the deep learning have been developing in many researches. In many application areas, deep-model with the high performance in the classification are required. This paper proposes a new time series classification method, which is called Multi-Channel MACD-Histogram-based LSTM-FCN (Multi-Channel MHLF), with the convolutional neural networks (CNN) and the MACD-histogram. Time series classification methods based on CNN were proposed in many researches and they are reported as the high accurately models. In this work, the proposed method includes multi-channel input that consists of time series data and its MACD-histograms. The MACD-histogram is extracted with the two kinds of windows as the short-term and long-term window. Additionally, the proposed method is based on the LSTM-FCN model which is reported the most accurately model. In experiments, the UCR archive dataset which is a defact standard benchmark dataset for the time series classification is used for comparing the proposed method and conventional methods. The experimental results show the proposed model is higher accurately than the conventional methods.

Keywords: time series classification, LSTM-FCN, MACD-histogram, LSTM, convolutional neural networks

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 1 つとして

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, Hiroshima 731-3194, Japan

a) shu.hashida@gmail.com

b) ktamura@hiroshima-cu.ac.jp

時系列データの分類問題があげられる。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、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ことができるモデルの開発が求められている。ただし、本研究では時系列データの中でも、単一の要素から構成される実数値の系列のみを扱うものとする。

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] を時系列データの分類問題に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加速度を表現している。MACD ヒストグラムは時系列データの加速度を表現している。ここで、加速度とは、時系列データの単位時間における値の変化量の加速度を示している。時系列上の数値が同じでも MACD ヒストグラムの値が異なる場合は、直前における変動の違いがあったと見なすことができる。Tamura ら [6] は、時系列データから MACD ヒストグラムを抽出し、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分類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検討する。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手法として Multi-Channel MACD-Histogram-based LSTM-FCN (Multi-Channel MHLF) を提案する。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分類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。2 章で時系列データの分類手法について関連研究を示し、3 章において FCN モデルと LSTM-FCN モデルの説明を行う。4 章では提案手法である Multi-Channel MHLF について説明する。5 章では評価実験とその結果について示す。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まかな種別として、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] があげられる。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、それぞれの手法を簡単に説明する。

距離ベースの手法としてユークリッド距離を用いた最近傍法 [8] と Dynamic Time Warping (DTW) を用いた手法 [9] があげられる。距離ベースの手法は訓練データと未知のデータとの距離を算出し、距離を使ってクラスラベルを決定する。シンプルな手法で安定しているが系列長の長い時系列データを用いると距離算出にかかる処理時間が大きいという課題がある。また、時系列データを SAX 表現 [12] と呼ばれる記号列へと圧縮変換し、文字列間の距離を算出することで時系列データの分類を行う手法 [10] も提案されている。

特徴抽出ベースの手法として Shapelet [11] があげられる。Shapelet は時系列データから分類ラベルごとに特徴的な波形を切り出す手法である。また、切り出された部分時系列と未知の時系列データとの距離を算出し、その距離配列を特徴ベクトルとして定義する。分類アルゴリズムとして、決定木や Support Vector Machine (SVM) が用いられている。Shapelet の利点として、説明性の高さや特徴的な波形の位相に依存せず、波形パターンとの類似度を算出できる点があげられる。近年の研究では、Shapelet の抽出を高速化する手法として、Shapelet の最適化手法 [13] や進化計算による抽出手法 [14] が提案されている。分類精度については従来手法と同等もしくはそれ以上の性能が報告されている。

代表的なアンサンブル手法として Hierarchical Vote Collective of Transformation-based Ensembles (HIVE-COTE) [15] 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モデルを用い、アンサンブルにより分類を行う。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。

Wang ら [3] は深層学習を用いた時系列データの深層モデルとして Multi-layer Perceptron (MLP), 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 [16] を用いた単純なモデルで十分に高い分類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。LSTM-FCN モデルは入力層から 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、分類精度の向上を図っている。UCR アーカイブデータセットを用いた実験

では最も分類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ための新しい手法を提案する。

また、Karim ら [4] は LSTM-FCN モデルに Attention 機構を取り入れた Attention LSTM-FCN (ALSTM-FCN) モデルを提案している。しかしながら、提案手法ではマルチチャンネルデータを入力し、かつ、次元シャッフルを用いないため ALSTM-FCN モデル内の Attention 機構を取り入れることができない。そのため、提案手法では Attention 機構を取り入れていない。ここで、次元シャッフルとは時系列データを扱う際、LSTM へ入力するデータの構造を変える手法である。具体的には 3.3 節にて説明する。

また、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。本研究では時系列データから MACD ヒストグラムを抽出し、入力データを時系列データと MACD ヒストグラムを多次元化したマルチチャンネルデータとして表現する。

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として単一の数値要素の系列データのみを扱う。時系列データを $X = (x_1, x_2, \dots, x_n)$ と表現する。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 X に対し、1 次元配列として表現されているフィルタ c を適用することである。時系列データに対する畳み込みは次のように定義される。

$$X' = X \otimes c \quad (1)$$

ここで $X \in \mathbb{R}^n$ は系列長 n となる 1 次元配列であり、同様に、1 次元配列 $c \in \mathbb{R}^s$ はフィルタサイズ s となる畳み込み層内のフィルタの 1 つである。また、 X' は畳み込み後の特徴マップである。畳み込み後の各要素 x'_t に対する算出を次に示す。

$$x'_t = \sum_{i=0}^{s-1} x_{t+i} c_i \quad (2)$$

CNN における畳み込みは入力データに対して複数のフィルタを適用し、局所的な特徴を示す特徴マップを抽出する。畳み込み層はさまざまな手法に取り組みられており、さまざまなデータに対して精度の高い手法として研究がさかに行われている [17], [18]。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

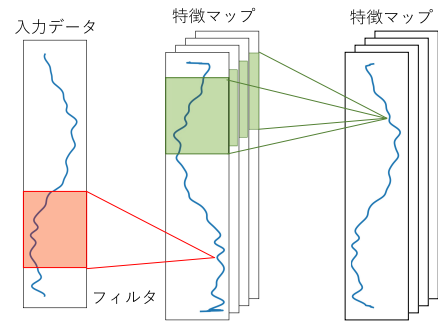


図 1 時系列データに対する畳み込み層の動き
Fig. 1 Convolutional layer for time series data.

