

特徴的部分系列に基づく時系列及び形状系列の判別分析

須賀 佑太郎^{1,a)} 関 庸一^{1,b)} 安藤 晋^{2,c)}

概要: 系列データの分類は時系列・センサストリームや画像輪郭線の分類など幅広い応用を含む機械学習の重要な問題の一つである。しかし、系列データは特殊な順序構造を持ち、一般的な分類器の直接の入力として適さない。このため一般的な分類器で系列データから学習するのに適した特徴量を生成することが課題となる。従来、有望なアプローチとして、Shapelet 等の系列内の特徴的部分から予測変数を生成する方法が提案されている。これらの方法では系列パターンとクラスの特徴を視覚的分析できるメリットがある。ただし、従来手法では多数の系列パターンを利用するとクラスとパターンとの対応が不明瞭になるという問題があった。本研究では系列パターンからの距離に基づく特徴量と特徴選択の手法を組み合わせることで、クラスに固有なパターンを抽出する方法を提案する。提案手法は、マージン最大化学習と同時にマージンを最大限維持する特徴選択手法を用いる。選択された特徴に対応する系列パターンを視覚的に分析した結果、クラス固有の部分形状が検出できることが示された。数値実験では、時系列データと輪郭データを用いて提案手法の性能を評価し、既存手法との比較を示す。

Abstract: Classification of sequential data is one of the important problems in machine learning, with a wide range of applications such as time series, sensor stream and image classification. However, due to its ordered structure, sequential data are not appropriate as the direct input of the general classifiers. Generate features for learning from time series and sequential data with a general classifier is therefore a critical task. One of the promising approaches is to find and exploit the characteristic subsequence patterns in the sequential data, such as Shapelets. The subsequences provide the discriminative features for learning classifiers as well as the primitives for graphical analysis. However, the conventional method has problematic issues when utilizing large number of sequence patterns. In this study, we propose a framework for feature selection and classification for sequential data that combines the clustering method for extracting subsequence patterns unique to the class and the distance-based feature based on the concept of multiple-instance learning. The feature selection method embedded in max-margin learning algorithm is employed to select important patterns and learn a linear classifier simultaneously. In our empirical study, we evaluated the performance of the proposed method using the time series data and the silhouette data and compared them with existing methods. The result showed that the proposed method can maintain high classification accuracies while extracting visually identifiable class-specific patterns in sequential shapes and time series.

1. はじめに

実世界事象の観測は多くの場合、系列の形をとる。このため系列データの分類は重要な応用問題である [1], [2], [3]. 系列データでは、連続する値が相関を持つ構造を持っている。例えば、時系列データでは時間軸で隣接する観測値に相関が存在する。また、画像から抽出される輪郭も系列データとなる。例えば、図 1 のような輪郭画像では隣接する点の間に相関が存在する。




図 1: 輪郭形状データの例

¹ 群馬大学
Gunma University
² 東京理科大学
Tokyo University of Science
^{a)} t13801448@gunma-u.ac.jp
^{b)} seki@cs.gunma-u.ac.jp
^{c)} ando@rs.tus.ac.jp

人は系列データに関して高い判別能力を持ち、さらに部分的な形状の特徴を事前に得た知識を踏まえて認識することが可能である。図 1 は (a) が鍵、(b) がギターの輪郭形状である。これらの画像のクラスを判別するとき、人はギターのネックと胴体の部分、鍵のブレード部分と握りの




図 2: 時系列データの例 (ロボット行動プロファイル)

部分等を事前の知識に基づいて認識し、画像全体のクラスを判別できる。一方、画像認識においてこのような類似した部分形状を持つ輪郭の判別は難しい問題である [4].

