

時系列データ分類に基づく クラス対応を考慮した部分時系列の学習

小寺 謙斗^{1,a)} 沼尾 正行² 福井 健一²

概要：機械学習の解釈性に関する研究が注目を集めている。近年時系列データ分類における解釈性の高い分類手法として、Shapelet と呼ばれる分類に有効な部分時系列を学習によって獲得する手法が提案された。しかしながら、従来手法では学習によって得られた Shapelet とクラスとの対応が不明瞭となる問題がある。本研究では、従来手法の構造を変更し、損失関数に新たな項を加えることで、クラス固有の Shapelet を獲得する手法を提案する。実験結果より、分類に有効な各クラス固有の Shapelet を獲得出来ることを確認した。

Learning subsequences considering class correspondence based on time series data classification

KOTERA KENTO^{1,a)} MUMAO MASAYUKI² FUKUI KEN-ICHI²

Abstract: Research on the interpretability of machine learning has attracted a great deal of attention. In recent years, as a highly interpretable classification method for time series data classification, a method to acquire subsequences effective for classification called Shapelet by learning has been proposed. However, in the conventional method, there is a problem that the correspondence between Shapelet and class obtained by learning becomes unclear. In this research, we propose a method to obtain class-specific Shapelet by changing the structure of the conventional method and adding a new term to the loss function. From the experimental results, we confirmed that we could acquire class-specific Shapelets that are valid for classification.

Keywords: Time Series Classification, Shapelet

1. はじめに

近年機械学習技術の発展により、様々な領域で応用が進んでいる。しかしながら、そのモデルの複雑さやブラックボックス化により、透明性や公平性が求められる分野での適用が難しいという課題がある。そこで、機械学習の出力に対し、説明性や解釈可能性を持たせる研究が注目を集めている [11].

機械学習の主要なタスクの 1 つに時系列データ分類問題がある。心電図のような生体情報やセンサデータなど、現

実世界のデータの多くが時系列の形をとる。これらのデータは、ただ分類するだけでなく、分類の根拠の説明を要求される場合がある。

説明性のある時系列データ分類手法として、分類に有効な部分時系列群をクラスターリングおよび特徴選択により獲得する手法 [10] や、Shapelet と呼ばれる部分時系列を探索や学習により獲得する手法がある。特に近年、その分類根拠の明確さから、Shapelet を用いる手法の研究が盛んである [3][9]。これらの手法では、時系列分類に有効なのは時系列全体のパターンではなく、局所的なパターンであるという前提に基づく。Shapelet はその局所的なパターンとの距離を特徴量に変換し、その特徴量を入力としてを用いたときにクラスを最大限に分離出来るような部分時系列である。図 1 は Shapelet の例である。Shapelet はそれぞれの時系列データの中から最も類似する部分との距離計算を行

¹ 大阪大学大学院情報科学研究科
Graduate School of Information Science and Technology, Osaka University

² 大阪大学産業科学研究所
The Institute of Scientific and Industrial Research, Osaka University

a) k-kotera@ist.osaka-u.ac.jp

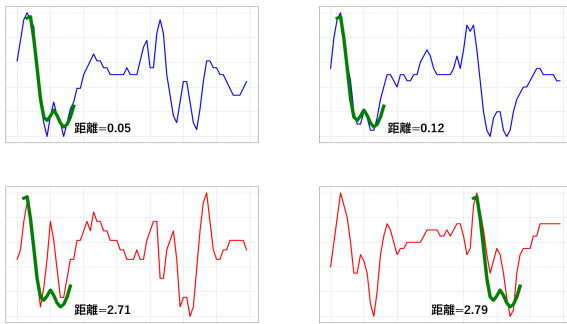


図 1 Shapelet(緑色) の例. 上側の 2 つの時系列はクラス 1(青色)に属し, 下側の 2 つはクラス 2(赤色)に属する.

う. 図 1 の Shapelet(緑色) はクラス 1 特有のパターンであるため, クラス 1 との距離は小さくなり, クラス 2 との距離は大きくなる.

Shapelet に関する初期の研究では, 部分時系列は訓練データの中から探索によって獲得された. Shapelet に関する最初の研究である文献 [8] では, Shapelet によって変換された特徴量を用いてクラスを分割した場合に, 情報利得が最大となるような Shapelet を探索し, 決定木を用いて分類器を作成した. 文献 [7] では, Local Shapelet と呼ばれるものを探索する手法を提案した. Local Shapelet は, それぞれの Shapelet が各クラスに対応付けられており, 分類結果の解釈が容易となるメリットがある. しかしながら, これらの探索ベースの手法では計算時間が大きく, ノイズに脆弱である問題がある.