特徴マップを抽出する (図 1)。

3.2 FCN モデル

FCN モデルは 3 層の畳み込み層と GAP 層、出力層から構成される。畳み込み層では時系列データに対して 1 次元のフィルタを適用し、時系列データから特徴マップの抽出を行う。GAP 層は 3 層目の畳み込み層の出力に対して、各特徴マップから平均値を算出し、出力層へ入力する。出力層は分類のためのソフトマックス層となっている。効率的な学習のため、それぞれの畳み込み層には Batch Normalization [19] と活性化関数として Rectified Linear Unit (ReLU) 関数を用いられている。一般的な CNN と同様に学習中に各フィルタのパラメータが自動的に更新されて、データセットの特徴をとらえるための最適なフィルタが求められる。

3.3 LSTM-FCN モデル

図 2 に LSTM-FCN モデルを示す。LSTM-FCN モデルは FCN モデルをベースとしている。LSTM-FCN モデルは LSTM 層を持った接続を持ち、LSTM 層の入力データ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。

次元シャッフルとは系列長 N 、チャンネル数 M の時系列データに対して時間軸とチャンネル軸の転置を行い、系列長 M 、チャンネル数 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、一方で系列長の長い時系列データの長期依存の学習が可能になると考えられている [4]。また、本研究で対象としている単変量の時系列データに対して次元シャッフルを行う場合、系列長 N 、チャンネル数 1 の時系列データとなるため、次元シャッフルが適用されると系列長 1、チャンネル数 N のデータ構造へと変換される。

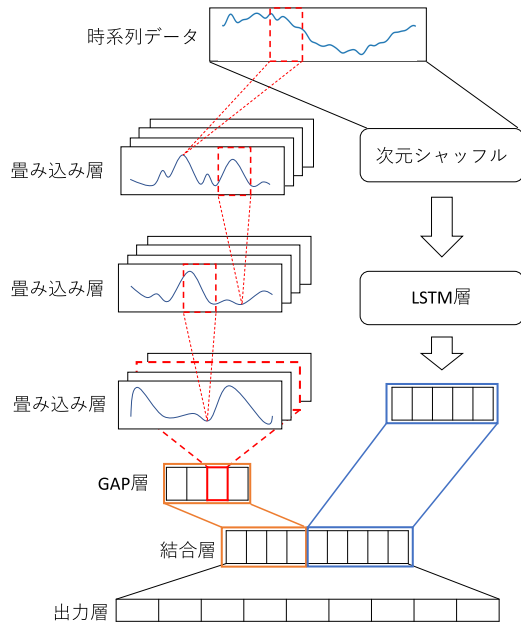


図 2 LSTM-FCN の概観
Fig. 2 LSTM-FCN model.

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) 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. 時系列データの EMA の定義は次のとおりである.

$$EMA(\omega)[X]_i = \alpha \times x_i + (1 - \alpha) \times EMA(\omega)[X]_{i-1} \quad (3)$$

ただし, $i \leq \omega$ のときの EMA を次に示す.

$$EMA(\omega)[X]_i = \frac{1}{i} \sum_{k=1}^i x_k \quad (4)$$

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. $\omega \in \mathbb{N}$ (\mathbb{N} は自然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 $\omega_1 < \omega_2$ となる異なる 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.

$$\begin{aligned} MACD(\omega_1, \omega_2)[X]_i \\ = EMA(\omega_1)[X]_i - EMA(\omega_2)[X]_i \end{aligned} \quad (5)$$

次に, MACD から ω_1, ω_2 とは異なるウィンドウ ω_3 により EMA を用いて $Signal$ を算出する.

$$\begin{aligned} Signal(\omega_1, \omega_2, \omega_3)[X]_i \\ = EMA(\omega_3)[MACD(\omega_1, \omega_2)[X]]_i \end{aligned} \quad (6)$$

MACD ヒストグラムは MACD と $Signal$ の差分であり, 次のように定義される.

$$\begin{aligned} Histogram(\omega_1, \omega_2, \omega_3)[X]_i \\ = MACD(\omega_1, \omega_2)[X]_i - Signal(\omega_1, \omega_2, \omega_3)[X]_i \end{aligned} \quad (7)$$

4.2 Multi-channel MHLF

図 3 に Multi-channel MHLF の概要を示す. Multi-channel MHLF は LSTM-FCN モデルをベースとし, マルチチャンネルデータをモデルへの入力データとする. 最初に時系列データから 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, 入力データをマルチチャンネル化する. 生成したマルチチャンネルデータは LSTM-FCN モデルの 2 通りのパスを通り, 特徴量が抽出される. 1 つは FCN モデルをベースとしたパスで 3 層の畳み込み層を用いた処理から特徴マップを抽出し, GAP 層によりそれぞれのチャンネルを圧縮する. また, LSTM をベースとしたパスでは, LSTM 層を含んだ接続から畳み込み層とは異なる特徴量を抽出する. そして, 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.

ここで提案手法と LSTM-FCN モデルとが異なる点として, マルチチャンネルデータを入力することと次元シャッフルを行わないことがあげられる. 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, 我々の事前実験において, MACD ヒストグラムを用いたモデルでは分類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 3 つのパラメータ ($\omega_1, \omega_2, \omega_3$) を用いて算出される. 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などさまざまな MACD ヒストグラムを抽出することができる. 短期的な変動を抽出する場合は MACD ヒストグラムのウィンドウパラメータを小さく設定し, 長期的な変動を用いる際はウィンドウパラメータが大きくなるように設定する.

図 4 に時系列データから算出した短期的な MACD ヒ

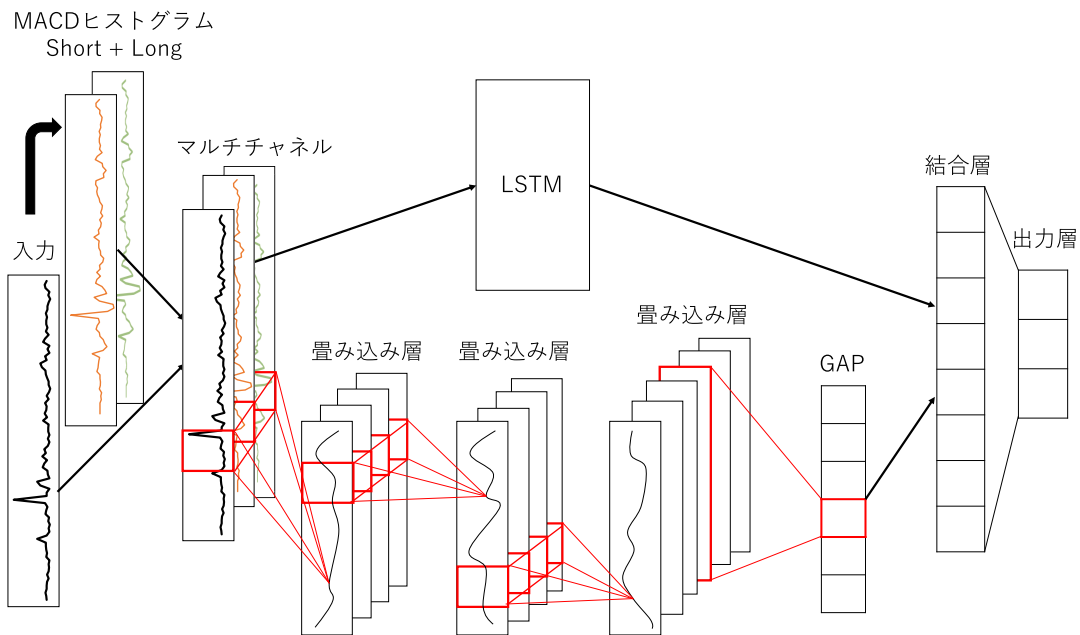


図 3 Multi-Channel MACD-histogram-based LSTM-FCN (Multi-Channel MHLF)
 Fig. 3 Multi-Channel MACD-histogram-based LSTM-FCN (Multi-Channel MHLF).

