

## one-class SVM による逐次的なクラス集合の作成法

## An sequential construction method of class set with one-class SVM

富永 真紀人 †

中田 雅也 †

濱津 文哉 †

濱上 知樹 †

Makito Tominaga

Masaya Nakata

Fumiya Hamatsu

Tomoki Hamagami

## 1 はじめに

設備機器の振動や医療におけるバイタルデータ等の時系列信号から、異常を検知・予測する手段は、ディペンダブルなシステムの実現に欠かせない技術である。本研究では、従来、人の経験や知識に頼っていた異常検知の中でも、特に正常データに比べ異常データが極端に少ない場合に有効なオンライン機械学習法の検討を進めている。

データに偏りがあると正常/異常の2クラス判定が困難となる。その場合、one-class 判定による外れ値検出が有効であることが知られている [1, 2]。しかし、1つの one-class 判定器による定常/外れの判定だけでは、正常とみなせる状態が時間とともに変化をする場合に対応できない。

そこで本稿では、(1) データを階層的に分割し、(2) one-class SVM(OCSVM) によるクラス判定器を逐次作成しながら短時間の異常判定を行うことで、正常クラスの変化に追従させる方法を提案する。さらに、(3) 作成した判定器をまとめたクラス集合に対して、再度 OCSVM を用いて抽出された外れクラスの割合から、中長期にわたる異常予兆が行えることを示す。

## 2 逐次的なクラス集合の作成

## 2.1 時系列データの作成

時系列データに対し、フレーム、セグメント、クラスセットからなる3つの階層的な時間幅を定義する。

1. フレーム ( $frm_n$ ): 最も短い分析区間であり、特徴パラメータベクトル  $c_n$  を分析する対象となる区間である。 $n$  はフレーム番号である。端点の影響を軽減するために、窓関数が用いられる。
2. セグメント ( $seg_m$ ): 複数の連続したフレームからなる区間である。フレームは時間的に重複して分析される。後述するように1つのセグメント中の特徴パラメータの集合  $C_m = \{c_1, c_2 \dots c_M\}$  から、正常/外れを判定する1つの OCSVM 判定器 (クラス)  $h_m(c)$  が作成される。 $m$  はセグメント番号である。
3. クラスセット ( $cs$ ): 一定時間過去に遡った複数のセグメントからつくられた判定器を集めた集合  $H$  である。

以下、簡単のため必要ない場合は、 $n, m$  を省略して表す。

## 2.2 セグメント判定アルゴリズム

セグメント  $seg$  の判定を以下の手順で行う

1.  $C$  を求める。2.3 で述べる手順で作成される  $H^*$  を用意する。
2.  $H^*$  から順に  $h(c)$  を取り出し、以下の判定を行う。
  - (a)  $C$  から順に  $c$  を取り出し、 $h(c)$  を判定する。
  - (b) すべての  $c$  を判定をし、外れ率  $T_e = count(h(c) == FALSE)/N$  を計算する。

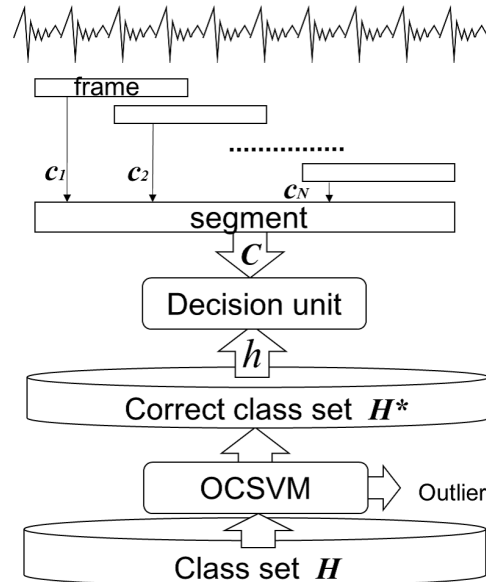


図1 セグメント判定アルゴリズム

- (c)  $T_e < T_{seg}$  のとき、 $seg$  は  $h$  に該当しているとみなし処理を終了する。そうでない場合は、2に戻り、他の判定器を用いて評価する。ここで  $T_{seg}$  は閾値である (Decision phase)。
- (d) すべての判定器に対し該当クラスが見つからなかった場合、 $seg$  は「外れ」セグメントとしてアラートを出す。