図 2 は自律エージェントロボットの速さの時系列であり、行動を表すプロファイルデータとして用いられる。縦軸は速度ベクトルのノルムの値を表し、横軸は単位時間に対応する。(a), (b) はそれぞれ異なるタスクの実行時のプロファイルであり、細かく上下に変化する部分形状が追跡行動に特徴的なパターンであることがわかる。一方、一定速度の部分は二つのタスク間で共通なパターンであり、これは時系列中の大きな割合を占める。このような場合はタスクに特徴的な部分形状を認識し、クラスの違いを識別する必要がある。

系列データは特殊な順序構造を持つため、一般的な分類器の直接の入力として適さない [5]. このため、機械学習の分野でも近年、部分形状を用いた学習の方法が有望視されている。その代表例が [6] において提案された時系列 Shapelet を用いる方法である。Shapelet は時系列の部分系列と閾値の対で構成され、クラスラベル付きの時系列集合を自身との距離によって分割した際に最大の情報利得が得られるものとして定義される。

Shapelet は、分類モデルの構築に利用される他、データの特徴を視覚的に分析しやすくするメリットがある。[7] では、Shapelet との一致を閾値により判定し、その結果を変数とする決定木を構築した。[8] では、Shapelet との一致に基づいて時系列を分類する Local Shapelet と呼ばれる方法が提案された。[6] では、情報利得や F 比などの高い複数の Shapelet を抽出し、各 Shapelet との距離を特徴ベクトルとして時系列を表現する Shapelet Transformation が提案された。

Shapelet は、情報利得やそれに類する単一基準に基づいて選択されるため、高速に抽出できる。一方、Shapelet が予測変数の役割を持つことから、特徴選択と同様の問題点も発生する。それぞれの Shapelet は別々に評価されるため、Shapelet 間の依存関係を踏まえて選択することが困難である。また、クラスの小さい割合の事例のみに含まれる部分系列から得られる情報利得は小さいため、それが典型的なパターンであっても抽出されにくい。これは、部分系列の大部分がクラス間で共通するパターンを持つ場合には重要なデメリットとなる。

本研究では Shapelet における問題に対処するための、特

微量生成と選択分類学習を一貫して行う枠組みを提案する。まず、階層的クラスタ構造に対するデータクリーニング手法を用いて共通パターンを排除し、特徴的な部分系列の候補を生成するクラスタリング手法を提案する。また、時系列を部分系列のマルチプルインスタンス例とみなし、部分系列のクラスタからの距離に基づいた特徴ベクトルを生成する。最後に、クラスタリングによる特徴生成とマージン最大化学習の枠組みを用いた特徴選択を行い、判別器の学習と同時に識別に役立つ部分系列を選択する。これにより、より多くの特徴的な形状を持つ系列データからの効果的な分類学習を実現する。

本稿の構成は以下の通りである。2 節では関連研究を示す。3 節では提案手法の詳細を述べる。4 節では数値実験の結果を示す。5 節では結論を述べる。

2. 関連研究

2.1 Shapelet

近年、時系列分類において Shapelet を使用する手法が深く研究されている。[9] では、Shapelet は時系列集合のクラスラベルについて最大情報利得を持つ部分系列と定義される。Shapelet の候補となる部分系列は距離の閾値と対になっていて、その値で時系列集合を分割したとき、最大情報利得を与える。Shapelet 手法の主な目的は、時系列の大きい集合の典型的なパターンの視覚的分析を可能にし、同時に分類モデルの性能を強化することである。[9] では、Shapelet の有無を属性とする決定木を提案している。[11] では、Local Shapelet と呼ばれる Shapelet とのマッチングによる分類手法を提案している。[12] では、Shapelet Transform と呼ばれる Shapelet との距離を時系列の特徴量とする変換手法が提案された。情報ゲインや F 統計 [13] 等の基準に基づいて複数の Shapelet を選択し、それらへの距離を特徴ベクトルとして分類を行っている。

2.2 AROM 特徴選択法

0 ノルムはベクトル内の非 0 要素の数で、一般的に $\|\cdot\|_0$ と表される。0 ノルム最小化は特徴選択問題 [14] に関係する。ラベル付けされたデータ $\{(x_i, y_i)\}_{i=1}^N$ とパラメータベクトル \mathbf{w} の線形モデルが与えられたとき、線形 SVM に関する 0 ノルム最小化問題は以下のように表される。

$$\min_{\mathbf{w}} \|\mathbf{w}\|_0 \text{ subject to } y_i(\mathbf{w}^\top \mathbf{x}_i) \geq 1 \quad (1)$$

