

## クラスタリング結果を用いた外れ値検出による、歩行軌跡データからの 行動識別手法

豊嶋伊知郎<sup>†</sup> 服部可奈子<sup>†</sup> 板倉 豊和<sup>†</sup> 榎原 孝明<sup>††</sup> 馬場 賢二<sup>††</sup>  
折原 良平<sup>†</sup>

<sup>†</sup> 株式会社 東芝 研究開発センター システム技術ラボラトリー  
〒 212-8582 川崎市幸区小向東芝町 1

<sup>††</sup> 株式会社 東芝 電力・社会システム技術開発センター 制御・ネットワークシステム開発部  
〒 183-8511 東京都府中市東芝町 1

E-mail:

{ichiro.toyoshima,kanako.hattori,toyokazu.itakura,takaaki.enohara,kenji2.baba,ryohei.oriyara}@toshiba.co.jp

**あらまし** 安全意識の高まりを受けて、サーベイランスシステムの需要が高まりつつある。一方でシステムの増加・巨大化は確認業務の増加を招くことは確実であり、解決のため自動的に問題のある状況を発見するインテリジェントなシステムの研究が行われてきている。逸脱行動などの問題状況を自動的に発見する機能を実現するための課題としては、教師データ不足やモデル化の不可能性が挙げられるが、その解決には外れ値検出法の枠組みが妥当であると考えられている。一般的な外れ値検出手法は、推定対象の分布の単峰性を仮定しているが、このことは歩行軌跡データ等の人間行動データでは成立しにくく、2つ以上の分布が存在する状況に対しても対応可能な仕組みが不可欠である。本報告ではステレオ画像処理により得られた歩行軌跡データを用いた逸脱行動検出問題において、クラスタリングにより分布の状況を事前に把握することが検出率の向上に有効である事実の実験結果を示した後、最適な逸脱行動検出の実現のため、外れ値検出手法の1つである1classSVMのハイパーパラメタ設定方法に関して論ずる。

**キーワード** 行動識別, 逸脱行動検出, 外れ値検出, 1classSVM, クラスタリング

## A Behavior Classification using human trajectories , by detecting outlier method based on Cluster Analysis

Ichiro TOYOSHIMA<sup>†</sup>, Kanako HATTORI<sup>†</sup>, Toyokazu ITAKURA<sup>†</sup>, Takaaki ENOHARA<sup>††</sup>, Kenji  
BABA<sup>††</sup>, and Ryohei ORIHARA<sup>†</sup>

<sup>†</sup> System Engineering Laboratory ,Corporate Research & Development Center,Toshiba Corporation  
1 Komukai Toshiba-cho,Saiwai-ku,Kawasaki city,212-8582,Japan

<sup>††</sup> Control & Network Systems Development Department ,Power and Industrial Systems R&D  
Center,Toshiba Corporation  
1 Toshiba-cho,Fuchu-shi,Tokyo city,183-8511,Japan

E-mail:

{ichiro.toyoshima,kanako.hattori,toyokazu.itakura,takaaki.enohara,kenji2.baba,ryohei.oriyara}@toshiba.co.jp

**Abstract** The demand for surveillance system is increasing. However large surveillance systems force us to verify a vast amount of images. To cope with ,many reseachs of automatic abnormal situation detection are being studied. Outlier detection method is one effective approach for automatic abnormal situation detection. The outlier detection assumes that a dataset is generated from single distribution,which is unlikely for human behavior data. As a consequence , we must deal with the data generated from two or more distributions for accuracy of the detection. In this paper , firstly we show that the effectiveness of grasping struture of distributions.Secondly,we discuss selection of learning parameters for one-class support vector machine.

