

異常値検出のアンサンブルによる 軌跡データからの特異行動の発見

星野大祐^{†1} Theerasak Thanomphongphan^{†1}
安藤 晋^{†1}
関 庸 一^{†1} Swagat Kumar^{†2} 鈴木 英之進^{†2}

本研究では動画から抽出された自律ロボットの軌跡データをもとに異常行動とみなせる部分系列を検出する問題に取り組んだ。従来の軌跡データマイニングでは軌跡を二次元空間の系列として扱うが、本研究では平均速度や回転速度等ロボットから主観的に計測できる物理量に変換した入力データとした。これにより動画の撮影環境が異なる場合や画像中の異なる個所で起きる異常も統一的に扱うことが可能になるため、提案手法は設計者に提示する上でより直感的で制御プログラムの修正にも生かしやすい異常検出手法となっている。ただし、速度等の物理量の時系列は時間窓サイズのパラメータによってノイズの影響や検出できる行動が変化する。そこで、われわれは複数のパラメータで生成した部分系列集合に対して異常検出を行い、そのラベルをメタ特徴量とするクラスタリングにより異常行動を検出する手法を提案した。提案手法は、高い精度と感度で人が異常と判断した行動を検出した。教師付き学習との比較では、訓練データとして与えられる異常行動のサンプルが限定的である場合、より高い感度を実現した。

Discovery of Unusual Actions from Trajectory Data using Ensemble of Outlier Detection

DAISUKE HOSHINO,^{†1}
THEERASAK THANOMPHONGPHAN,^{†1} SHIN ANDO,^{†1}
YOUICHI SEKI,^{†1} SWAGAT KUMAR^{†2}
and EINOSHIN SUZUKI^{†2}

We addressed the problem of detecting unusual behaviors from the trajectories of autonomously controlled robots. Subsequences of average velocities converted from the video trajectories were used as the input, in order to ad-

dress behaviors which occur in different areas of image and in different length of time in a general. However, the selection of the preprocessing parameters: the window size and the subsequence length, and the frequency and the length of the behavioral pattern, influences the detection result with mutual dependence. In this paper, we identify clusters of abnormal subsequences using different preprocessing parameters and exploit the cluster labels as meta-features in an ensemble clustering method. Empirical result shows that the proposed method with can partition abnormal behaviors of the robots with high precision and recall. In comparison to a supervised learning method, the proposed method has the advantage when the number of labeled abnormal samples are limited, which suggests that the proposed method is advantageous is practical when difficult to obtain or expensive.

1. はじめに

実環境で動作する自律ロボットの制御プログラムの設計は長時間のテストとその動作解析の繰り返しを伴う。その解析は設計者に大きな負担となっている。本論文では、ロボットの軌跡データから自動的に異常行動を検出することで設計者の負担を軽減する手法の開発を目指す。われわれは、動画から抽出したロボットの軌跡を速度に変換し、その部分系列集合を入力として用いた。これによってカメラの角度等の観測状況に依存せず、より一般的に異常行動を検出することができる。ただし、速度のような時間的な概念を含む特徴量は正しい時間間隔パラメータを選ばないと行動の特徴を捉えることができない。そこでわれわれは複数の時間間隔設定で行った学習結果のアンサンブルにより精度と感度の高い異常行動検出手法を提案する。提案手法は二段階で構成される。まず、いくつかの異なる時間間隔パラメータで生成した部分系列集合から半教師付学習により異常行動のクラスタを抽出する。続いて、そのクラスタラベルをメタ特徴量としてアンサンブルクラスタリングを行う。提案手法を異常行動を含む2つの軌跡データに適用し、精度と感度を評価した。教師付き学習手法との比較では、異常行動の例を訓練データとして多く準備することが難しい場合には提案手法の感度が上回った。