これらの問題を克服するため, 近年学習によって Shapelet を獲得する手法が提案された [3]. この手法では, 入力データと Shapelet との距離を計算する部分と, ロジスティック回帰によってクラス予測を行う部分を結合し, 勾配法により Shapelet とロジスティック回帰の重みを同時に獲得する. この手法は探索ベースの手法に比べ非常に高速である. さらに, 訓練データに存在しない Shapelet の形状を獲得出来るため, 高い精度を達成することが出来る. しかしながら, 得られる Shapelet は特徴量変換のための部分時系列以上の意味を持たず, クラスとの対応が不明瞭である. その上, 学習時に行われる様々な幾何学的変換により, 得られる Shapelet の解釈が困難になる問題がある.

そこで, 本研究では Shapelet をクラスに対応付け, 解釈が容易な形状を学習によって獲得することを目的とする. 従来手法 [3] の構造をクラス数だけ並列に並べ, それぞれの構造をクラスに対応付けて One-vs-rest で学習させることにより, Shapelet をクラスに対応付ける. さらに, 学習時の幾何学的変換による解釈不可能性を克服するため, Shapelet が対応したクラスに属するデータから遠ざかることにペナルティを科す項を損失関数に加える. これにより, 得られる Shapelet はそのクラスに属するデータにおける, 分類に有効な局所パターンのセントロイドに近似さ

せる. これらのクラス対応付けと形状のセントロイド近似のアイデアをモデル設計の段階で組み込むことは, 出力される Shapelet を解釈する上での信頼性を提供する. 提案手法について, いくつかの実データに対して実験を行い, 得られた Shapelet が分類に有効であることを示す. さらに, 得られた Shapelet を視覚的に分析し, 対応したクラスを表現する Shapelet が得られていることを確認する.

2. 部分時系列の学習法

2.1 Shapelet 変換

Shapelet 変換とは, k 個の Shapelet を用いた場合に, ある時系列データに関して各々の Shapelet が最も類似する箇所との距離を計算することで, k 次元の特徴量に変換することである. このような特徴量変換のアイデア自体は, Shapelet に関する最初の研究 [8] の時点ですでに存在していた. しかしながら, この研究では Shapelet の探索が分類器として用いる決定木に従属しており, 特徴量は逐次的に計算された. このような決定木を構築しながら Shapelet を探索する試みは, 分類精度や探索時間に問題があった. 後に探索時間の高速化の手法 [4][6] も提案されたが, 決定木に由来する過学習の問題を解決することは出来なかった. そこで文献 [5] では, Shapelet を分類器と独立して探索し, 探索された複数の Shapelet による特徴量計算を Shapelet 変換という特徴変換とみなすアイデアを導入した. 変換された特徴量に 1NN 法や SVM などの汎用的な分類器を適用することで, Shapelet により提供される解釈性を維持しつつ, 高い精度での分類を可能にした. Shapelet 変換の具体的な定義は以下ようになる.

2.1.1 時系列データセットと Shapelet

時系列データセットを $T \in \mathbb{R}^{I \times Q}$ とする. ここで, I は時系列データセットのデータ数であり, Q は各時系列データのデータ長とする. また, Shapelet の集合を $S \in \mathbb{R}^{K \times L}$ とする. ここで, K は Shapelet の数であり, L は各 Shapelet のデータ長とし, これらは事前に設定される.

2.1.2 時系列データと Shapelet 間の距離

i 番目の時系列データの j 番目の値を $T_{i,j}$ とする. 長さ L の部分時系列を考えると, i 番目の時系列データの j 番目から開始される部分時系列は $(T_{i,j}, \dots, T_{i,j+L-1})$ となる. なお, 1 つの時系列データに対して長さ L の部分時系列は $J = Q - L + 1$ 個存在する. k 番目の Shapelet の l 番目の値を $S_{k,l}$ とする. 部分時系列 $(T_{i,j}, \dots, T_{i,j+L-1})$ と Shapelet S_k との距離は以下のように計算される.