**Key words** behavior classification,abnormal behavior detection,outlier detection,one-class suppot vector machine,cluster analysis

## 1. はじめに

### 1.1 研究の背景

近年情報とその関連技術の進歩により、安心・安全社会の実現に貢献する要素技術が整いつつある。安心・安全を保障する技術としてはシミュレーション技術・暗号技術・ネットワーク技術などが挙げられる。これらに加えて、実空間での不審者発見技術も発展が期待される技術の一つであり、文部科学省報告書[12]においても「新たに取り組むべき課題」としてリストに上っている。

自動的な特定行動検出機能は、大規模かつ広域なサーベイランスシステムの実現に不可欠の要素技術である。

### 1.2 行動検出技術の要件

不審者発見に代表される特定行動検出技術は、具体的にはセンサから得たデータを用いた機械学習問題として実現される。以下は機械学習の立場から特定行動検出の課題を整理したものである。

#### ● 教師データの不在

検出対象である特定行動のデータは「通常の」行動に比して事例数が寡少であり、学習に十分な一定数を確保することは困難である。また仮にそのようなデータが存在していた場合でもプライバシー等の法的制限から使用できない場合が多い。

#### ● 現象記述の不可能性

特定行動が何らかの知見によってモデル化できる場合、そのモデルを利用してその行動の検出を行うことが考えられる。しかし問題のある行動の種類は人間の想定を超えて無数に存在するため、モデルの枠組みに収まらない、検出されるべき行動が存在することは容易に想像できる。

上記の課題の対策としては「通常」とみなされるデータ集合の特徴を推定し、そこから逸脱しているものを検出する**外れ値検出**の枠組みを用いることが一般的である<sup>(注1)</sup>

南里ら[10]は部分空間法を用いており、正常とされるデータの部分空間からの距離により逸脱行動を定義している。また鈴木ら[15]は行動パターンを隠れマルコフモデルでモデル化し、該当モデルの生起確率が低いデータを逸脱行動として定義している。

## 2. 外れ値検出手法の課題

### 2.1 サーベイランスシステムの試作

我々はインテリジェントなサーベイランスシステムの実現を目的とし、ステレオ画像処理により得られた歩行軌跡データを用いた逸脱行動検出システムの試作を行っている。図1はそのイメージである。

行動識別手法としては、Support Vector Machine の一種で

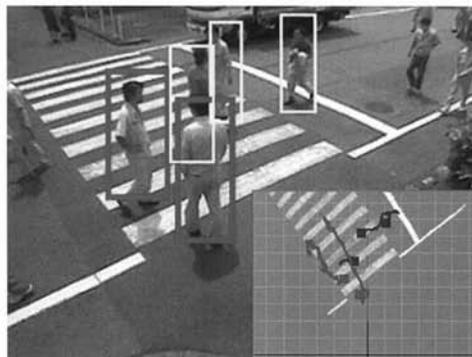


図1 サーベイランスシステムイメージ

ある one-class Support Vector Machine(1classSVM) を用いている。1classSVM は入力データの高密度領域の境界面を得る機械学習手法であり、学習結果の境界面を利用することで外れ値検出に応用される。

### 2.2 高密度領域推定手法の課題

1classSVM に代表される高密度領域推定手法は一般に、対象とするデータが単一の確率分布から生成されるという仮定を持っており、その仮定が妥当な問題であれば一定の性能をあげることが可能である[9]。しかし実空間での人間の行動について考えた場合、とりわけ行動の自由度の高い場面においてはこの仮定は成立せず、2つ以上の凝集を持ったデータが出現することが想定される。

逸脱行動検出問題として考えた場合、2つの分布を1つの分布とみなして学習することは、本来両分布から見て外れ値であるはずの、幾何学的には両分布の中間に存在するデータを尤度の高いデータとして誤識別してしまうことに相当する。図2は通常の外れ値検出手法の問題点を直観的に示したものである。

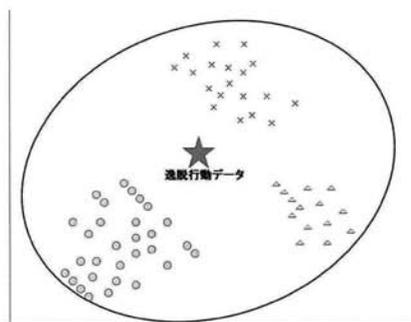


図2 通常の高密度領域推定手法の問題のイメージ

我々は学習データ中の分布の構造を把握することで、最適な外れ値検出精度を実現することを目指しており、本報告はその枠組みと手法の逸脱行動検出問題での有効性の検証である。