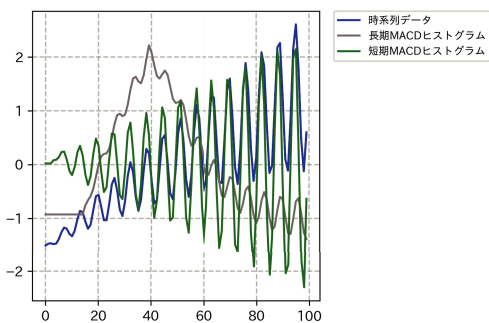


図 4 短期 MACD ヒストグラムと長期 MACD ヒストグラムの例
 Fig. 4 A example of short and long MACD-histogram.

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。短期と長期での 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。

本研究では、時系列データ、長期と短期の2種類のMACDヒストグラムをマルチチャンネル化してマルチチャンネルデータとしてモデルに入力する。ここでマルチチャンネルデータとは系列長 N 、チャンネル数1となるような k 個の時系列データを重ね合わせ、系列長 N 、チャンネル数 k となる時系列データのことである。Multi-Channel MHLF 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のマルチチャンネルデータを生成する。また、前処理としてそれぞれの系列データを




図 5 マルチチャンネルのための前処理
 Fig. 5 Prerprocessing for multi-channel time series data.

標準化した後、モデルへと入力している (図 5)。

時系列データと時系列データから取り出した長期と短期2種類のMACDヒストグラムをマルチチャンネルデータとして入力データを構成する効果は次のとおりである。MACDヒストグラムは時系列データの局所的な変化の度合いを表している。LSTM-FCNモデルではFCN層を持ち、フィルタを使って時系列データの分類を決定付ける特徴的な部分系列データが抽出され、また、LSTM層を持つので、特徴的な変化を短期・長期メモリで記憶できる。ここで、MACDヒストグラムを同時に入力することで特徴に対する重み付けが行われ、特徴的な部分系列データと変化の記憶がより強調される効果がある。

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。本章では提案手法と従来手法との比較結果を報告する。

5.1 UCR データセット

評価実験では時系列データの分類問題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。85 種類の時系列データセットが含まれており*1, それぞれのデータセットにおいて系列長, 訓練データ, テストデータの数, 時系列データの特徴が異なっている。それぞれの時系列データの情報を付録の表 A.1 に示す。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正解率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分けされている。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。カテゴリごとに分類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。カテゴリは “Device”, “ECG”, “Image”, “Motion”, “Sensor”, “Simulated”, “Spectro” の 7 つのカテゴリに分かれている。“Device” データセットは主に電子機器の負荷計測の際に観測されたデータが含まれている。“ECG” は心電図から計測されたデータを時系列データとして用いられている。“Image” データセットは画像データ内の物質の輪郭線などを系列データとして扱っている。“Motion” データセットは人間の動きを観測したデータである。“Sensor” はそれぞれの対象としている現象をセンサ機器から観測したデータが含まれている。“Simulated” はシミュレーションを通して算出された人工的な系列データである。“Spectro” は全反射測定法などにより取得された食品などに対するスペクトログラムの各周波数ごとの値を系列として扱っているデータが含まれている。

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, $(\omega_1, \omega_2, \omega_3) = (3, 5, 4), (13, 26, 9)$ として設定した。FCN モデル, LSTM-FCN モデルと提案手法を構成している, 3 層の畳み込み層のフィルタサイズ, フィルタ数は表 1 のとおりである。また, LSTM-FCN モデルの 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 モデルを参照し, 同様のパラメータを設定した。損失関数を Categorical Cross Entropy, 最適化アルゴリズムを Adam と設定し, エポック数を 2,000 とした。

5.3 評価実験 1

評価実験 1 では代表的なモデルとの比較を行った。

表 1 MHLF 内の畳み込み層のハイパパラメータ

Table 1 MHLF's parameters.

	1 層目	2 層目	3 層目
フィルタ数	128	256	128
フィルタサイズ	8	5	3

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 [15] によって提案されているアンサンブル手法である。深層学習を用いないモデルのなか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モデルであり, 文献 [20] 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。

LSTM-FCN (次元シャッフル (DS) なし)

Karim ら [4] によって提案されている LSTM-FCN モデルは次元シャッフルを用いてデータ構造を変える手法を用いている。しかし, 提案手法では次元シャッフルを用いないため, 新たに次元シャッフルを用いない LSTM-FCN モデルを構成し, 実験を行った。

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 [21] を取り入れたモデルである。

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。

*1 現在は 120 個のデータセットが登録されている。

表 2 全データセットにおける比較結果
Table 2 The comparison result of all datasets.

	HIVE-COTE	MLP	FCN	ResNet	LSTM-FCN	LSTM-FCN (DS なし)	ALSTM-FCN	Short-MHLS	Long-MHLS	Multi-channel MHLF
平均正解率	0.8471	0.7516	0.8440	0.8385	0.8724	0.8663	0.8786	0.8737	0.8741	0.8794
平均ランク	5.670	9.023	6.752	7	4.282	4.694	3.576	3.564	3.917	3.211
最高精度数	17	2	6	9	10	18	20	24	17	27

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

Dataset	HIVE-COTE	MLP	FCN	ResNet	LSTM-FCN	LSTM-FCN (DS なし)	ALSTM-FCN	Short-MHLS	Long-MHLS	Multi-channel MHLF
Computers	0.76	0.54	0.848	0.824	0.86	0.88	0.864	0.824	0.832	0.804
ElectricDevices	0.7703	0.58	0.723	0.728	0.7681	0.7693	0.7672	0.7686	0.7619	0.7797
LargeKitchen Appliances	0.864	0.48	0.896	0.893	0.92	0.92	0.9067	0.9173	0.8987	0.8987
Refrigeration Devices	0.5573	0.371	0.533	0.528	0.5813	0.5893	0.584	0.5947	0.5973	0.6
ScreenType	0.5893	0.408	0.667	0.707	0.6693	0.68	0.6907	0.6533	0.64	0.632
SmallKitchen Appliances	0.8533	0.389	0.803	0.797	0.808	0.832	0.7947	0.8133	0.8373	0.8133
平均正解率	0.7324	0.4613	0.745	0.7462	0.7678	0.7784	0.7679	0.7619	0.7612	0.7546
平均ランク	6.1667	10	6.6667	6.6667	4.3333	2.5	4.6667	4.3333	4.6667	4.5
最高精度数	1	0	0	1	0	2	0	0	0	2

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値はそれぞれの論文を参照している。また、従来手法は 1 試行における学習の繰り返し回数 (エポック数) を 2,000 回に設定し、2,000 回の中で検証データの分類精度が高いモデルを採用している。本研究においても、従来手法と同様に考え、2,000 回の中で検証データの分類精度が高いモデルを採用した。従来研究においては、複数試行の言及されていないが、この点に関しては 5.5 節で考察する。

表 2 に全データセットでの実験結果をまとめた内容を示す。分類手法の評価値として平均正解率、平均ランキング、最高精度数の 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、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 2 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手法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 は従来手法と比較して最も良い手法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内の各時系列データセットに対する正解率をカテゴリごとに表 3、表 4、表 5、表 6、表 7、表 8、表 9 に示す。

表 3 に “Device” カテゴリの結果を示す。平均正解率は次元シャッフルを持たない LSTM-FCN モデルが高く、“Device” カテゴリ内において分類精度が良い手法であった。しかし、最高精度数は次元シャッフルを持たない LSTM-FCN モデルとともに提案手法も高く、平均ランクでは次元シャッフルを持たない LSTM-FCN モデルが上位であることが示されており、Multi-channel MHLF は “Device” カテゴリにおいて一部のデータセットに対して効果的な手法である

表 4 “ECG” カテゴリにおける比較結果
Table 4 The comparison result of “ECG” dataset.