Fig.1 に、セグメント判定アルゴリズムの概略を示す。

## 2.3 正常クラス集合判定アルゴリズム

現時刻から一定時間過去に遡った複数のセグメントから作成される判定器の集合  $H$  を、以下の手順で作成する。

1. 一定時間過去までのセグメントのそれぞれから  $C$  を得る。
2. 最初のセグメントの  $C$  から OCSVM によって判定器を作成し、 $H$  に加える。
3. 2つ目以降のセグメントについては、 $H$  の判定器を用いて評価し、外れと評価された場合に、新たに OCSVM による判定器を作成し、 $H$  に追加する。

$H$  は過去一定時間内のセグメントの特徴を網羅するが、この中には異常セグメントのクラスが含まれる可能性がある。そこで  $H$  中からさらに OCSVM によって外れのクラスを抽出し、残った正常クラス集合  $H^*$  を用いて 2.2 の判定を行っている。また、 $H$  と  $H^*$  の数の比によって、 $H$  を構成している判定器の特徴を調べる。

$h$  の特徴ベクトル  $d$  を以下のように求める。

1.  $H$  の各判定器の作成に使われた  $C$  を集め、 $C^V$  とする。

† 横浜国立大学大学院工学府 Graduate School of Engineering, Yokohama National University

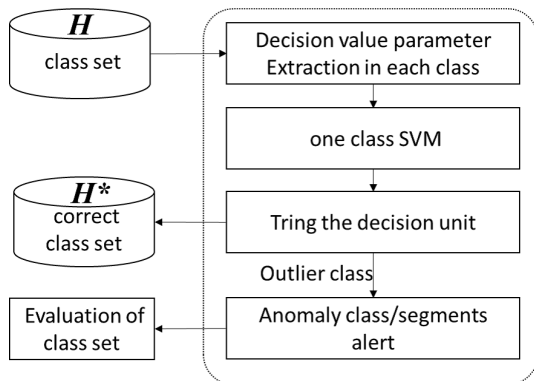


図2 正常クラス集合判定アルゴリズム

表1 1セグメントあたりの振動データ

データ点数	フレーム幅	フレーム数
40000 point/segment	640 point	185 flame/segment

2.  $H$  のすべての  $h$  に対して以下の処理を行う
  - (a)  $h$  を用いて  $C^V$  を評価する. このとき, 各  $c \in C^V$  について, OCSVM の識別面との距離を求める. なお, この符号が正であれば正常, 負であれば外れの判定となる.
  - (b) 2の距離を昇順に並び替えた後に, 下記に示すスコットの選択法により決定されるピン幅を用いてヒストグラムを作成し, クラス特徴ベクトル  $d$  とする.

$$\text{Binsize} = \frac{3.5\sigma}{n^{\frac{1}{3}}} \quad (1)$$

$\sigma$  はデータの標準偏差,  $n$  はデータ総数を表す.

3. 以上の処理を経て得られた  $d$  を用いて OCSVM を行う. 正常とみなされたクラスを  $H^*$  とする.

Fig.2 に正常クラス集合判定アルゴリズムの概要を示す.

### 3 実験結果および考察

稼働中の機器の振動を測定した時系列データに対して異常検出シミュレーション実験を行う. 使用した振動測定器のサンプリング周波数は 8 kHz である. セグメント長は 5.0s であり, 1.0h ごとに 1つのセグメントを取得している. なお, 測定開始後, 404 セグメント (404h) 目に異常が発生して停止をしている.