(注1)：本報告においても以後、検出目的の行動を**逸脱行動**と呼び、区別のためそれ以外の大部分を占める行動を**通常行動**とよぶ。

### 2.3 適応的外れ値検出手法

我々の提案する適応的外れ値検出手法は 1classSVM の学習に、クラスタリングによる前処理を追加することで実現される。以下はそのプロセスである。

#### (1) クラスタリングによる分布構造の把握

学習データに対してクラスタリングアルゴリズムを適用し、距離・構成数などの一定基準を満たすクラスターを発見する。

#### (2) クラスターごとの 1classSVM による学習

発見された各クラスターごとに 1classSVM による学習を行い、それぞれの識別関数を得る。

未知データに対する識別結果は、(2)の各識別器による識別結果を統合することで得られる。具体的には全ての識別器により外れ値と識別されたものを最終的な外れ値として出力する。図 3 は提案手法のイメージ図である。

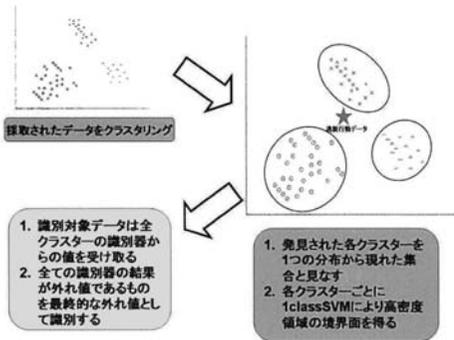


図3 適応的外れ値検出手法の仕組み

本手法の仕組みは、システムの汎用性の面からも有用である。一般に機械学習問題では特徴抽出が課題となるが、逸脱行動検出問題では最適性の基準を設定することは困難である。人の行動は多様であり、システムが設置される場によって行動のトレンドや逸脱の定義は千差万別であるからである。