(1) の問題は NP 困難として知られている [14] では、対数

Algorithm 1 ハウスドルフテンプレートの生成

入力: 訓練データ (部分系列集合) $\mathcal{S} = \{s_i\}_{i=1}^N$
 訓練ラベル $\mathcal{Y} = \{y_i\}_{i=1}^N$
 $y_i \in \{1, -1\}$
 m (最小クラスサイズ)
 出力: 一様クラス \mathcal{C}
 関数: HC(単連結クラスタリング)
 t : (単連結木) $\mathcal{Y} = \{y_i\}_{i=1}^N$
 $t \leftarrow HC(\mathcal{S})$
 $\mathcal{T} \leftarrow t$ に含まれるラベル y_i が一様な部分木を列挙
 $\mathcal{S} \leftarrow \mathcal{T}$ の中で葉の数が m 以上ある要素を列挙
return \mathcal{C}

1 ノルムを使用した 0 ノルムの近似として、次式のような近似 0 ノルム最小化 (AROM) が示された。

$$\min_{\mathbf{w}} \log(\|\mathbf{w}\|_1 + \epsilon) \text{ subject to } y_i(\mathbf{w}^\top \mathbf{x}_i) \geq 1 \quad (2)$$

ただし、 ϵ は平滑化のための定数で $0 < \epsilon \ll 1$ である。対数損失は勾配降下法 [15] により最小化する。0 ノルム最小化の結果、クラスの差異に関係しない特徴量の係数の絶対値は減少するため、相対的に重要な特徴を選択できる。

3. 提案手法

提案手法では訓練データからクラスに特徴的な部分形状をクラスタリングにより抽出し、さらに各データについて部分形状との距離に基づく特徴量を生成する。

3.1 部分系列のクラスタリング

時刻 t における観測値を x_t とする。時刻 $1, \dots, T$ における観測時系列を $X = (x_1, \dots, x_T)$ と表す。 i 番目の観測時系列を X_i とし、 $\mathcal{X} = \{X_i\}_{i=1}^n$ を訓練データとする。訓練データのラベルを $\mathcal{Y} = \{y_i\}_{i=1}^n$ と表す。 X_i を長さ l の部分系列に分割し、各部分系列は $\mathbf{s}_t = (x_t, \dots, x_{t+l-1})$ と表す。 X_i の部分系列集合 S_i は $S_i = \{\mathbf{s}_t\}_{t=1}^{T-l+1}$ と表す。全訓練データの部分系列の和集合を $\mathcal{S} = \bigcup_{i=1}^n S_i$ と表す。

訓練データからクラスに特徴的な部分形状を階層的クラスタリングにより抽出する手順を以下に示す [16]。

- (1) 階層的クラスタリングにより部分系列を併合した階層木構造を生成する。
- (2) クラスが全て同じでかつ指定された数 m 以上の葉を持つ部分木を抽出する。部分木の要素の集合を一様クラスと呼ぶ。ただし、他の同様な部分木に包含される部分木は除く。

上の手順の疑似コードを Algorithm1 に示す。 \mathcal{S} を入力として生成した集合を $\mathcal{C} = \{C_j\}_{j=1}^q$ とする。一様クラスはクラスクラスタ [17], [18] の特徴を持つ。 m は最小クラスサイズであり、偶然にその大きなクラスタが発生しないよう 20~30 以上とすることが望ましい。

3.2 特徴量の生成

3.1 節で生成した部分系列のクラスは時系列の特徴量

を生成するために用いる。特徴量は時系列 X と各一様クラスタとの距離から以下に示す方法で生成する [19]。

ここでは、一つの時系列を部分系列の集合と考え、マルチプルインスタンス学習 [20] で用いられるハウスドルフ距離を用いる。ハウスドルフ距離は 2 つの集合例の間の距離のミニマックスにより求める。本研究ではユークリッド距離を D としたとき、訓練データ X_i とクラス C_j の距離 d を次のように定義する [19]。

$$d(X_i, C_j) = \max_{C \in C_j} \min_{S \in S_i} \{D(C, S)\} \quad (3)$$

なお、前節で定義した通り、 S_i は X_i の部分系列集合である。また、 X_i の特徴量ベクトル $\mathbf{v}(X_i)$ を次のように定義する。

$$\mathbf{v}(X_i) = (d(X_i, C_1), \dots, d(X_i, C_q)) \quad (4)$$

本研究では $\mathbf{v}(X_i)$ を入力として長さ q の重みベクトル \mathbf{w} をパラメータとする線形分類器 $f: \mathbb{R}^q \rightarrow \{1, -1\}$ を学習する。 $\mathbf{v}(X_i)$ を X_i のハウスドルフテンプレート変換 (Hausdorff Template Transform: HaTT) と呼ぶ。テストデータについても (3)(4) 式から HaTT を生成することができる。