$$D_{i,k,j} = \frac{1}{L} \sum_{l=1}^L (T_{i,j+l-1} - S_{k,l})^2 \quad (1)$$

2.1.3 Shapelet 変換による特徴量

前述した定義により, i 番目の時系列データの k 番目の Shapelet との距離 $D_{i,k}$ は J 個存在し, そのうち距離が最

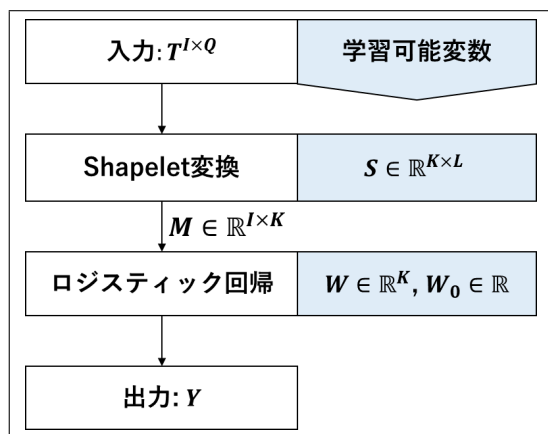


図 2 LTS 法の流れ

小の部分は k 番目の Shapelet と最も類似する箇所とみなすことが出来る。そのときの距離を $M_{i,k}$ とすると、次のように表すことが出来る。

$$M_{i,k} = \min_{j=1,\dots,J} D_{i,k,j} \quad (2)$$

Shapelet 変換は、 K 個の Shapelet を用いて、時系列データ $T \in \mathbb{R}^{I \times Q}$ から $M \in \mathbb{R}^{I \times K}$ に変換する一連の操作である。

2.2 LTS 法

Learning time-series shapelets(LTS) 法 [3] は前述した Shapelet 変換とロジスティック回帰を組み合わせた Shapelet の学習手法である。Shapelet の初期値に対して、損失関数を小さくする方向に重みと Shapelet を反復的に更新することで、分類器のモデルを学習しながら Shapelet 自身も予測精度が最大になる方向へ形状が最適化される。具体的なモデルと損失関数は次の通りである。

2.2.1 予測モデル

簡略化のため、2 クラス分類の場合を考える。訓練データの教師ラベルを $Y \in \{0, 1\}^I$ とする。線形重みを $W \in \mathbb{R}^K$ (およびバイアス $W_0 \in \mathbb{R}$) とし、ロジスティック関数を $\sigma(\cdot)$ とする。Shapelet 変換後の特徴ベクトル M を用いて、クラスの予測値 \hat{Y} は次のように表される。

$$\hat{Y}_i = \sigma(W_0 + \sum_{k=1}^K M_{i,k} W_k), \quad \forall i \in \{1, \dots, I\} \quad (3)$$

以上の手続きを示したものが図 2 である。多クラス分類の場合も、通常のロジスティック回帰と同様出力をクラスの数だけ用意し、出力の one-hot 表現とソフトマックス関数を用いることで容易に拡張出来る。

2.2.2 損失関数

通常のロジスティック回帰同様、損失関数はクロスエントロピー誤差関数および L2 正則化を用いる。クロスエントロピー誤差関数は教師ラベル Y と予測値 \hat{Y} を用いて次のように表される。

$$L(Y, \hat{Y}) = -Y \ln \hat{Y} - (1 - Y) \ln (1 - \hat{Y}) \quad (4)$$

ロジスティック回帰の重みの L2 正則化項 $\|\cdot\|_2$ およびその係数 λ_w を用いて、損失関数 F は次のように表される。

$$F(W, S) = L(Y, \hat{Y}) + \lambda_w \|W\|_2 \quad (5)$$

一般的なロジスティック回帰では、式 (5) の重み W に関する勾配を計算し更新するが、LTS 法では (5) の重み W に加えて Shapelet S の勾配を計算し、それぞれ更新する。

3. 提案手法

提案手法では、Shapelet をクラスに対応付けるために従来の LTS 法の構造を拡張する。さらに、Shapelet が訓練データから遠ざかることにペナルティを科す項を損失関数に加えることで、Shapelet がクラス固有の形状を獲得することを旨とする。以下では、具体的な構造および損失関数を述べる。