本手法は任意の特徴量について適応的に外れ値検出精度を向上させることが可能であり、特徴選択の困難性に対する対策の一つと成りうるものである。

### 3. 使用データ

#### 3.1 サーベイランスシステム

本章では行動識別に使用するデータについて具体的に述べる。以下は前出のサーベイランスシステム全体の処理手順であり、図 4 は、直観的な図示である。

##### (1) 歩行軌跡データの抽出

ステレオ画像処理を用いて画面内人物の歩行軌跡データを抽出する。

##### (2) 基本行動量ベクトルの計算

抽出した歩行軌跡データから、後述のアルゴリズムより特徴

量として基本行動量ベクトルを計算する。

##### (3) 1classSVM による行動識別

識別対象の基本行動量ベクトルについて、識別関数を用いて外れ値か否かを判定する。

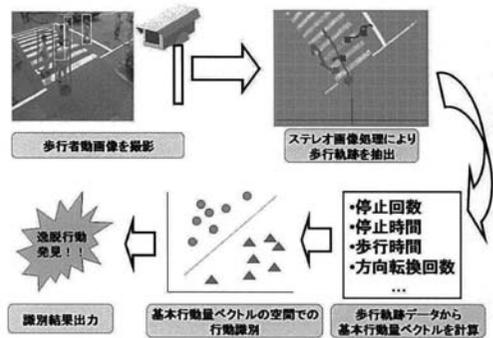


図4 本システムのデータフロー図

本報告でのクラスタリング及び 1classSVM の学習に使用するデータは (2) で計算された基本行動量ベクトルの集合である。

#### 3.2 歩行軌跡データの抽出方法

本報告では、東芝電力・社会システム技術開発センターにて開発されたステレオ画像処理人流計測システム [11] を用いて収集した歩行軌跡データを使用した。

歩行軌跡データ抽出までの画像処理のプロセスを以下に示す。

- (1) リバースマッチングによる人間候補領域の獲得
- (2) DBSCAN による人間抽出
- (3) 高次特徴量による連続性獲得

(3) の高次特徴量は以下の値を用いる。

- 2次元位置、テクスチャ
- 3次元位置、3次元速さ、3次元移動方向
- 存在時間

本手法ではステレオ画像処理の利点である3次元情報を用いているため、人や物の重なりに強い耐隠蔽特性を持つ。この特性は複数人数が存在する状況であっても安定した追跡を可能にするため、将来的な需要として単一の歩行軌跡ではなく場面ごとの状況識別を行う際、必要な複数人の歩行軌跡データを少ない誤差で収集することが可能である。

図 5, 6 では、入力画像中で他人による隠蔽が発生した場合でも安定して歩行軌跡データを抽出する性能が確認できる。

#### 3.3 基本行動量ベクトル

我々は [13] で歩行軌跡データからの特徴量計算手法である基本行動量ベクトル計算法を提案した。本報告においても、これらの手法を用いて特徴量計算を行う。基本行動量ベクトルの形

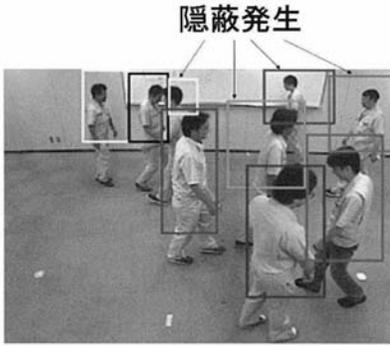


図5 隠蔽発生状況

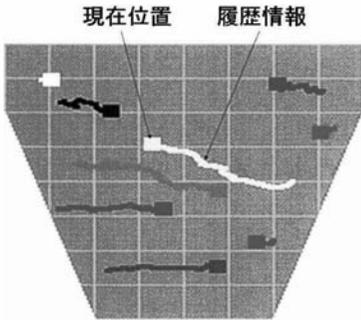


図6 歩行軌跡データ抽出状況

式的な定義の一部を以下に再掲する。

### 3.3.1 前提となる観測量

本節では歩行軌跡の定義と、後の計算に必要な前処理について述べる。

以下では  $N$  は軌跡データの総時点数、 $FPS$  を1秒あたりの時点数とする。 $F$  は時点間の時間であり、 $F = 1/FPS$  で計算される。

### 定義 歩行軌跡

歩行軌跡は基本行動判別への入力データであり、一名の人間の位置座標を各時点ごとに記録した  $R^2$  ベクトルの列である。歩行軌跡  $T$  の形式的な定義を以下で与える。

$$T = \{t_1, t_2, \dots, t_{N-1}, t_N\}, (t_i = (t_i^{(x)}, t_i^{(y)})) \quad (1)$$

$t_i^{(x)}, t_i^{(y)}$  はそれぞれ  $i$  番目の時点における観測対象者の  $x$  座標および  $y$  座標である。

### 定義 方向ベクトル列

方向ベクトル列  $V$  は、歩行軌跡より各時点間の方向ベクトルを計算することによって得られる  $R^2$  ベクトルの列である。

$$V = \{v_1, v_2, \dots, v_{N-2}, v_{N-1}\}, (v_i = t_{i+1} - t_i) \quad (2)$$

### 定義 ノルム列

ノルム列  $D$  は、方向ベクトル列の各要素のノルムを計算することによって得られるスカラー列である。

$$D = \{d_1, d_2, \dots, d_{N-2}, d_{N-1}\}, (d_i = |v_i|) \quad (3)$$

### 3.3.2 基本行動判別及び基本行動量計算

本節では基本行動判別及び、それに基づく基本行動量の計算方法を述べる。基本行動および基本行動量ベクトルは現時点では非常にシンプルかつ直観的な方法で計算される。

基本行動は各時点間に対してラベル付けされる。各基本行動の判別結果は  $N-1$  または  $N-2$  要素の列を作る。

### 定義 停止行動列

停止行動列  $S = \{s_1, s_2, \dots, s_{N-1}\}$  は以下で定義される。直感的には、その時点で停止していれば1、停止していなければ0である。停止行動列の各要素  $s_i$  の定義を以下で与える。 $Th_1$  は停止行動と歩行行動を分割する閾値であり、別途収集した行動データから推定された線形判別関数により決定される。

$$s_i = \begin{cases} 1 & \forall k, d_{i+k} < Th_1 \quad (|k| < FPS) \\ 0 & otherwise \end{cases} \quad (4)$$