3.3 特徴選択

前節で定義した訓練データの特徴量ベクトルを $\mathcal{V} = \{\mathbf{v}_i\}_{i=1}^n$ とする。これを入力とし、AROM 手法により特徴選択と線形 SVM の学習を行う。以下に AROM の手順を示す。

線形 SVM の重みベクトル \mathbf{w} を \mathbf{v} から学習する。学習後、 \mathbf{w} を用いて入力 \mathbf{v} を以下のようにスケールする。

$$\begin{aligned} \mathbf{v}' &= \mathbf{w} \cdot \mathbf{v} \\ &= (w_1 v_1, w_2 v_2, \dots, w_q v_q) \end{aligned} \quad (5)$$

$\mathbf{v} = \mathbf{v}'$ とし、再びベクトル \mathbf{w}' を学習する。

以上の手順を r 回繰り返して得られた重みを $\mathbf{w}^{(r)}$ とする。 $\mathbf{w}^{(r)}$ の係数のうち絶対値の小さな特徴量を \mathbf{v} から削除し、これを \mathbf{v}^* とする。最後に、 \mathbf{v}^* から \mathbf{w}^* を学習し、判別関数 f を

$$f(\mathbf{v}^*) = \text{sgn}(\mathbf{w}^{*\top} \mathbf{v}^*) \quad (6)$$

とする。

以下の実験では、重みの絶対値上位 10 から 20 個の変数を選択する。

4. 実験

4.1 データ概要

本研究では実世界データを 6 つ用いた実験により、提案手法の検証を行った。実世界データとして輪郭画像データとエージェントロボットの行動プロファイル時系列を用いた。MPEG7 CE Shape-1 は、2 値画像の集合で MPEG7

表 1: データ概要

	事例数	分割比	系列長
key vs guitar	40	4 : 1	500
spoon vs guitar	40	4 : 1	500
重複輪郭	40	4 : 1	500
Myth	10	4 : 1	500
行動プロフィール	8	5.5 : 1	4561

インターフェイスの形状記述子のためのベンチマークデータである [4]. [21] では画像から抽出した輪郭を系列に変換し, Shapelet を用いて Transformation 分類手法を適用している. 本実験では分類が難しいとされるギターと鍵とスプーンの画像から 2 クラス分類問題を用意する. key と guitar クラスの判別を輪郭判別問題 1, spoon と guitar クラスの判別を輪郭判別問題 2 とする. 輪郭から系列を生成する手順は [21] にならって, 輪郭点の重心からの距離を系列とした.

2 番目の実データとして複数の輪郭画像を組み合わせた重複輪郭画像を用いる. 各画像は MPEG7 の 5 種の画像を重ね, 輪郭を抽出したものである. 空港の機内持ち込み品の X 線検査で得られる画像の分類など実用上重要な問題がある. positive クラスには hammer の形状が含まれ, negative クラスには含まれない. この 2 クラスの画像を判別する問題を扱う.

3 番目の実データとして非剛体の画像分類問題のベンチマークを扱う [22]. 以下では Myth データと呼ぶ. ここでは centaur と horse の 2 クラスの画像を判別する, 2 クラス分類問題を扱う.

最後に, マルチエージェントロボット実験 [23] における 2 台の自律エージェントロボットの行動プロフィールからその行動を分類する問題を扱う. エージェントロボットの行動は追跡と探索の 2 種類ある. 図 5 (a) (b) に示した時系列はそれぞれ追跡, 探索行動のプロファイルの例である. 縦軸は速度ベクトルのノルムの値を表し, 横軸は単位時間に対応する. 行動の種類によって時系列の形状が異なることが分かる.