Dataset	HIVE-COTE	MLP	FCN	ResNet	LSTM-FCN	LSTM-FCN (DS なし)	ALSTM-FCN	Short-MHLS	Long-MHLS	Multi-channel MHLF
ECG200	0.85	0.92	0.9	0.87	0.9	0.91	0.91	0.94	0.92	0.93
ECG5000	0.9462	0.935	0.941	0.931	0.9473	0.9453	0.9484	0.9431	0.9489	0.946
ECGFiveDays	<u>1</u>	0.97	0.985	0.955	0.9919	0.9907	0.9954	0.9977	<u>1</u>	<u>1</u>
NonInvasiveFatal ECGThorax1	0.9303	0.942	0.961	0.948	0.9654	0.9583	0.9751	0.9654	0.9562	0.9644
NonInvasiveFatal ECGThorax2	0.9445	0.943	0.955	0.951	0.9623	0.9491	0.9664	0.9613	0.9588	0.9644
TwoLeadECG	0.9965	0.853	<u>1</u>	<u>1</u>	0.9991	<u>1</u>	0.9991	<u>1</u>	<u>1</u>	<u>1</u>
平均正解率	0.9446	0.9272	0.957	0.9425	0.961	0.9589	0.9657	0.9679	0.964	0.9675
平均ランク	7.1667	8.3333	5.8333	7.5	4.6667	5.6667	3.5	3.1667	3	2.5
最高精度数	1	0	1	1	0	1	2	2	3	2

表 5 “Image” カテゴリにおける比較結果
Table 5 The comparison result of “Image” dataset.

Dataset	HIVE-COTE	MLP	FCN	ResNet	LSTM-FCN	LSTM-FCN (DS なし)	ALSTM-FCN	Short-MHLS	Long-MHLS	Multi-channel MHLF
50words	0.8088	0.712	0.679	0.727	0.8044	0.756	0.8242	0.7802	0.8044	0.8088
Adiac	0.8107	0.752	0.857	0.826	0.8593	0.8363	0.867	0.8747	0.8721	0.8696
ArrowHead	0.8629	0.823	0.88	0.817	0.9086	0.8629	0.9257	0.92	0.92	0.9314
BeetleFly	0.95	0.85	0.95	0.8	0.95	<u>1</u>	<u>1</u>	0.95	<u>1</u>	<u>1</u>
BirdChicken	0.85	0.8	0.95	0.9	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	0.9	<u>1</u>
DiatomSizeReduction	0.9412	0.964	0.93	0.931	0.9673	0.9771	0.9739	0.9837	0.9935	0.9837
DistalPhalanxOutline AgeGroup	0.7626	0.827	0.835	0.798	0.86	0.865	0.8625	0.87	0.865	0.8675
DistalPhalanxOutline Correct	0.7717	0.81	0.812	0.82	0.825	0.84	0.8417	0.8383	0.8417	0.845
DistalPhalanxTW	0.6835	0.747	0.79	0.74	0.8175	0.8225	0.8175	0.81	0.8075	0.81
FaceAll	0.803	0.885	0.929	0.834	0.9402	0.9645	0.9657	0.9834	0.9556	0.971
FaceFour	0.9545	0.83	0.932	0.932	0.9432	0.9432	0.9432	0.9432	0.9545	0.9659
FacesUCR	0.9629	0.815	0.948	0.958	0.9293	0.942	0.9434	0.962	0.9605	0.9629
Fish	0.9886	0.874	0.971	0.989	0.9829	0.9714	0.9771	0.9886	0.9886	0.9943
HandOutlines	0.9324	0.807	0.776	0.861	0.893	0.857	0.903	0.841	0.897	0.888
Herring	0.6875	0.687	0.703	0.594	0.7656	0.7344	0.75	0.7031	0.8125	0.6875
MedicalImages	0.7776	0.729	0.792	0.772	0.8013	0.8092	0.7961	0.7961	0.7776	0.7895
MiddlePhalanxOutline AgeGroup	0.5974	0.735	0.768	0.76	0.8125	0.8075	0.8175	0.8125	0.8075	0.8075
MiddlePhalanxOutline Correct	0.8316	0.76	0.795	0.793	0.8217	0.8467	0.84	0.8317	0.8683	0.8583
MiddlePhalanxTW	0.5714	0.609	0.612	0.607	0.6165	0.6366	0.6466	0.6416	0.6466	0.6466
OSULeaf	0.9793	0.57	0.988	0.979	0.9959	0.9959	0.9959	<u>1</u>	0.9669	<u>1</u>
PhalangesOutlines Correct	0.8065	0.83	0.826	0.825	0.8368	0.838	0.838	0.852	0.8462	0.8485
ProximalPhalanx OutlineAgeGroup	0.8585	0.824	0.849	0.849	0.8927	0.8976	0.8878	0.8878	0.878	0.8829
ProximalPhalanx OutlineCorrect	0.8797	0.887	0.9	0.918	0.945	0.9313	0.9313	0.9313	0.9313	0.9278
ProximalPhalanxTW	0.8146	0.797	0.81	0.807	0.835	0.8375	0.8375	0.83	0.825	0.825
ShapesAll	0.905	0.775	0.898	0.912	0.9017	0.9017	0.9183	0.9317	0.9383	0.935
SwedishLeaf	0.9536	0.893	0.966	0.958	0.9792	0.976	0.9856	0.9904	0.968	0.9824
Symbols	0.9739	0.853	0.962	0.872	0.9839	0.9839	0.9869	0.9638	0.9819	0.9829
WordsSynonyms	0.7382	0.594	0.58	0.632	0.6708	0.6473	0.6677	0.6881	0.7116	0.7398
Yoga	0.9177	0.855	0.845	0.858	0.9177	0.8883	0.919	0.9153	0.9153	0.9363
平均正解率	0.8405	0.7894	0.846	0.83	0.8778	0.8748	0.8849	0.88	0.884	0.8879
平均ランク	6.8621	9.1724	7.5862	7.9655	4.3103	4.5862	2.9655	3.3448	3.7586	2.7241
最高精度数	2	0	0	0	2	5	7	7	6	10

表 6 “Motion” カテゴリにおける比較結果
Table 6 The comparison result of “Motion” dataset.