^{†1} 群馬大学大学院工学研究科

Gunma University

^{†2} 九州大学大学院システム情報科学研究院

Kyushu University

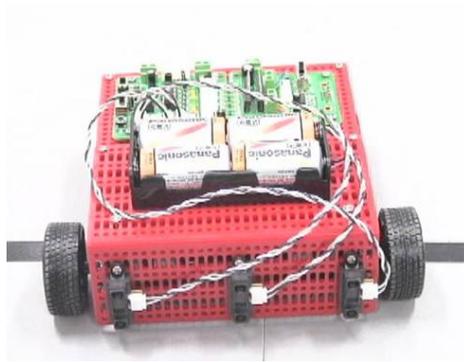


図 1 ROBO DESIGNER の外観
Fig. 1 External View of ROBO DESIGNER

```
$$$: センサー値  
$d$: 閾値$(=100)$  
ObjectDetection($d$):  
センサー値を取得し, $d$に応じてセンサー値を評価し  
物体の検知を True or False で返す関数  
loop  
if ObjectDetection$(d)$ then  
while LeftObjectDetection$(d)==$ True do  
  右回転  
end while  
else if  
while RightObjectDetection$(d)==$ True do  
  左回転  
end while  
else  
  直進  
end loop
```

図 2 実験に使用したロボットの擬似コード
Fig. 2 Pseudo code of robots used in experiments

2. データ概要

本研究では, Swarm ロボティクスと呼ばれるローエンドな自律ロボットの軌跡データを扱う. 群ロボットとは, 複数の比較的単純なロボットを使い実環境でさまざまな作業を遂行するための自律ロボットである.

2.1 群ロボット

本研究で扱うロボットの軌跡データは九州大学システム情報科学研究院 鈴木(英)研究室から提供を受けている⁶⁾. 使用されたロボットは JAPAN ROBOTTECH の ROBO DESIGNER^{*1}. このロボットは, 2 輪のタイヤ, モーター, 電池, 制御部, 前面に取り付けた 3 つの測距センサーから構成されている(図 1). 大きさは $21cm \times 21cm$ であり, 通信機能は搭載されていない.

このロボットのとれる行動は事前にプログラムされた直進, 右回転, 左回転である. 各ロボットは, 閾値 θ を定め, 右センサーのセンシング値が閾値を越えれば左回転, 左センサーが閾値を越えれば右回転, そうでなければ直進する.

*1 <http://www.japan-robottech.com/>



図 3 動画から抽出したフレームの例
Fig. 3 Example of frame extracted from dynamic scene

2.2 軌跡データ

軌跡データは, 赤, 青, 緑, 黄の 4 台のロボットが (X, Y) 座標の時系列データを生成する. 実際にロボットは $192cm(W) \times 192cm(H)$ の壁で仕切られたフィールド内を移動する. この様子を USB カメラを用いて, 地面に対し鉛直方向斜め約 45° の角度から撮影している(図 3). $320(W) \times 240(H)$ の解像度のカメラ画像に $0 \leq x \leq 240, 0 \leq y \leq 240$ の射影変換を行った. 撮影された動画のフレームレートは 20fps (1 秒間に 20 フレーム撮影)である. また, ロボットの位置については色に基づく画像処理を行っている. ロボットに 4 色の彩色を施し, エッジの重心をそのロボットの整数座標として画像処理により抽出する. ロボットの形状の非対称性により, 前進以外の行動, 例えば回転でも位置座標が変化する. 画像処理によって得られたロボットの位置座標は方向転換によって移動する. 本研究では, 異なる初期配置から図 2 のプログラムを試行した P3C2, C3 の 2 つのデータを使用した.

2.3 異常行動

この 4 台のロボットのうち青いロボットには異常行動とみられる行動が確認された(図 5). 以下この行動を Wobble と呼ぶ. この Wobble は, ロボットが角の近くで左右の回転を交互に繰り返す状態である. またこの Wobble の周期は約 1 秒 (20 フレーム) ほどであった.

2.4 部分系列集合

ロボットの座標を x とし, その長さ T の時系列を X とする.