4.2 設定

前節に示した各データについて, 事例数, 訓練データとテストデータの分割比, 系列長を表 1 に示す. 提案手法のパラメータ m は 20, 30 を用いた. 部分系列の長さ l はそれぞれの問題で 50, 100, 200 とした. 線形 SVM の学習には LibLinear[24] を使用し, ℓ_2 正規化の係数は $C = 0.1$ とした.

比較手法として, 隠れマルコフモデル分類器 (HMM)^{*1}[6] と Local Shapelet[10] を用いた. 4 つの輪郭データでは 5 分割交差検定を行い正答率の平均を示す. 行動プロファイ

^{*1} <http://doc.gold.ac.uk/mas02mg/software/hmmweka/>

表 2: 正答率の比較

	部分系列長	特徴選択前	提案手法	Local	
				Shapelet	HMM
key vs guitar	100	90.0	87.5	65.0	50.0
	200	87.5	90.0	65.0	50.0
spoon vs guitar	100	65.0	62.5	67.5	70.0
	200	67.5	62.5	55.0	70.0
重複輪郭	100	85.0	82.5	50.0	-
	200	87.5	87.5	57.5	-
Myth	100	70.0	90.0	60.0	60.0
	200	90.0	90.0	50.0	60.0
行動プロフィール	100	81.4	75.4	38.4	80.0
	200	88.9	92.7	38.1	87.0

表 3: 提案手法の正答率とテンプレート数 (key vs guitar)

部分系列長	50		100		200		
	m	20	30	20	30	20	30
テンプレート数 (選択前)	54.8	26.0	123	59.0	165	86.4	
正答率 (選択前)	80.0	80.0	90.0	90.0	92.5	87.5	
正答率	75.0	77.5	87.5	87.5	85.0	90.0	

ルのデータは 4 つの実験から得られた時系列を前後半でそれぞれ訓練, テストデータとし, その正答率の平均を示す.

4.3 結果

提案手法及び比較手法の分類結果の正答率を表 2 に示す. 単位はパーセントとし, 選択前は提案手法において AROM による特徴選択を行う前の正答率である. 行動プロフィールについては Local Shapelet は予測を保留する例があり, 正答率・保留率・誤答率を合計すると 1 になる. 保留率は $m = 100, 200$ のときそれぞれ 46.7, 47.5 である. 提案手法は 5 個のデータ中, 4 個のデータで比較手法を上回った.

表 3~表 7 に提案手法のパラメータを変更した場合の正答率と特徴選択前の変数の数を示す. 全体の傾向として, m が大きい方が選択前のテンプレート数は少なくなった. 部分系列が長いほど正答率は高くなった. また, 提案手法は特徴選択前と比べ, ほぼ同等であった.

提案手法により抽出されたクラスタの例を図 3, 図 4 に示す. 図 3 では, guitar クラスのボディの丸み, key クラスのブレード形状, spoon クラスの皿部の丸みや取っ手の直線部がそれぞれ抽出された. 図 4 では, centaur クラスの頭部から腕, horse クラスの背中や足から頭部がそれぞれ抽出された. また, 行動プロフィールデータから抽出した部分系列を図 5 に示す. 追跡データの頻繁な速度ベクトルノルムの変化が生じる部分, (b) では探索行動における一定の速さで移動する部分がそれぞれ抽出された. 提案手法によりそれぞれのデータについて視覚的に認識できる特徴的な形状を抽出できたといえる. AROM による特徴選択ではラベル情報を用いるため必ずしも汎化の効果は得られない.