Dataset	HIVE-COTE	MLP	FCN	ResNet	LSTM-FCN	LSTM-FCN (DS なし)	ALSTM-FCN	Short-MHLS	Long-MHLS	Multi-channel MHLF
CricketX	0.8231	0.569	0.815	0.821	0.8077	0.7949	0.8051	0.8103	0.8256	0.8333
CricketY	0.8487	0.595	0.792	0.805	0.8179	0.8103	0.8205	0.8103	0.841	0.8462
CricketZ	0.8308	0.592	0.813	0.813	0.8103	0.8051	0.8308	0.8359	0.8513	0.8795
GunPoint	<u>1</u>	0.933	<u>1</u>	0.993	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>
Haptics	0.5195	0.461	0.551	0.506	0.5747	0.526	0.5649	0.5649	0.5812	0.6039
InlineSkate	0.5	0.351	0.411	0.365	0.4655	0.4636	0.4927	0.4527	0.5055	0.5327
ToeSegmentation1	0.9825	0.601	0.969	0.965	0.9825	0.9825	0.9868	0.9912	0.9781	0.9825
ToeSegmentation2	0.9538	0.746	0.915	0.862	0.9308	0.9308	0.9308	0.9538	0.9692	0.9769
UWaveGestureLibraryX	0.8398	0.768	0.754	0.787	0.849	0.8118	0.8481	0.8166	0.8146	0.8289
UWaveGestureLibraryY	0.7655	0.703	0.725	0.668	0.7672	0.727	0.7658	0.7286	0.7401	0.7468
UWaveGestureLibraryZ	0.7831	0.705	0.729	0.755	0.7973	0.7563	0.7982	0.7719	0.7591	0.7795
UWaveGestureLibraryAll	0.9685	0.954	0.826	0.868	0.9618	0.8657	0.9626	0.8758	0.8989	0.8961
Worms	0.5584	0.343	0.669	0.619	0.6685	0.6796	0.6575	0.7293	0.6851	0.7238
WormsTwoClass	0.7792	0.597	0.729	0.735	0.7956	0.8122	0.8011	0.7901	0.7569	0.8011
平均正解率	0.7966	0.637	0.7641	0.7544	0.8021	0.7833	0.8046	0.7951	0.8005	0.8165
平均ランク	3.8571	9.4286	7.2857	8.0714	3.8571	6.2143	3.4286	4.3571	3.7857	2.3571
最高精度数	3	0	1	0	3	2	2	3	1	6

表 7 “Sensor” カテゴリにおける比較結果
Table 7 The comparison result of “Sensor” dataset.

Dataset	HIVE-COTE	MLP	FCN	ResNet	LSTM-FCN	LSTM-FCN (DS なし)	ALSTM-FCN	Short-MHLS	Long-MHLS	Multi-channel MHLF
Car	0.8667	0.833	0.917	0.933	0.95	0.9333	0.9667	0.9167	0.9	0.9167
ChlorineConcentration	0.712	0.872	0.843	0.828	0.8099	0.8164	0.807	0.7982	0.8104	0.8115
CinCECGtorso	0.9964	0.842	0.813	0.771	0.8862	0.8942	0.9058	0.9442	0.8812	0.8964
Earthquakes	0.7482	0.792	0.801	0.786	0.8354	0.8323	0.8292	0.8261	0.8323	0.8292
FordA	0.9644	0.769	0.906	0.928	0.9272	0.9206	0.9267	0.9322	0.9334	0.9347
FordB	0.8235	0.629	0.883	0.9	0.918	0.9164	0.9158	0.9241	0.9208	0.9224
InsectWingbeatSound	0.6551	0.631	0.402	0.531	0.6616	0.5237	0.6823	0.5096	0.6061	0.6005
ItalyPowerDemand	0.9631	0.966	0.97	0.96	0.9631	0.964	0.9602	0.9708	0.9689	0.9679
Lighting2	0.8197	0.721	0.803	0.754	0.8033	0.7705	0.7869	0.8361	0.8525	0.8852
Lighting7	0.7397	0.644	0.863	0.836	0.8356	0.863	0.8219	0.8767	0.8767	0.863
MoteStrain	0.9329	0.869	0.95	0.895	0.9393	0.9521	0.9361	0.9137	0.8882	0.9225
Phoneme	0.3824	0.098	0.345	0.324	0.3776	0.3539	0.3671	0.3761	0.3528	0.3803
Plane	<u>1</u>	0.981	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>
SonyAIBO	0.7654	0.727	0.968	0.985	0.9817	0.9917	0.97	0.9884	0.9867	0.9817
Robot Surface	0.9276	0.839	0.962	0.962	0.978	0.9811	0.9748	0.9811	0.9098	0.9213
SonyAIBO	0.9276	0.839	0.962	0.962	0.978	0.9811	0.9748	0.9811	0.9098	0.9213
Robot SurfaceII	0.9276	0.839	0.962	0.962	0.978	0.9811	0.9748	0.9811	0.9098	0.9213
StarlightCurves	0.9815	0.957	0.967	0.975	0.9756	0.9749	0.9767	0.9692	0.9744	0.9671
Trace	<u>1</u>	0.82	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>
Wafer	0.9994	0.996	0.997	0.997	0.9992	0.9995	0.9981	0.9998	0.9987	0.9992
平均正解率	0.8488	0.777	0.855	0.8536	0.8801	0.8715	0.8792	0.8757	0.8718	0.8778
平均ランク	5.1111	8.6667	5.7778	6.1111	3.8889	3.9444	4.7222	3.7222	4.5556	4.0556
最高精度数	6	1	2	2	3	5	4	6	3	3

ことが分かる。

表 4 に “ECG” カテゴリの結果を示す。表 4 より MACD ヒストグラムをベースとした手法が高い精度であることが分かる。これは “ECG” データセットは心電図であり、加速度による違いで特徴をとらえやすく、MACD ヒストグラムを用いた方がいいためである。また、Short-MHLF と Long-MHLF で精度の差があることから、MACD ヒストグ

ラムの算出においてパラメータの設定は分類精度に大きく関係することが分かった。

表 5 と表 6 に “Image” カテゴリと “Motion” カテゴリの結果を示す。両カテゴリとも提案手法は最も良い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

表 8 “Simulated” カテゴリにおける比較結果
Table 8 The comparison result of “Simulated” dataset.