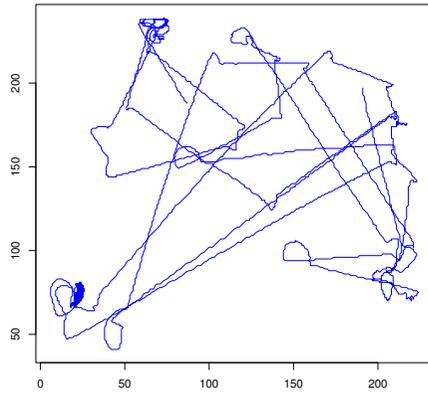


図 4 異常行動を含むロボットの軌跡
Fig. 4 Trajectory of the robot that with an unusual behavior

$$X = [\mathbf{x}(t)]_{t=1}^T \quad (1)$$

ある時刻の時間間隔 l から速度ベクトル $\mathbf{v}(t)$ 求め、速度絶対値 $v(t)$ とする。

$$\mathbf{v}^l(t) = \frac{1}{l} \sum_{i=0}^{l-1} \mathbf{x}_{t+i} - \frac{1}{l} \sum_{i=1}^l \mathbf{x}_{t-i} \quad (2)$$

$$v^l(t) = |\mathbf{v}(t)| \quad (3)$$

速度絶対値 $v(t)$ のウィンドウサイズ w の部分系列 s 、その個数を N とし、部分系列 s の集合 S を次のように定義する。

$$s_i = (v(t))_{t=i}^{i+w-1} \quad (4)$$

$$S_{w,l} = [s_i]_{i=1}^N \quad (5)$$

$l \in \{2, 10, 50\}$ と変えた場合の時系列の一部を図 6 に示す。時間間隔 l が小さいと微小な振幅の影響を受けてしまい、大きすぎると平滑化が強すぎて行動の特徴が失われてしまうことがわかる。

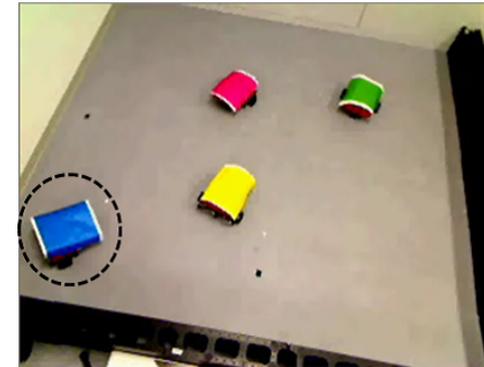
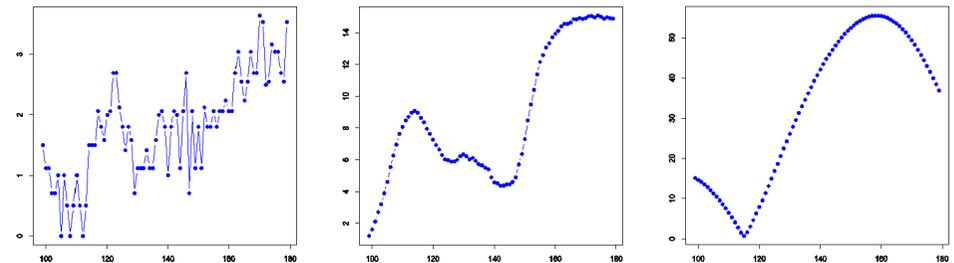


図 5 異常行動が発生しているフレーム
Fig. 5 An example of an unusual behavior
点線で囲んだ部分が異常行動 (Wobble) を起こした青ロボットである



(a) $l = 2$ (b) $l = 10$ (c) $l = 50$

図 6 異なる時間間隔 l を用いた場合の時系列のプロット (フレーム 100-180)

Fig. 6 Plot of the input time series using different l

3. 手法の構成

時間の概念を含む特徴量では時間間隔 l を変えるとその特徴が変化する。ウィンドウサイズ w を大きく取ると次元数が増え、クラスタリング、異常検出が困難になってしまう。本

研究では、人が動画を見て Wobble と判断したフレームに Wobble ラベルを付与し、これを抽出できるような手法を行う。また、ロボットの速度の系列について着目する。