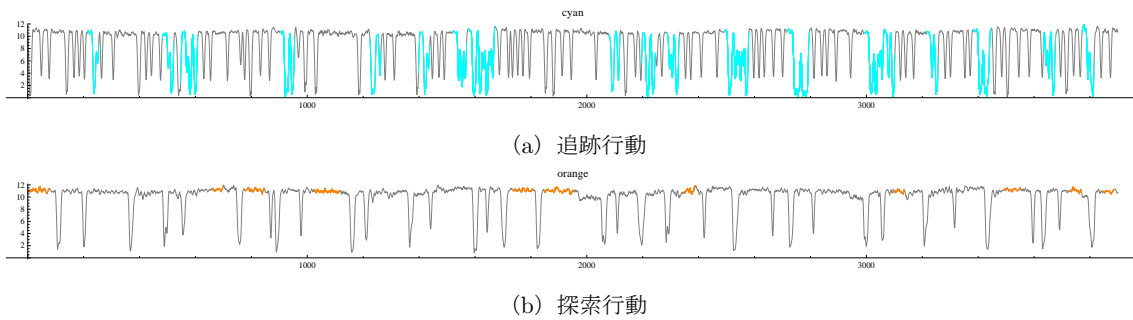


図 5: 行動プロファイルデータにおいて選択されたテンプレートの例




図 3: MPEG7 データにおいて選択されたテンプレートの例

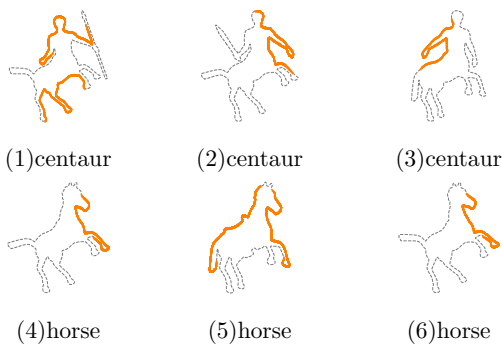


図 4: Myth データにおいて選択されたテンプレートの例

表 4: 提案手法の正答率とテンプレート数 (spoon vs guitar)

部分系列長	50		100		200	
	m					
テンプレート数 (選択前)	44.2	26.0	92.6	55.8	153	78.4
正答率 (選択前)	59.4	52.5	65.0	65.0	77.5	67.5
正答率	72.5	50.0	67.5	62.5	85.0	62.5

4.4 おわりに

本研究では、時系列データからより正確性の高い分類を行うため、特徴量生成と選択分類学習を一貫して行う枠組みを提案した。クラスタリング手法を用い、特徴的な部分系列の候補を生成した後、特徴選択により視覚的に認識できる特徴的な形状を抽出できた。また、時系列を部分系列

表 5: 提案手法の正答率とテンプレート数 (Myth)

部分系列長	50		100		200	
	m					
テンプレート数 (選択前)	14.8	6.40	49.4	19.6	84.0	42.2
正答率 (選択前)	60.0	50.0	90.0	70.0	90.0	90.0
正答率	70.0	50.0	90.0	90.0	90.0	90.0

表 6: 提案手法の正答率とテンプレート数 (重複輪郭)

部分系列長	50		100		200	
	m					
テンプレート数 (選択前)	54.4	17.2	107	44.8	156	80.2
正答率 (選択前)	57.5	72.5	85.0	85.0	85.0	87.5
正答率	55.0	55.0	77.5	82.5	77.5	87.5

表 7: 提案手法の正答率とテンプレート数 (行動プロファイル)

部分系列長	100		200	
	m			
テンプレート数 (選択前)	74.8	34.5	76.3	34.5
正答率 (選択前)	81.4	80.0	88.9	84.7
正答率	75.4	78.2	92.7	82.5

のマルチプレインスタンス例とみなし、部分系列から特徴量を生成することで、より多くの特徴的な形状を持つ系列データからの効果的な分類学習を実現した。

参考文献

- [1] 平野章二, 津本周作, 構造的類似性に着目した多変量時系列医療データのクラスタ分析, 第 70 回全国大会講演論文集, 情報処理学会, pp.5-47-48, 2008.
- [2] 平野章二, 津本周作, 長期時系列データ類型化法の比較, 情報処理学会研究報告 (知能と複雑系), 90(2003-ICS-133), pp.139-144, 2003.
- [3] 大平良司, 矢田紀子, 長尾智晴, 単純な図形の組み合わせによる分類アルゴリズム, 情報処理学会研究報告 (数理モデル化と問題解決研究報告), 2010-MPS-77, pp.1-6, 2010.
- [4] Latecki, Longin Jan and Lakämper, Rolf and Eckhardt, Ulrich, Shape Descriptors for Non-rigid Shapes with a Single Closed Contour, Proc. IEEE Conf. Computer Vision and Pattern Recognition, pp.424-429, 2000.
- [5] M. W. Kadous and C. Sammut. Classification of Multivariate Time Series and Structured Data Using Constructive Induction. Mach. Learn., 58(2-3):179-216, Feb.2005.
- [6] C.M. ビショップ, パターン認識と機械学習 (下), シュプリンガー・ジャパン, 2008
- [7] Lexiang Ye, Eamonn Keogh, Time series shapelets: a