3.1 基本構造

提案手法の構造は、Shapelet の学習 (STEP1) のための構造と、クラス予測 (STEP2) のための構造に分かれる。

3.1.1 STEP1: Shapelet の学習

Shapelet を学習するための構造では、図 2 に示した LTS 法の構造をクラスの数だけ並列に並べる。それぞれの構造の中の Shapelet は、それぞれのクラスに対応付けられる。つまり、Shapelet の集合はクラス数を C とすると $S \in \mathbb{R}^{C \times K \times L}$ となる。入力データ $T^{I \times Q}$ はクラスに対応付けられた特徴量の集合 $M \in \mathbb{R}^{C \times I \times K}$ に変換され、クラス毎に One-vs-rest な予測を行うよう線形重み $W \in \mathbb{R}^{C \times K}$ (およびバイアス $W_0 \in \mathbb{R}^C$) を用いてロジスティック回帰を行う。つまり、このロジスティック回帰における各々の教師ラベルは

$$Y_{i,c} = \begin{cases} 1 & (\text{if } c = Y_i^{\text{categorical}}) \\ 0 & (\text{otherwise}) \end{cases} \quad (6)$$

となる。ここで、 $c \in \{1, \dots, C\}$ は並列に並んだ構造の番号であり、 $Y^{\text{categorical}}$ はデータの元の教師ラベルのカテゴリ変数表現である。図 3(a) は 2 クラスの場合の Shapelet を学習するための構造の例である。入力データ T は、クラス 1, クラス 2 に対応した Shapelet S_1, S_2 によって M_1, M_2 に変換される。クラス 1 の構造では、 M_1 を入力としてクラス 1 かそれ以外かのバイナリ分類をロジスティック回帰で行う。クラス 2 の構造も同様にクラス 2 かそれ以外のバイナリ分類を行う。この構造によって得られた Shapelet は、対応したクラスに属するかどうかを予測するのに有効な部分時系列となる。後述する損失関数により、それをセントロイドの形状獲得しながら近づけることで、クラス固有の局所パターンを獲得する。

3.1.2 STEP2: クラスの予測

クラスを予測するための構造では、学習済の Shapelet

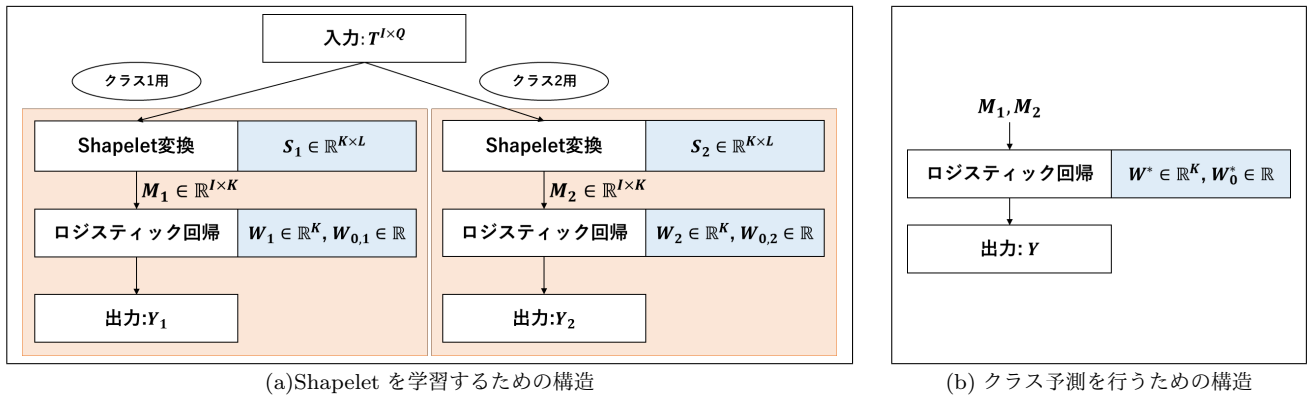


図 3 2 クラスの場合の提案手法

より計算される $M \in \mathbb{R}^{C \times I \times K}$ を入力として、線形重み $W^* \in \mathbb{R}^{C \times K}$ (およびバイアス $W_0^* \in \mathbb{R}$) を用いてロジスティック回帰を行う (3 クラス以上の場合には多クラスロジスティック回帰を行う)。ただし、このときの入力 M はクラスごとに分割されない。学習時の重みの更新はロジスティック回帰の重みだけを行い、Shapelet は更新されない。図 3(b) は、クラスを予測するための構造の具体例である。図 3(a) で Shapelet の形状を学習後、特徴量 M_1, M_2 が計算される。 M_1, M_2 の両方を入力としてロジスティック回帰の学習を行い、クラスの分類器を構築する。この学習によって得られる重みの大きさは、後に Shapelet の重要度を分析するのに役立つ。