Dataset	HIVE-COTE	MLP	FCN	ResNet	LSTM-FCN	LSTM-FCN (DS なし)	ALSTM-FCN	Short-MHLS	Long-MHLS	Multi-channel MHLF
CBF	0.9989	0.86	<u>1</u>	0.994	0.9978	0.9967	0.9967	0.99	0.9967	0.99
MALLAT	0.962	0.936	0.98	0.979	0.9808	0.9765	0.9838	0.9817	0.974	0.9706
ShapeletSim	<u>1</u>	0.483	0.867	<u>1</u>	0.9722	<u>1</u>	0.9833	<u>1</u>	0.9944	<u>1</u>
SyntheticControl	0.9967	0.95	0.99	<u>1</u>	0.9933	0.9933	0.99	<u>1</u>	0.9967	0.99
TwoPatterns	<u>1</u>	0.886	0.897	<u>1</u>	0.9968	<u>1</u>	0.9968	<u>1</u>	<u>1</u>	<u>1</u>
平均正解率	0.9915	0.823	0.9468	0.9946	0.9882	0.9933	0.9901	0.9943	0.9924	0.9901
平均ランク	3.4	10	6	3	5.4	3.8	5.2	2.6	4.2	5
最高精度数	2	0	1	3	0	2	1	3	1	2

表 9 “Spectro” カテゴリにおける比較結果
Table 9 The comparison result of “Spectro” dataset.

Dataset	HIVE-COTE	MLP	FCN	ResNet	LSTM-FCN	LSTM-FCN (DS なし)	ALSTM-FCN	Short-MHLS	Long-MHLS	Multi-channel MHLF
Beef	0.9333	0.833	0.75	0.767	0.9	0.8333	0.9333	0.9333	0.9	0.9333
Coffee	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>	<u>1</u>
Ham	0.6667	0.714	0.762	0.781	0.7714	0.8	0.8381	0.7905	0.8381	0.819
Meat	0.9333	0.933	0.967	<u>1</u>	0.9167	0.9	0.9833	0.9333	0.9833	0.95
OliveOil	0.9	0.4	0.833	0.867	0.8667	0.8333	0.9333	0.9333	0.9333	0.9333
Strawberry	0.9703	0.967	0.969	0.958	0.9838	0.9821	0.9838	0.9821	0.9804	0.9804
Wine	0.7778	0.796	0.889	0.796	0.8704	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	0.8884	0.9399	0.9283	0.9214	0.9266
平均ランク	5.7143	7.5714	6.1429	5.8571	4.8571	5.7143	1.4286	2.8571	3.1429	3
最高精度数	2	1	1	2	2	1	4	3	3	2

分かる。また、分類精度が向上したデータセットでは比較的系列長が長く、MACD ヒストグラムを用いた時系列データ分類は系列長の長い時系列データに対して効果的な手法であることが分かる。これは MACD ヒストグラムを用いることで時系列データの変化を強調でき、良い特徴を取り出すことができているためだと考えられる。

表 7 に “Sensor” カテゴリの結果を示す。結果から Short-MHLF の分類精度が高いことが示されている。しかし、Multi-Channel MHLF や Long-MHLF は Short-MHLF に対して分類精度が高くないことから、このカテゴリ内では短期的な変動を顕著に抽出できる短期 MACD ヒストグラムを用いることで分類精度を向上できることが考えられる。

表 8 では ResNet モデルと Short-MHLF の分類精度が高いことが分かった。また、“Simulated” カテゴリ内は全体を通して正解率が高く、分類問題として簡単なデータセットが多いことが分かる。Multi-Channel MHLF の分類精度が ResNet モデルよりも低くなった原因として、MACD ヒストグラムは時系列データの傾向をとらえることができるが激しいノイズのような系列データが含まれたとき、トレンドを正しく抽出することができないことがあげられる。そのため、「CBF」データセットや「MALLAT」データセッ

トでは十分な分類精度が得られなかった。

表 9 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は適していないことが分かる。このカテゴリは、一部の周波数の微小な違いで分類されるため、Attention 構造が有効的に働いている問題が多く、ALSTM-FCN モデルが最も良い。

各カテゴリについて、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分類精度の向上が得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あげられる。

また、時系列データによっては短期 MACD ヒストグラムや長期 MACD ヒストグラムのみを用いることで分類精度が向上したデータセットも見られた。このことから MACD ヒストグラムのパラメータを調整することでさらに分類精度を向上できることが考えられる。また、MACD ヒストグラムの効果についてそれぞれのデータセットのカテゴリごとにまとめたものを表 10 に示す。“ECG”, “Image”,

表 10 カテゴリごとに対する MACD ヒストグラムの効果
Table 10 The effect of MACD histogram for each category.

カテゴリ名	MACD ヒストグラムの 効果の有無	説明
Device	△	一部のデータセットでは MACD ヒストグラムを用いたモデルの性能が向上したが、次元シャッフルを持たない LSTM-FCN モデルがより安定して精度が高かった。
ECG	○	変化の違いを強調する MACD ヒストグラムを用いることで分類精度の向上が行えた。MACD ヒストグラムのパラメータを調整することでさらに分類精度を向上すると期待される。
Image	○	Multi-Channel MHLF の分類精度が最も良いことから、マルチチャンネル化と MACD ヒストグラムを用いる効果が見られた。
Motion	○	Multi-Channel MHLF の分類精度が最も良いことから、マルチチャンネル化と MACD ヒストグラムを用いる効果が見られた。
Sensor	△	Short-MACD ヒストグラムのみを用いたモデルの精度が最も良いことから、短期的な変化を抽出することで精度の向上が行えた可能性がある。しかし、その他のモデルでは精度の改善が見られなかった。
Simulated	△	Short-MACD ヒストグラムのみを用いたモデルと ResNet の分類精度がほとんど変わらなかった。
Spectro	×	ALSTM-FCN モデルの分類精度が最も高く、MACD ヒストグラムを用いたモデルの性能の改善が見られなかった。

“Motion” カテゴリのデータセットに対して MACD ヒストグラムの効果が見られた。しかし、“Device”、“Sensor”、“Simulated” カテゴリでは MACD ヒストグラムを用いた分類モデルの性能の向上が確認できたが、十分な精度の改善は見られなかった。原因としては、短期 MACD ヒストグラムを用いたモデルと長期 MACD ヒストグラムを用いたモデルに性能の差があることから、MACD ヒストグラムのパラメータを調整する必要があると考えられる。最後に“Spectro” カテゴリに対して MACD ヒストグラムの効果は得られないことが分かった。今後の課題として、MACD ヒストグラムのパラメータの最適化があげられる。

表 11 MHRP と提案手法の比較結果
Table 11 The comparing result of MHRP vs Multi-Channel MHLF.