- novel technique that allows accurate, interpretable and fast classification, *Data Mining and Knowledge Discovery*, Volume 22, Issue 1-2, pp.149-182, 2011.
- [8] 辻本貴昭, 上原邦昭, Local Shapelet を用いた時系列分類に最適な距離尺度の選択, 情報処理学会研究報告 (バイオ情報学), 2012-BIO-32(27), pp.1-6, 2012.
 - [9] L. Ye and E. Keogh. Time Series Shapelets: a Novel Technique that Allows Accurate, Interpretable and Fast Classification. *Data Min. Knowl. Discov.*, 22(1-2):149-182, Jan 2011.
 - [10] Z. Xing, J. Pei, P. Yu, and K. Wang., Extracting Interpretable Features for Early Classification on Time Series. In *Proceedings of the 11th Siam International Conference on Data Mining (SDM11)*, pp.247-258, 2011.
 - [11] Mueen, Abdullah and Keogh, Eamonn and Young, Neal, Logical-shapelets: An Expressive Primitive for Time Series Classification, *Proceedings of the 17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD '11*, pp.1154-1162, 2011.
 - [12] J. Lines, L. M. Davis, J. Hills, and A. Bagnall. A Shapelet Transform for Time Series Classification. In *Proc. of the 18th ACM SIGKDD Intl. Conf. on Knowledge Discovery and Data Mining*, pp. 289-297, 2012.
 - [13] D. Cox. *Principles of Statistical Inference*. Cambridge U. Press, 2006.
 - [14] J. Weston, A. Elisseeff, B. Schölkopf, and M. Tipping. Use of the Zero Norm with Linear Models and Kernel Methods. *J. Mach. Learn. Res.*, 3:1439-1461, 2003.
 - [15] M. Frank and P. Wolfe. An Algorithm for Quadratic Programming. *Naval Research Logistics Quarterly.*, 3:95-110, 1956.
 - [16] 須賀佑太郎, 安藤晋, 関庸一, 人行動分類のための類型パターンに基づく最近傍法, 情報処理学会研究報告 (数理モデル化と問題解決研究報告), 2013-MPS-93 pp.1-5, 2013.
 - [17] Ivan Tomek, Two Modifications of CNN, *Systems, Man and Cybernetics, IEEE Transactions on*, pp.769-772, 2007.
 - [18] Haibo He and Edwardo A. Garcia. Learning from Imbalanced Data. *IEEE Trans. on Knowl. and Data Eng.* 21, 9 (September 2009), 1263-1284.
 - [19] 寫真由理, 安藤晋, 関庸一, 時系列分類のための部分類型に基づく特徴量, 研究報告数理モデル化と問題解決 (MPS), 2014-MPS-97(3), pp.1-5, 2014.
 - [20] 上原邦昭, 川村俊樹, 近傍事例集合の分布密度を用いた Multiple-Instance 学習, 情報処理学会研究報告 (数理モデル化と問題解決研究報告), SIG4(TOM20), pp.117-124, 2008.
 - [21] Jon Hills, Jason Lines, Edgaras Barabauskas, Classification of time series by shapelet transformation, *Data Mining and Knowledge Discovery*, pp.1-31, 2013.
 - [22] Alexander M. Bronstein, Michael M. Bronstein, Alfred M. Bruckstein, and Ron Kimmel. 2008. Analysis of Two-Dimensional Non-Rigid Shapes. *Int. J. Comput. Vision* 78, 1 (June 2008), 67-88.
 - [23] Kouno, A.; Takano, S.; Suzuki, E., Constructing Low-cost Swarm Robots that March in Column Formation, *Proceedings of the 7th International Conference on Swarm Intelligence*, Springer-Verlag, pp.556-557, 2010.
 - [24] R.E. Fan, K.W. Chang, C.J. Hsieh, X.R. Wang, and C.J. Lin, LIBLINEAR: A Library for Large Linear Classification, *Machine Learning Research* 9(2008), 1871-1874.