3.1 部分空間での異常系列クラスタの検出

$w = w_0, l = l_0$ としたとき、ラベルが未知の速度部分系列集合を S_{w_0, l_0} 、異常を含まない速度部分系列集合を Q_{w_0, l_0} とする。以下のように K 平均法を用いて l_0 を用いた場合の異常クラスタを検出し、ラベルを付ける。

- S_{w_0, l_0} を K 平均法で k 個のクラスタの代表点 $\{s_i\}_{i=1}^k$ に割り当てる。
- 得られた代表点を用いて、 Q_{w_0, l_0} を最近傍のクラスタ代表点に割り当てる。

ここでわれわれは、 S_{w_0, l_0} においてクラスタに属する系列の割合よりも Q_{w_0, l_0} における割合が大きく減少したときにそのクラスタに属する S_{w_0, l_0} の系列を異常とみなす。具体的には、

- S_{w_0, l_0} での系列の数が $N/2k$ 以上。
- Q_{w_0, l_0} での割合が S_{w_0, l_0} の $1/2$ 以下。

この条件を満たしたクラスタを異常クラスタとみなす。ここでは、 $N/2k$ 個以上のまとまった異常部分系列をおおまかに検出することが目標である。

3.2 メタ特徴量の生成とクラスタリング

$(w_p, l_q) : p \in \{1, 2, \dots, \lambda_w\}, q \in \{1, 2, \dots, \lambda_l\}$ について上の手順で異常クラスタを検出し、その集合を C とする。各クラスタ $c_j \in C$ についてバイナリベクトル \mathbf{b}_j を次のように定義する。

$$\mathbf{b}_j = (b_1, b_2, \dots, b_N) \quad (6)$$

$$b_i = \begin{cases} 1 & \text{if } s_i \in c_j \\ 0 & \text{otherwise} \end{cases} \quad (7)$$

メタ特徴行列 B を次のように定義する。

$$B = \begin{bmatrix} \mathbf{b}_1 \\ \vdots \\ \mathbf{b}_M \end{bmatrix}^T \quad (8)$$

ただし、 M は異常と判定されたクラスタの数である。このとき各時系列は M 次元のバイナリベクトルで表される。

メタ特徴量 B として表された部分系列集合を再度 K 平均法を用いてクラスタリングする。クラスタの数は k^* とする。

4. 実験

4.1 設定

利用するデータは P3C2, C3 の 2 種類である。各データの青ロボット、赤ロボットの軌跡から未知の部分系列集合に青ロボット、正常な部分系列集合に赤ロボットの系列を与える。データ P3C2 では、赤ロボット、青ロボットともに時系列の長さは 4122 フレーム (3 分 30 秒) P3C3 は 4677 フレーム (3 分 54 秒) である。マニュアル (人が動画を見て) で付けた青ロボットの Wobble ラベルの数は P3C2 では 1281 フレーム (1 分 4 秒)、P3C3 では 580 フレーム (29 秒) である。 $l \in \{2, 5, 10, 20\}, w \in \{2, 5, 10, 20\}$ の組み合わせから 16 個の部分系列集合を生成した。時系列データから動画で約 15 秒以上含まれている異常行動を検出するため、 $k = 7, k^* = 2$ とした。

4.2 評価方法

提案手法で得られたクラスタ中の Wobble ラベルの割合を精度、Wobble ラベルのうちクラスタに含まれる割合を感度とする。精度・感度の高い方のクラスタの値を評価する。提案手法は負例のみを用いる半教師付きクラスタリングを用いる手法である。既存の手法では、このような入出力を持つ適当な比較対象がないので本研究では教師付き学習である SVM と比較して性能を評価する。SVM の入力には全ての (l, w) の組合せでの部分系列を結合した 80 次元の特徴ベクトルとした。青ロボットの Wobble ラベルの付いたフレームのうち、SVM に訓練データとして与える異常サンプルの割合を R とする。訓練データは、赤ロボットの部分系列集合と R を変えた部分系列集合とし、青ロボットの残りの部分系列集合をテストデータとする。SVM の実装は、libSVM、線形カーネル、次数 3、 $\epsilon = 0.001$ を用いた。