データセット名	MHRP	Multi-Channel MHLF
CBF	0.6710	0.9900
DistalPhalanxOutlineAgeGroup	0.8700	0.8675
DistalPhalanxOutlineCorrect	0.8420	0.8450
DistalPhalanxTW	0.8220	0.8100
ECG200	0.9400	0.9300
ECG5000	0.9350	0.9460
ECGFiveDays	1.0000	1.0000
ElectricDevices	0.6340	0.7797
FaceAll	0.7450	0.9710
FacesUCR	0.8550	0.9629
ItalyPowerDemand	0.9710	0.9679
MedicalImages	0.2224	0.7895
MiddlePhalanxOutlineAgeGroup	0.8120	0.8075
MiddlePhalanxOutlineCorrect	0.8370	0.8583
MiddlePhalanxTW	0.6640	0.6466
MoteStrain	0.8800	0.9225
PhalangesOutlinesCorrect	0.8380	0.8485
Plane	1.0000	1.0000
ProximalPhalanxOutlineAgeGroup	0.8930	0.8829
ProximalPhalanxOutlineCorrect	0.9070	0.9278
ProximalPhalanxTW	0.8300	0.8250
SonyAIBORobot Surface	0.8390	0.9817
SonyAIBORobot SurfaceII	0.8050	0.9213
SwedishLeaf	0.9470	0.9824
SyntheticControl	0.5870	0.9900
TwoPatterns	0.3810	1.0000
TwoLeadECG	0.9950	1.0000
平均正解率	0.8269	0.8794
平均ランク	1.630	1.296
最高精度数	10	19

5.4 評価実験 2

先行研究 [6] にて提案されている MACD-histogram-based Recurrence Plot (MHRP) と提案手法との比較を行う。MHRP では時系列データから算出された MACD ヒストグラムをリカレンスプロットと呼ばれる白黒画像データへと変換する。また、深層学習のモデルとして Stacked-Autoencoder が用いられている。Stacked-Autoencoder は入力データに対して階層的に自己符号化器を用いて事前学習を行う手法である。MHRP は系列長の長い時系列データをリカレンスプロットへ変換すると計算時間が急増するため、UCR アーカイブデータセット内の一部のデータセットでのみ実験が行われている。

表 11 に MHRP と提案手法との比較結果を示す。平均正解率は Multi-Channel MHLF が MHRP よりも高く、最高精度数においても MHRP と比べて提案手法の方が多いことが分かる。結果として提案手法である Multi-Channel

MHLFはMHRPと比較して分類精度を改善することができた。しかし、MHRPの方が分類精度が高いデータセットも見られる。これらのデータセットではデータセットに含まれる時系列データの系列長が比較的短い。したがって、MHRPでは系列長の短いデータセットで高い精度を示している。一方で、“MedicalImage”データセットや“TwoPatterns”データセットに対しては提案手法は大幅な分類精度の改善が示されている。つまり、MHRPでは時系列データの周期性に基づくデータ表現を用いているが、系列長が長い場合は提案手法はLSTMを用いることでより複雑な変化をとらえることができている。

5.5 評価実験3

深層学習を用いた分類手法では、学習時に乱数を用いているため精度に多少の差が生じることがある。本実験では、提案手法の分類精度のばらつきを観測し、提案手法の性能のばらつきの有無について考察する。また、提案手法は学習回数2,000回の後、検証データに対しての最良値を選択している。この処理を10回繰り返し、提案手法の性能のばらつきを標準偏差として算出した結果を表12に示す。結果として、データセットごとに分類性能のばらつきが確認されたが、標準偏差から全体的にばらつきは少ないが、標準偏差が0となっているデータセットも含まれている。これは、分類精度が100%となっているデータセットであり、安定して十分な分類精度を示せることが分かった。

6. まとめ

本論文では深層学習を用いた新しい時系列データの分類手法としてMulti-Channel MHLFを提案した。提案手法ではMACDヒストグラムを用いて入力データをマルチチャンネル化し、分類精度の向上を図った。具体的には時系列データから短期ウインドウと長期ウインドウを用いて、時系列データから異なるMACDヒストグラムを抽出して時系列データと2種類のMACDヒストグラムでマルチチャンネルデータを入力層で生成する。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表現している。これらの異なる特徴を持つ2種類のMACDヒストグラムをマルチチャンネルデータとしてLSTM-FCNベースの深層モデルに入力することで特徴をより効果的に学習することができる。UCRアーカイブデータセットを用いた比較実験を行い、提案手法は従来手法と比較して分類精度が向上していることを示すことができた。しかしながら、カテゴリによっては提案手法の精度が高くないケースがあった。今後の課題として、より汎用的な手法を目指し、MACDヒストグラムのパラメータ調整について考察する。また、LSTM-FCNモデルは深層モデルとしては層が浅いため、より深い層を持つモデルを使っ

表 12 乱数による提案手法の性能のばらつき

Table 12 Performance Variation of Multi-Channel MHLF.

dataset	標準偏差
50words	0.0043
Adiac	0.0038
ArrowHead	0.0056
Beef	0.0163
BeetleFly	0.0000
BirdChicken	0.0200
Car	0.0117
CBF	0.0013
ChlorineConcentration	0.0040
CinCECGtorso	0.0098
Coffee	0.0000
Computers	0.0067
CricketX	0.0054
CricketY	0.0058
CricketZ	0.0045
DiatomSizeReduction	0.0030
DistalPhalanxOutlineAgeGroup	0.0028
DistalPhalanxOutlineCorrect	0.0064
DistalPhalanxTW	0.0042
Earthquakes	0.0021
ECG200	0.0049
ECG5000	0.0007
ECGFiveDays	0.0000
ElectricDevices	0.0067
FaceAll	0.0029
FaceFour	0.0094
FacesUCR	0.0018
Fish	0.0026
FordA	0.0015
FordB	0.0019
GunPoint	0.0000
Ham	0.0083
HandOutlines	0.0044
Haptics	0.0075
Herring	0.0157
InlineSkate	0.0129
InsectWingbeatSound	0.0058
ItalyPowerDemand	0.0008
LargeKitchenAppliances	0.0021
Lighting2	0.0115
Lighting7	0.0110
MALLAT	0.0015
Meat	0.0107
MedicalImages	0.0028
MiddlePhalanxOutlineAgeGroup	0.0043
MiddlePhalanxOutlineCorrect	0.0064
MiddlePhalanxTW	0.0081
MoteStrain	0.0057
NonInvasiveFatalECGThorax1	0.0010
NonInvasiveFatalECGThorax2	0.0023
OliveOil	0.0100
OSULeaf	0.0000
PhalangesOutlinesCorrect	0.0037
Phoneme	0.0042
Plane	0.0000
ProximalPhalanxOutlineAgeGroup	0.0029
ProximalPhalanxOutlineCorrect	0.0036
ProximalPhalanxTW	0.0031
RefrigerationDevices	0.0070
ScreenType	0.0102
ShapeletSim	0.0075
ShapesAll	0.0026
SmallKitchenAppliances	0.0061
SonyAIBORobot_Surface	0.0036
SonyAIBORobot_SurfaceII	0.0068
StarlightCurves	0.0009
Strawberry	0.0021
SwedishLeaf	0.0033
Symbols	0.0018
Syntheticcontrol	0.0016
ToeSegmentation1	0.0033
ToeSegmentation2	0.0080
Trace	0.0000
TwoPatterns	0.0000
TwoLeadECG	0.0000
UWaveGestureLibraryX	0.0040
UWaveGestureLibraryY	0.0036
UWaveGestureLibraryZ	0.0026
UWaveGestureLibraryAll	0.0025
Wafer	0.0002
Wine	0.0074
WordsSynonyms	0.0040
Worms	0.0103
WormsTwoClass	0.0110
Yoga	0.0033