3.2 損失関数

新しい損失関数は STEP1 の Shapelet を学習するための構造に適用される。式 (5) の損失関数に加えて、Shapelet が対応するクラスの波形から遠ざかることにペナルティを科す項を加える。Shapelet 変換による特徴量 $M_{c,i}$ ($i = 1, \dots, I$) は Shapelet とデータとの距離なので、損失関数に c がデータのクラスラベルと同一の場合は $M_{c,i}$ を、それ以外の場合は 0 を加えればよい。追加の項を式で表すと以下のようになる。

$$\sum_{i=1}^I \sum_{k=1}^K Y_{i,c} M_{c,i,k} \quad (7)$$

さらに、従来手法では多くの Shapelet が出力される中、ロジスティック回帰の重みの大きさの差異が小さく、重要な Shapelet を取り出すことが難しい問題があった。より解釈を容易にするため、L2 正則化の代わりに L1 正則化を用いることで、少数の重要な Shapelet の獲得を図る。以上より、クラス c に対応した構造の損失関数は以下のようになる。

$$F_c(W, S) = L(Y_c, \hat{Y}_c) + \lambda_w \|W_c\|_1 + \lambda_c \sum_{i=1}^I \sum_{k=1}^K Y_{i,c} M_{c,i,k} \quad (8)$$

STEP2 のクラス予測を行うための構造では、式 (5) と同様通常の損失関数を用いるが、正則化は L1 正則化を用いる。

$$F^*(W) = L(Y, \hat{Y}) + \lambda_w^* \|W^*\|_1 \quad (9)$$

3.3 アルゴリズム

以上の手続きを疑似コードで示すと以下の通りである。

Algorithm 1 提案手法

Require: 入力データ $T^{I \times Q}$, 出力ラベル $Y^{I \times C}$, クラス数 C , Shapelet の個数 K , Shapelet 長 L , 最大イテレーション数 $Maxitr_1, Maxitr_2$, 学習率 η

STEP1

- 1: **for** $itr = 1, \dots, Maxitr_1$ **do**
- 2: **for** $c = 1, \dots, C$ **do**
- 3: **for** $k = 1, \dots, K$ **do**
- 4: $W_{c,k} \leftarrow W_{c,k} - \eta \frac{\partial F_c}{\partial W_{c,k}}$
- 5: **for** $l = 1, \dots, L$ **do**
- 6: $S_{c,k,l} \leftarrow S_{c,k,l} - \eta \frac{\partial F_c}{\partial S_{c,k,l}}$
- 7: **end for**
- 8: **end for**
- 9: **end for**
- 10: **end for**

STEP2

- 11: **for** $itr = 1, \dots, Maxitr_2$ **do**
- 12: **for** $k = 1, \dots, C \times K$ **do**
- 13: $W_k^* \leftarrow W_k^* - \eta \frac{\partial F^*}{\partial W_k^*}$
- 14: **end for**
- 15: **end for**
- 16: **return** S, W, W^*

4. 実験と評価

本実験では UCR time series archive[2] で公開されている時系列データを用いる。いくつかの実データに関して、従来手法および提案手法を用いて実験を行い、視覚的分析




図 4 Coffee データの実験結果 (従来手法)




図 6 Coffee データの実験結果 (従来手法, 強調して可視化)




図 5 Coffee データの実験結果 (提案手法)

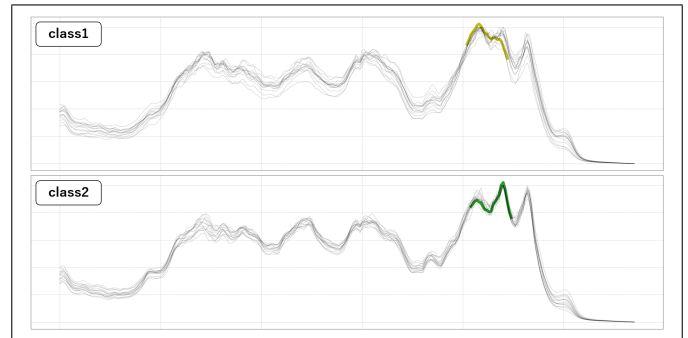


図 7 Coffee データの実験結果 (提案手法, 強調して可視化)

により提案手法がクラス固有のパターンを捉えた Shapelet を獲得出来ていることを確認する。次に、分類精度についても検討し、獲得した Shapelet が分類に有効な波形であることを示す。