4.3 結果

3.1 節のルールによって異常と判断したクラスタにラベル付けを行った。表 1 に $l = 10, w = 10$ の場合の例を示す。各行は、クラスタ毎に含まれる青ロボット、赤ロボット及び Wobble ラベルの部分系列の個数である。異常と判断されたクラスタのラベルを P 、そうでないクラスタは N とした。実際の異常クラスタの判断をデータ P3C2 の $l = 10, w = 10$ の場合を例に説明する。この例では、Cluster4, 5, 6 が異常クラスタと判断され、それに属する部分系列に P のラベルを付けた。しかし、Cluster5 のように Wobble をあまり含んでいないクラスタも異常クラスタと判定されていることがわかる。

提案手法と SVM の精度・感度を表 2, 表 3 に示す。提案手法は正例を用いない半教師付き学習なので SVM よりも精度は小さい。SVM との感度の比較を図 10, 図 11 に示した。

表 1 異常クラスタの判定の例.P3C2. $l = 10, w = 10$
Table 1 Example of judging unusual cluster.P3C2. $l = 10, w = 10$

Cluster	青	赤	Wobble	ラベル
0	315	2355	4	N
1	735	426	14	N
2	283	305	22	N
3	407	385	18	N
4	864	189	592	P
5	611	268	14	P
6	877	164	617	P

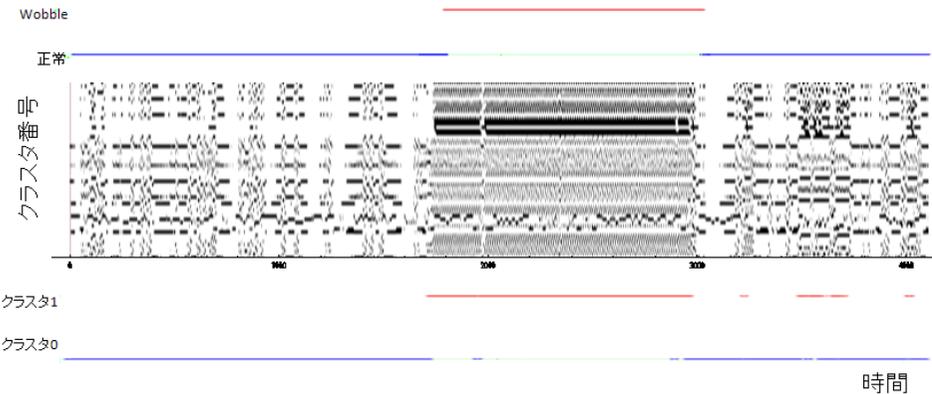


図 7 P3C2 から得られたメタ特徴行列 B およびクラスタラベル
Fig. 7 Meta feature procession B and cluster label obtained from P3C2

異常サンプルが P3C2 において 200 フレーム ($R = 0.158$) 以下, P3C3 では 400 フレーム ($R = 0.686$) 以下の場合, 提案手法の感度は SVM より高い.

図 7 に P3C2 から得られたメタ特徴行列とそのクラスタリング結果を示す. メタ特徴行列は横軸が部分系列の番号, 縦軸がクラスタの番号に対応する. 行列プロットとして表している. 部分系列がクラスタに属する場合は対応する領域を黒, そうでない場合は白く塗りつぶして表示している. 図上部の赤・青線は縦方向に対応する部分系列を人が判断してそれぞれ異常・正常と判断したことを示す. 図下部の赤・青線は縦方向に対応する部分系列がそれぞれクラスタ 0, クラスタ 1 に属することを示す. 同様に図 8 は P3C3 の結果である.