た手法を検討する予定である。

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, *2017 International Joint Conference on Neural Networks (IJCNN)*, pp.1578–1585, IEEE (2017).
- [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] Tamura, K. and Ichimura, T.: MACD-histogram-based recurrence plot: A new representation for time series classification, *2017 IEEE 10th International Workshop on Computational Intelligence and Applications (IWCIA)*, pp.135–140, IEEE (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 Trans. 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, *Proc. 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)*, pp.002419–002424, IEEE (2016).
- [11] Lines, J., Davis, L.M., Hills, J. and Bagnall, A.: A shapelet transform for time series classification, *Proc. 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.289–297, ACM (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] Grabocka, J., Schilling, N., Wistuba, M. and Schmidt-Thieme, L.: Learning Time-series Shapelets, *Proc. 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD '14*, pp.392–401, ACM (online), DOI: 10.1145/2623330.2623613 (2014).
- [14] Vandewiele, G., Ongena, F. and De Turck, F.: GENDIS: GENetic DIScovery of Shapelets, arXiv preprint arXiv:1910.12948 (2019).
- [15] 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)*, pp.1041–1046, IEEE (2016).
- [16] Lin, M., Chen, Q. and Yan, S.: Network in network, arXiv preprint arXiv:1312.4400 (2013).
- [17] Kim, Y.: Convolutional Neural Networks for Sentence Classification, *Proc. 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, Doha, Qatar, pp.1746–1751, Association for Computational Linguistics (online), DOI: 10.3115/v1/D14-1181 (2014).
- [18] 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).
- [19] Ioffe, S. and Szegedy, C.: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, *Proc. 32nd International Conference on International Conference on Machine Learning (ICML), Proc. Machine Learning Research*, Vol.37, pp.448–456, PMLR (2015).
- [20] He, K., Zhang, X., Ren, S. and Sun, J.: Deep residual learning for image recognition, *Proc. IEEE Conference on Computer Vision and Pattern Recognition*, pp.770–778 (2016).
- [21] 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).

付 録

表 A.1 UCR アーカイブデータセット

Table A.1 UCR time series dataset.

データセット名	系列長	クラス数	訓練データ	テストデータ
50words	270	50	450	455
Adiac	176	37	390	391
ArrowHead	251	3	36	175
Beef	470	5	30	30
Beetle Fly	512	2	20	20
Bird Chicken	512	2	20	20
Car	577	4	60	60
CBF	128	3	30	900
Chlorine Concentration	166	3	467	3,840
CinC ECG torso	1,639	4	40	1,380
Coffee	286	2	28	28
Computers	720	2	250	250
Cricket X	300	12	390	390
Cricket Y	300	12	390	390
Cricket Z	300	12	390	390
Diatom Size Reduction	345	4	16	306
Distal Phalanx	80	3	400	139
Outline Age Group	80	2	600	276
Distal Phalanx	80	6	400	139
Outline Correct	80	6	400	139
Distal Phalanx TW	80	6	400	139
Earthquakes	512	2	322	139
ECG200	96	2	100	100
ECG5000	140	5	500	4,500
ECG Five Days	136	2	23	861
Electric Devices	96	7	8,926	7,711
Face All	131	14	560	1,690
Face Four	350	4	24	88
Faces UCR	131	14	200	2,050
Fish	463	7	175	175
Ford A	500	2	3,601	1,320
Ford B	500	2	3,636	810
Gun Point	150	2	50	150
Ham	431	2	109	105
Hand Outlines	2,709	2	1,000	370
Haptics	1,092	5	155	308
Herring	512	2	64	64
Inline Skate	1,882	7	100	550
Insect Wingbeat Sound	256	11	220	1,980
Italy Power Demand	24	2	67	1,029
LargeKitchen	720	3	375	375
Appliances	637	2	60	61
Lighting 2	319	7	70	73
Lighting 7	1,024	8	55	2,345
MALLAT	448	3	60	60
Meat	99	10	381	760
Medical Images	80	3	400	154
Middle Phalanx	80	2	600	291
Outline Age Group	80	2	600	291
Middle Phalanx	80	6	399	154
Outline Correct	84	2	20	1,252
Middle Phalanx TW	80	6	399	154
Mote Strain	84	2	20	1,252
Non Invasive Fatal	750	42	1,800	1,965
ECG Thorax 1	750	42	1,800	1,965
Non Invasive Fatal	750	42	1,800	1,965
ECG Thorax 2	750	42	1,800	1,965
Olive Oil	570	4	30	30
OSU Leaf	427	6	200	242
Phalanges Outlines	80	2	1,800	858
Correct	80	2	1,800	858
Phoneme	1,024	39	214	1,896
Plane	144	7	105	105
Proximal Phalanx	80	3	400	205
Outline Age Group	80	2	600	291
Proximal Phalanx	80	6	400	205
Outline Correct	80	6	400	205
Proximal Phalanx TW	80	6	400	205
Refrigeration Devices	720	3	375	375
Screen Type	720	3	375	375
Shapelet Sim	500	2	20	180
Shapes All	512	60	600	600
Small Kitchen	720	3	375	375
Appliances	720	3	375	375
Sony AIBO	70	2	20	601
Robot Surface	70	2	20	601
Sony AIBO	65	2	27	953
Robot Surface II	65	2	27	953
Starlight Curves	1,024	3	1,000	8,236
Strawberry	235	2	613	370
Swedish Leaf	128	15	500	625
Symbols	398	6	25	995
Synthetic Control	60	6	300	300
Toe Segmentation 1	277	2	40	228
Toe Segmentation 2	343	2	36	130
Trace	275	4	100	100
Two Patterns	128	4	1,000	4,000
Two Lead ECG	82	2	23	1,139
U Wave Gesture	315	8	896	3,582
Library X	315	8	896	3,582
Library Y	315	8	896	3,582
Library Z	315	8	896	3,582
Library All	945	8	896	3,582
Wafer	152	2	1,000	6,164
Wine	234	2	57	54
Words Synonyms	270	25	267	638
Worms	900	5	181	77
Worms Two Class	900	2	181	77
Yoga	426	2	300	3,000



橋田 修一 (学生会員)

2018年広島市立大学情報科学部知能工学科卒業。2020年同大学大学院情報科学研究科知能工学専攻博士前期課程修了。時系列データ分析、深層学習に興味を持つ。IEEE 学生会員。



田村 慶一 (正会員)

広島市立大学大学院情報科学研究科教授。博士(情報科学)。1998年九州大学工学部情報工学科卒業。2000年同大学大学院システム情報科学研究科知能システム学専攻修士課程修了。2003年同大学院システム情報科学府知能システム学専攻博士後期課程単位取得のうえ満期退学。広島市立大学情報科学部助手、広島市立大学大学院情報科学研究科助教、同講師、同准教授を経て、2019年より現職。データマイニングと高性能ビッグデータ分析、時系列データ分析、並列処理に関する研究に従事。IEEE、電子情報通信学会、日本データベース学会、人工知能学会、日本知能情報ファジイ学会各会員。