$s_i$  を停止状態と判定する基準は、当該時点間のノルム  $d_i$  が  $Th_1$  を下回るだけでなく、前後1秒間の全ての時点間も  $Th_1$  を超えないことを判定の条件としている。上記定義に基づいて計算された停止行動列  $S$  により、基本行動量の停止時間  $ST$  および停止回数  $SE$  を求めることができる。

$$ST = F * \sum_{k=1}^{N-1} s_k \quad (5)$$

$SE$  は、 $s_i = 1$  である連続系列の個数をカウントすることで求められる。

### 定義 歩行行動列

歩行行動列  $W = \{w_1, w_2, \dots, w_{N-1}\}$  は以下で与えられる。また閾値  $Th_2$  は歩行状態と走行状態を分割する閾値であり、 $Th_1$  と同様の方法または、歩行速度の分布の外れ値基準を設定することで決定される。

$$w_i = \begin{cases} 1 & (d_i < Th_2) \wedge (s_i \neq 1) \\ 0 & otherwise \end{cases} \quad (6)$$

歩行行動列  $W$  に基づいて、 $ST$  と同様の方法で、歩行時間  $WT$  も求められる。

### 定義 走行行動列

走行行動列  $R = \{r_1, r_2, \dots, r_{N-1}\}$  は以下で与えられる。

$$r_i = \begin{cases} 1 & (s_i \neq 1) \wedge (w_i \neq 1) \\ 0 & otherwise \end{cases} \quad (7)$$

走行行動列  $W$  にもとづいて、 $ST, WT$  と同様の方法で歩行時間  $RT$  も求められる。

### 定義 方向転換行動列

方向転換行動列  $C = \{c_1, c_2, \dots, c_{N-2}\}$  は以下で与えられる。

$$c_i = \begin{cases} 1 & \cos\theta < 0 \\ 0 & \text{otherwise} \end{cases} \quad (8)$$

$\cos\theta$  は  $v_i$  と  $v_{i+1}$  から決定される両ベクトルのなす角である。方向転換行動列  $C$  にもとづいて、 $SE$  と同様の方法で方向転換回数  $CDT$  も求められる。

以上の処理により、歩行軌跡データ  $T$  は基本行動量ベクトル  $PV_T$  に写像される。上記の基本行動量及び、角度変化量総和  $ARG$ 、角度変化量絶対値総和  $AbsARG$  により構成される基本行動量ベクトル  $PV_T = (ST, SE, WT, RT, CDT, ARG, AbsARG)$  により張られる特徴空間において、該当軌跡データの行動判別を行う。

### 3.4 歩行軌跡と基本行動量の有効性

我々は本研究に先立って、仮想店舗における買物行動演技データを使用して歩行軌跡データの行動識別能力について実験を行い、決定木による分析を行った [13]。図 7 は、仮想店舗の見取図と歩行軌跡データのサンプル<sup>(注2)</sup>である。

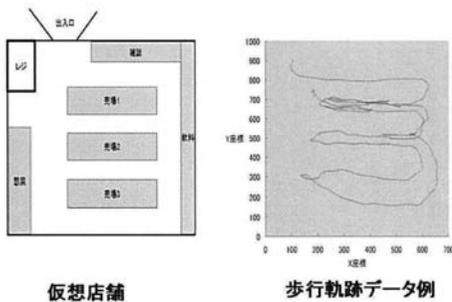


図 7 仮想店舗と歩行軌跡データサンプル

識別対象とした買物行動は下記の 3 種類である。

- 迷走行動
- 購買検討行動
- その他行動

図 8 に決定木による解析結果を示す。

迷走行動と購買検討行動が線型分離可能であることなどの知見を得たが、演技データのためこの結果を一般化することは困難ではある。しかし特定の状態において基本行動量ベクトルデータの分布に偏りが発生すること、それにより歩行軌跡デ