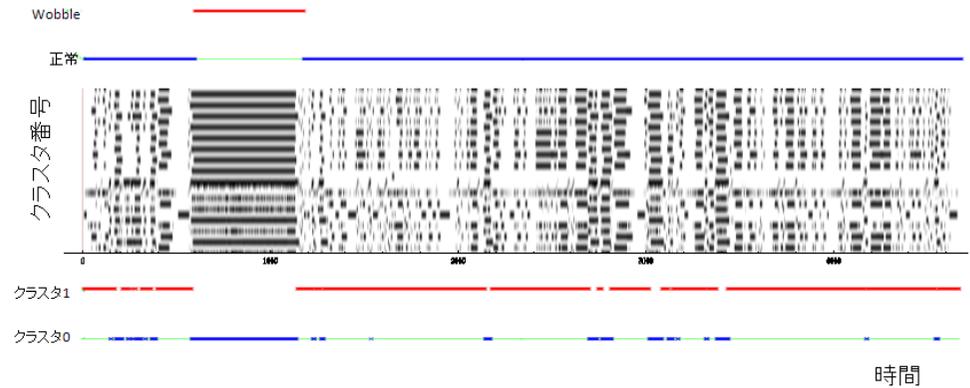


図 8 P3C3 から得られたメタ特徴行列 B およびクラスタラベル
Fig. 8 Meta feature procession B and cluster label obtained from P3C3

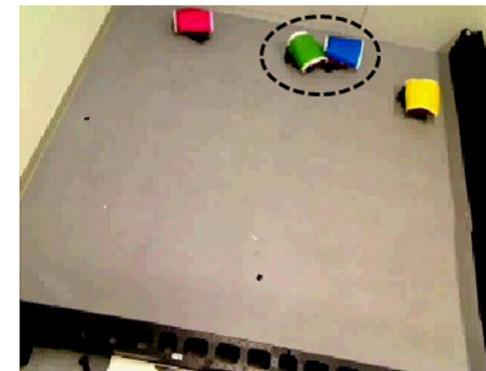


図 9 P3C3 から検出された Wobble とは異なる異常行動の例
Fig. 9 An example of unusual behaviors detected from P3C3 data that is not Wobble

図 7 では 2000 前後の部分系列が真陰性となっている. これはロボットが Wobble しながらも前進したところであった. また, 3000 以降に偽陽性が見られるが, これは Wobble に類似した行動をロボットが起こしていた. 図 8 では偽陽性が多く見られる. 動画を確認したところ, 短い時間ながら Wobble に類似した動作が見られることが分かった. また, Wobble 以外にも図 9 のように別のロボットと接触し, 前進が妨げられる異常行動を検出した.

表 2 データ P3C2 での提案手法と SVM の精度と感度

Table 2 Precision and Recall of proposal technique and SVM in data P3C2

	SVM						提案手法
	R	0.015	0.031	0.063	0.079	0.158	
精度	0.972	0.957	0.935	0.925	0.899	0.860	0.887
感度	0.788	0.828	0.878	0.894	0.924	0.944	0.929

表 3 データ P3C3 での提案手法と SVM の精度と感度

Table 3 Precision and Recall of proposal technique and SVM in data P3C3

	SVM						提案手法
	R	0.034	0.068	0.137	0.172	0.348	
精度	0.791	0.743	0.765	0.743	0.672	0.499	0.523
感度	0.904	0.907	0.907	0.911	0.906	0.943	0.959

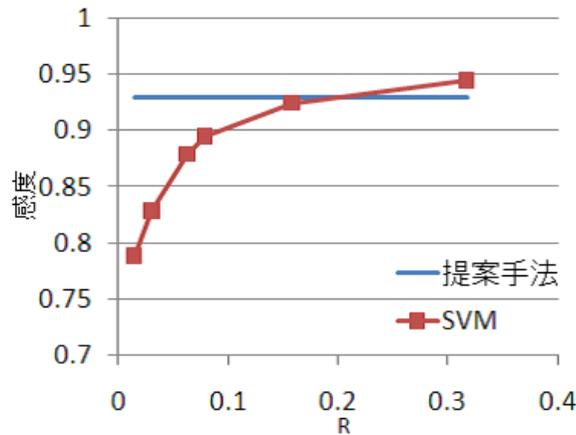


図 10 P3C2 での提案手法と SVM の感度の比較

Fig. 10 The proposal technique and SVM in P3C2 are compared by recall

また、クラスタリング結果を正規化相互情報量 (NMI)⁷⁾ を用いて評価する。K 平均法を SVM と同様の 80 次元の特徴ベクトルに適用した結果 NMI は 0.256 であったのに対し、提案手法は 0.657 であった。また、P3C3 ではそれぞれ 0.236, 0.504 であった。この結果からメタ特徴量を用いることで異常行動と正常な行動が分割されやすくなったといえる。