フレームの特徴ベクトル  $c$  として, ケプストラムを用いる. ケプストラムとは, 主に音声解析の分野で用いられる信号の特徴量であり, 振動のパワースペクトルを対数化し, 逆フーリエ変換をとることで得られる. ケプストラムの低次数部分のフーリエ変換は振動のスペクトル概形を表すため, 振動の周波数スペクトル概形をベクトルとして表現できる. なお, 機械振動の異常では, 固有の周波数の高次成分の変化が生じることが知られており, 周波数スペクトルの概形の変化が反映されるケプストラムは異常発見に有用であると考えられる.

使用データ 1 セグメントあたりの情報を表 1 に示す. 実験パラメータを表 2 に示す.  $\nu$  とは OCSVM の外れ値割合を制御するための内部パラメータである.

表2 実験パラメータ

$\nu$	$T_{seg}$	ケプストラム次数	セグメント数/クラスセット
0.005	0.4	28	60 segment

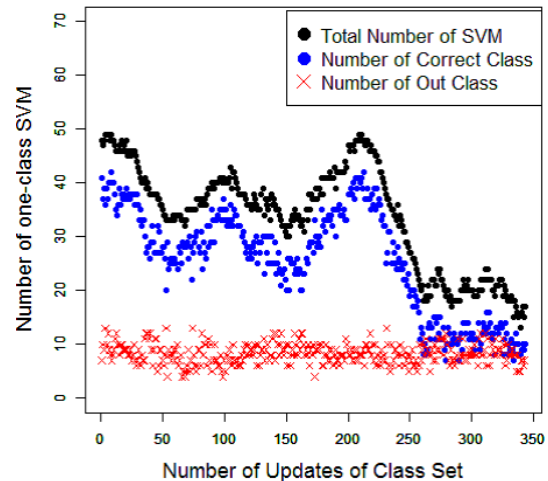


図3 SVM 個数の遷移

図3に,  $H$ ,  $H^*$  および, 差集合  $H - H^*$  のそれぞれに含まれる判定器数 (クラス数) の変化を示す.

$H$  のクラス数は時間とともに変動しているが,  $H - H^*$  のクラス数は大きな変化がみられない. これは OCSVM が一定数の外れができるように識別面をつくるアルゴリズムであることに加え, 定常状態が続く箇所では1つの正常クラスに複数のセグメントが該当するようになるためと推察される.

$H - H^*$  に着目すると, 更新回数が 200 程度から  $H$  のクラス総数が減り始め, 250 付近からは 20 クラス前後になっている. また,  $H^*$  と  $H - H^*$  のクラス数もほぼ同じになっている. クラス総数が大きく減っていることは, 分解能の低い判定器になっていることを示唆している. 相対的に  $H - H^*$  が増えることと合わせると, 200 回以前と明らかに  $H$  内の分布の変化が認められる. すなわち,  $H$ ,  $H^*$  および  $H - H^*$  に含まれるクラス数の関係から, 異常の予兆が発見できることを示唆している.

### 4 おわりに

本稿では時系列データの自動異常検出を目的として, 動的に正常状態が変化することを想定したデータから正常クラス集合を逐次的に作成, 更新する方法を提案した. フレーム, セグメント, クラスセットという 3 階層で分析を行い, セグメント単位とクラスセット単位の 2 段階の OCSVM を行うことで, 時系列の変化に追従した判定器集合を作成した. セグメントの外れ判定と, 外れクラスに該当するセグメントの異常判定, さらに, クラスセット内の正常/外れの比率から, 異常の発見・予測が可能であることを示した.

### 参考文献

- [1] 小野田崇 他, “One Class SVM に基づく水力発電所軸受異常振動の予兆発見”, 人工知能学会全国大会論文集 pp.170-170 (2004)
- [2] 中尾浩二 他 “1 クラス・サポートベクターマシンによる回転機の軸受振動診断”, 電気学会 産業計測制御研究会 IIC-16-005 (2016.6)