(注2)：該当軌跡データは擬似ステレオ視による色追跡手法によって得られたものであり、本報告のステレオ画像処理システムによって得られたものではない。

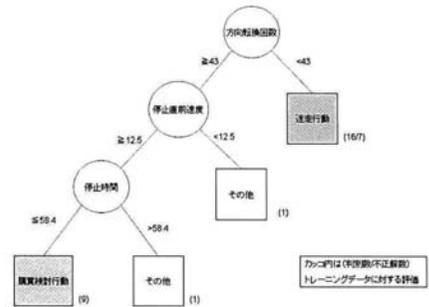


図 8 買物行動データに対する決定木の学習結果

ータを用いた行動識別が可能であることは確認されたと考えている。

## 4. 実験結果

本章では提案手法である適応的外れ値検出手法の有効性を確認するための実験とその検証結果について述べる。

### 4.1 データ収集状況

当社事業場内の屋外通路に前記ステレオ画像処理システムを設置し一定時間の一般通行者の歩行軌跡データを収集した。またシナリオ演技により 4 名の逸脱行動者の歩行軌跡データも同時に収集した。

### 4.2 問題設定

前節の実験で収集された歩行軌跡データから基本行動量ベクトルを計算する。各歩行軌跡データの先頭から 2 秒を 1 単位として基本行動量ベクトルを計算する。終端が 2 秒に満たない場合は切り捨てるものとする。6.5 秒間の歩行軌跡データの場合、得られる基本行動量ベクトルのデータ数は 3 レコードである。

得られた基本行動量ベクトルの集合に対して提案手法を適用する。学習対象データは通常行動データと逸脱行動データとともに含むものとする。これは、実運用環境では現実には逸脱行動データを取り除いて学習させることは困難であることを考慮した設定である。

### 4.3 クラスタリング結果

歩行軌跡データから得られた基本行動量ベクトル群に対して主成分分析を行い第一及び第二主成分得点に変換する。図 9 は正規化した基本行動量ベクトルデータの分散共分散行列の固有値である。

第二主成分までの合計寄与度が 0.7 を下回っており、情報損失が懸念される結果ではあるが以下のように良好なクラスタリング結果を得た。

第一及び第二主成分軸上の 2 次元データに対して、最短距離法によるボトムアップクラスタリングを行い表 1 の 2 つのクラスターを発見した。最短距離方の閾値は 0.4 とした。また全レ