4.1 Coffee データ

Coffee データは、ロブスタ種とアリビカ種のコーヒー豆を分類するための食物スペクトログラムデータである。Shapelet 長 $L = 20$, Shapelet の個数を $K = 2 \times 10$ とし、従来手法である LTS 法と提案手法のそれぞれについて実験を行う。図 4 図 5 はそれぞれ従来手法および提案手法での実験結果である。黒色の細線がクラス 1 およびクラス 2 それぞれの時系列データであり、その他の色で表される太線が Shapelet である。従来手法では Shapelet とクラスの対応がないため、合計 20 個の Shapelet を Class1 と Class2 の両方に表示している。Shapelet の位置は、各クラスの中からデータをランダムに 1 つ取り出し、そのデータと最もマッチングする箇所に配置している。提案手法では、対応するクラスに基づきそれぞれ 10 個ずつ表示している。図 4 で示される通り、従来手法の Shapelet はデータと無関係な形状となることが多い。一方図 5 では、Shapelet がデータのパターンを捉えており、提案した構造および損失関数が上手く機能していることが確認出来る。

さらに、ロジスティック回帰の重みの大きさをを用いて、どの Shapelet が分類に重要な役割を果たしているか検討する。図 6 図 7 はそれぞれ図 4 図 5 で示される実験結果について、対応した重みの大きさに応じ色の濃淡で重要な

表 1 上位 5 つの重みの大きさ (Coffee データ)

| 順位 | 従来手法 | 提案手法 |
|-----|-------|-------|
| 1 位 | 0.366 | 1.108 |
| 2 位 | 0.234 | 0.768 |
| 3 位 | 0.229 | 0.000 |
| 4 位 | 0.194 | 0.000 |
| 5 位 | 0.158 | 0.000 |

Shapelet が強調している。表 1 は実際の重みの大きさについて、上位 5 つの値を示している。これらの図と表より、従来手法ではクラスの予測に多くの Shapelet を利用しているのが分かる。一方提案手法では、図 7 において黄色で示される Shapelet (クラス 1 に対応) および緑色で示される Shapelet (クラス 2 に対応) 以外の重みの大きさは無視できるほど小さく、実質その 2 つの Shapelet のみで予測を行っている。この 2 つの Shapelet はそれぞれ対応したクラスのパターンを捉えているので、これら 2 つのパターンの違いが、このデータの分類上有効な違いであると言える。

4.2 GunPoint データ

GunPoint データは、銃をホルスターから取り出して構え、後元に戻す動作と、それを銃を持たずに真似た動作の 2 つについて、モーションキャプチャリングによって得られる 2 クラス分類の時系列データである。一連の動作に関して、映像の中心を原点とし、手の X 軸方向の位置について追跡して得られる。Shapelet 長 $L = 30$, Shapelet の個数を $K = 2 \times 10$ とし、従来手法である LTS 法と提案手法のそれぞれについて実験を行う。図 8 図 9 はそれぞれ従来手




図 8 GunPoint データの実験結果 (従来手法, 強調して可視化)





図 9 GunPoint データの実験結果 (提案手法, 強調して可視化)

法および提案手法での実験結果である。図 6 図 7 同様、対応した重みの大きさに応じて強調している。このデータにおいても、従来手法では困難である、クラス固有のパターンを捉えた Shapelet を獲得出来ていることが分かる。ここで、提案手法で得られた各クラス毎の最も重要な Shapelet について検討する。図 10 は図 9 で示される最も強調された Shapelet を拡大したものである。クラス 2 の Shapelet である図 10(b) の波形には凹んだ部分が確認出来る。これは、オーバーシュート現象として知られており [8]、クラス 2 特有のものである。従来手法では Shapelet が分類に有効な波形以上の意味を持たないため、この現象の発見が困難である。一方、提案手法では Shapelet が各クラスに対応付けられており、さらに Shapelet が局所パターンのセントロイドに近似するように設計されているため、出力される Shapelet は局所パターンの代表的な形状である。よって、出力される Shapelet 間の形状の差異、つまり凹みの有無に注目することでデータの解釈に繋げることが出来る。

4.3 分類精度

最後に、UCR time series archive[2] に含まれる 6 つのデータについて、従来手法および提案手法の分類精度について検討する。さらに、Shapelet 関連の手法以外のベースラインとして、動的時間伸縮法 (DTW) を距離尺度とする 1-Nearest Neighbor 法 (1NN) の精度についても比較する。この手法は時系列データ分類における最も代表的な分類手法であり、汎用性および精度の高さから、非常に強力なベースラインとして知られている [1]。従来手法