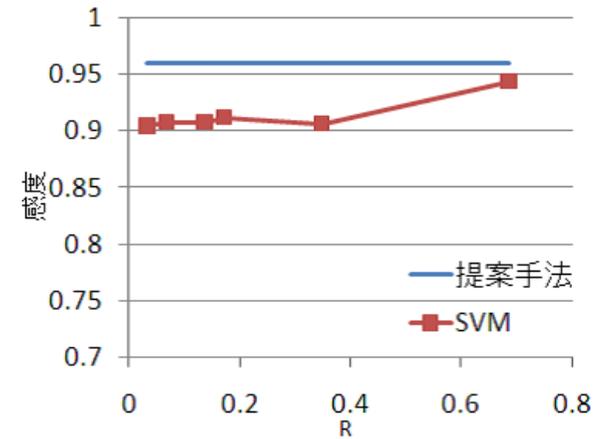


図 11 P3C3 での提案手法と SVM の感度の比較

Fig. 11 The proposal technique and SVM in P3C2 are compared by recall

5. おわりに

本研究では、ロボットの異常行動検出のためにクラスタリング結果をアンサンブルする手法を提案した。実験では実際にロボットの動きを観測した 2 種類のデータを用いて異常行動を検出することを考えた。結果、おおまかにパラメータを指定するのみで高い精度と感度で異常行動を検出できた。また、対象とする部分系列集合に異常行動が含まれていない場合、部分系列集合での異常検出で異常クラスタのラベルが付かないため、2 段階目を省略して偽陽性検出を避けることが考えられる。

軌跡データからは速さ以外にも各ロボットとの相互距離や壁との距離などの特徴を得ることを考えられるが、速さに着目したことによってフィールドの大きさにかかわらず異常を見つける可能性があり、ロボット自身でも観測できるため実機に載せられる可能性も考えられる。

参考文献

- 1) Trajectory-Based Anomalous Event Detection, Piciarelli, C. Micheloni, C. Foresti, G.L. :Trajectory-Based Anomalous Event Detection, IEEE Trans. on Circuits and

- Systems for Video Technology, Vol.18 , No.11, pp.1544-1554, (2008) .
- 2) Dragomir Yankov, Eamonn Keogh, Uma Rabbapragada :Disk aware discord discovery: finding unusual time series in terabyte sized datasets, Knowl. Inf. Syst. 17, No. 2, pp. 241-262, (2008) .
 - 3) 新納浩幸, 佐々木稔 : NFM による重み付きハイパーグラフを用いたアンサンブル文書クラスタリング, 自然言語処理 Vol.13 No.2, pp.1-17. Apr.(2006) .
 - 4) Alexander Strehl ,Joydeep Ghosh : Cluster ensembles a knowledge reuse framework for combining multiple partitions, The Journal of Machine Learning Research archive Volume 3 , table of contents, pp. 583-617 , March. (2003) .
 - 5) Tim Oates : PERUSE: An Unsupervised Algorithm for Finding Recurring Patterns in Time Series, in International Conference on Data Mining, pp. 330-337, (2002) .
 - 6) Einoshin Suzuki, Hiroshi Hirai, Shigeru Takano, Shin Ando : Toward Using Symbolic Discovery in Designing Controllers of Autonomous Swarm Robots, 1st workshop on Learning and Mining from Robots, (2008).
 - 7) Meila, M : Comparing clusterings—an information based distance Journal of Multivariate Analysis, 98, pp. 873-895, (2007) .