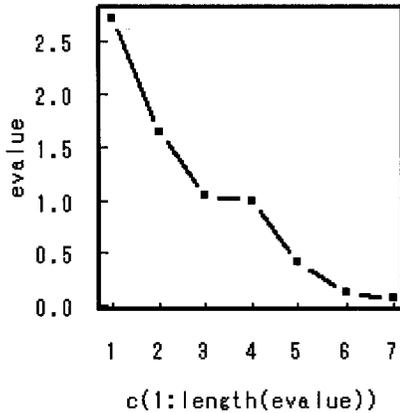


図9 基本行動量ベクトルデータの分散共分散行列の固有値

表1 クラスタリング結果

クラスター名	データ数	級内分散
C1	2234	1.024
C2	18	0.389

コード数は 2314 レコードである。また図 10 はクラスタリング結果を反映した通常行動データと逸脱行動データのプロットである。

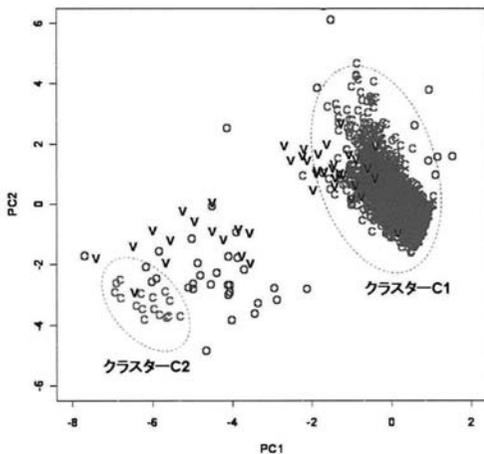


図 10 通常行動データと逸脱行動データのプロット。  
C:発見クラスターに含まれる「通常行動」データ。O:発見クラスターに含まれない「通常行動」データ。V:「逸脱行動」データ  
点線部は視認補助用に追加

#### 4.4 検出精度比較

クラスタリング結果を利用して、各群ごとに外れ値検出を行った結果と、全データを一群分布と見なした場合の外れ値検出の

表2 全学習データから得られた 1classSVM による逸脱行動検出結果

逸脱行動データ数	検出数	検出率
42	24	57 %

表3 提案手法による逸脱行動検出結果

	逸脱行動データ数	検出数	検出率
C1SVM	42	33	79 %
C2SVM	42	41	98 %
最終結果	42	32	76 %

精度を比較する。検出に用いるデータは、前出の 4 つの逸脱行動の歩行軌跡データから計算された 42 レコードの基本行動量ベクトルデータである。表 2 は通常の 1classSVM による逸脱行動検出結果である。学習に用いたパラメータは  $\nu = 0.05, \sigma = 2.0$  である。

また表 3 は提案手法による検出結果である。C1SVM, C2SVM はいずれも各クラスターから学習された 1classSVM による逸脱行動データの検出結果である。学習に用いたパラメータは両 SVM とともに通常手法と同様に  $\nu = 0.05, \sigma = 2.0$  である。通常手法に比べて 19% の精度向上が確認されている。

また図 11 に逸脱行動の歩行軌跡データの例を示す。提案手法の検出能力の高さを直感的に確認できる。

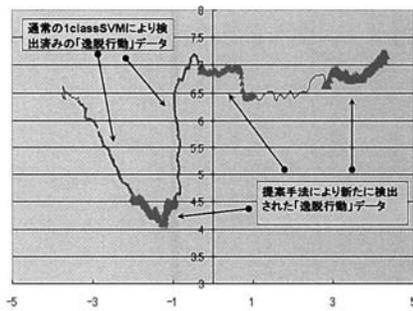


図 11 逸脱行動歩行軌跡例と提案手法による識別結果

## 5. one-class SVM のモデル選択

### 5.1 one-class SVM の概要

我々は構造特定の困難な人間行動データの分布に対する学習方法として 1classSVM が非線型性・制御可能性の点から有効であると考えている。1classSVM は、特徴空間の原点を一つのクラスと見なした  $\nu$ SVM の特別な場合であり、学習結果として得られる非線形識別関数は、 $x$  を識別対象データ、各  $x_i$  を学習データ、 $x_B$  を識別面上データ、各  $\alpha$  をパラメータとすると以下で与えられる [1] [7]。

$$f(x) = \sum_{i=1}^n \alpha_i k(x_i, x) - \sum_{i=1}^n \alpha_i k(x_i, x_B) \quad (9)$$

また  $k(x_i, x_j)$  はカーネル関数であり、1classSVM では以下の RBF カーネルを用いることが一般的である。

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right) \quad (10)$$

1classSVM は入力空間での外れ値が、識別関数の値を負にするように設計されている。  $k(x_i, x_j)$  が RBF カーネルとすると外れ値が  $x$  の場合、任意の  $i$  に対して  $k(x_i, x)$  は 0 に近づく。結果として式 (9) の第一項が 0 に近づくことと第二項が正の値であることから式 (9) 自体は負の値となる。