(a) クラス 1 の Shapelet (b) クラス 2 の Shapelet
図 10 それぞれのクラスの最も重要な Shapelet (GunPoint)

表 2 テストデータでの分類精度

| データ名 | Train/Test | 1NN _{DTW} | 従来手法 | 提案手法 |
|-------------|------------|--------------------|------|------|
| CBF | 30/900 | 1.00 | 0.98 | 0.98 |
| Coffee | 28/28 | 1.00 | 1.00 | 0.96 |
| GunPoint | 50/150 | 0.91 | 1.00 | 0.96 |
| SonyAIBO. 1 | 20/601 | 0.73 | 0.92 | 0.90 |
| SonyAIBO. 2 | 27/953 | 0.83 | 0.89 | 0.82 |
| DiatomSize. | 16/306 | 0.96 | 0.95 | 0.95 |

および提案手法の実験パラメータは、 $K \in \{10, 20\} \times C$ 、 $L \in \{0.075, 0.125, 0.175, 0.2\} \times Q$ より検証データを用いて従来手法で選択し、提案手法は同一のパラメータを用いた。訓練データとテストデータの分割は UCR データの標準に従った。表 2 はテストデータにおける分類結果である。提案手法では損失関数に分類に直接影響しない項を加えたため、従来手法に比べて精度は若干損なわれているものの、概ね高い分類性能を維持していることが確認出来る。なお、提案手法は分類精度の向上を目的としたものでないことを強調しておく。

5. おわりに

本研究では、出力として得られる Shapelet をクラスに対応付けられるように従来手法を拡張した。視覚的分析から、各クラス固有のパターンを捉えた Shapelet を獲得出来ることを確認した。さらに、従来手法では困難であったデータに内在する現象の理解に関して、提案手法による解釈のプロセスを述べ、その有効性を示した。

参考文献

- [1] Bagnall, A., Lines, J., Bostrom, A., Large, J., Keogh, E.: The great time series classification bake off: a review and experimental evaluation of recent algorithmic advances. In: Data Mining and Knowledge Discovery, Vol. 31 No. 3, pp. 606-660(2017).
- [2] Chen, Y., Keogh, E., Hu, B., Begum, N., Bagnall, A., Mueen, A., Batista, G.: The UCR Time Series Classification Archive(2015). www.cs.ucr.edu/~eamonn/time_series_data/
- [3] Grabocka, J., Schilling, N., Wistuba, M., Schmidt-Thieme, L.: Learning time-series shapelets. In: Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 392-

- 401(2014).
- [4] He, Q., Dong, Z., Zhuang, F., Shi, Z.: Fast Time Series Classification based on infrequent shapelets. In: Proceedings of the 2012 11th International Conference on Machine Learning and Applications, pp.215-219(2012).
 - [5] Hills, J., Lines, J., Baranauskas, E., Mapp, J., Bagnall, A.: Classification of time series by shapelet transformation. In: Data Mining and Knowledge Discovery, Vol. 28, pp. 851-881(2014).
 - [6] Mueen, A., Keogh, E., Young, N.: Logical-shapelets: an expressive primitive for time series classification. In: Proceedings of the 17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. pp. 1154-1162(2011).
 - [7] Xing, Z., Pei, J., Yu, P., Wang, K.: Extracting Interpretable Features for Early Classification on Time Series. In: Proceedings of the 11th SIAM International Conference on Data Mining, pp. 247-258(2011).
 - [8] Ye, L., Keogh, E.: Time series shapelets: a new primitive for data mining. In: Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 947-956(2009).
 - [9] Zhang, Q., Wu, J., Yang, H., Tian, Y. and Zhang, C.: Unsupervised Feature Learning from Time Series. In: Proceedings of the 25th International Joint Conference on Artificial Intelligence, pp. 2322-2328 (2016).
 - [10] 須賀佑太朗, 関庸一, 安藤晋. 特徴的部分系列に基づく時系列および形状系列の判別分析. 情報処理学会論文誌 数理モデル化と応用, vol.8, No.2, pp.66-76 (2015).
 - [11] 増井紀貞. 機械学習の解釈性. 人工知能学会誌, Vol.33, No.5, pp.641-644(2018).