SVM の各バリエーションではカーネルの選択が課題となるが 1classSVM においては上の特徴を満たすカーネルを用いる必要がある。

1classSVM の学習アルゴリズムは、以下の二次計画問題として定式化される。

$$\begin{aligned} & \underset{\alpha}{\text{minimize}} \quad \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j k(x_i, x_j) \quad (11) \\ & \text{subject to} \quad 0 \leq \alpha_i \leq \frac{1}{\nu n}, \sum_{i=1}^n \alpha_i = 1 \end{aligned}$$

$\nu$  パラメータは学習結果の識別面の外側に、どれだけ学習データの存在を許容するかをコントロールするハイパーパラメータであり (0, 1] の範囲の値を取る。また RBF カーネルは事前に  $\sigma$  の値を設定する必要があり、 $\nu$  と合わせて学習結果に影響を与える要素である。

## 5.2 モデル選択への試み

前項のとおり、1classSVM の学習においては  $\nu$  および  $\sigma$  が重要な役割を果たす。  $\nu$  の学習結果との関連については、理論的解析も進んでおり [7] 直観的には外れ点割合の調整という説明が可能である。

$\sigma$  の学習結果との関係については詳細な理論的結果は少ない。以下に  $\sigma$  の値が学習結果に影響する事実を確認するため、人工データによる直観的な例を示す。使用したデータは 2 つの 2 次元正規分布であり、分散共分散行列は対角成分が 0.03 の対角行列である。図 12 に見るように、  $\sigma$  の値が大きい場合、  $k(x_i, x_j)$  の値は外れ値に対して鈍感であり識別面は単一の凸包を構成するが、逆に図 13 のように値が極度に小さな場合は、外れ値となる空間が増大し 2 個の非連結な空間に分割されている。

このように 1classSVM の学習では  $\sigma$  の値により識別面の構造が大きく変化するため、これを最適に制御することが外れ値検出精度の向上と誤検出の低減には必須であると考えられる。  $\sigma$  の最適化に関する先行研究として [4] ではベアリングの振動データを用いて実験的アプローチを行い、所定の  $\nu$  に対して  $\sigma = 1 - \nu$  とすることで最適な精度を実現しており、一つの指針としては有効である。一方で特定データに基づく結果であり、逸脱行動検出問題に適用するには不確実な要素も多い。

我々 1classSVM の学習問題においてデータから推測される分布の内、入力空間での連結を維持しつつ測度が最小のものを選択することが、逸脱行動検出問題に有効であると考えており、これらの要求を満たす定式化を検討中である。

## 6. 結 論

本報告では逸脱行動検出システムにおける行動識別機能の要

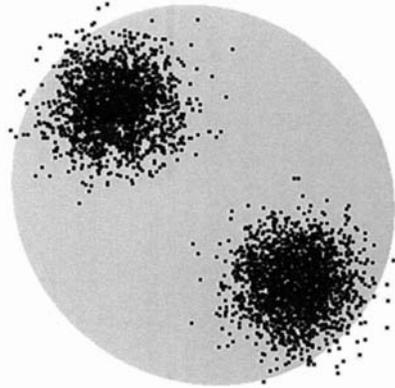


図 12  $\sigma$  の値が大きい場合 ( $\sigma=2.0$ )

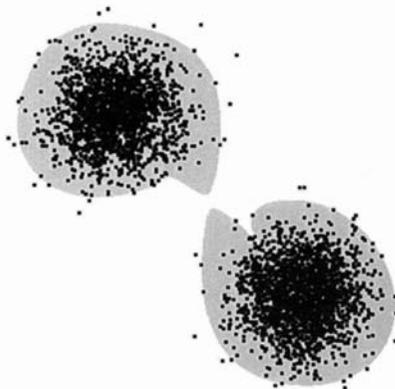


図 13  $\sigma$  の値が小さい場合 ( $\sigma=0.02$ )

件について紹介し、適用手法である外れ値検出手法の課題として分布構造の把握が重要である事実を指摘した。またステレオ画像処理システムから得た歩行軌跡データにクラスタリングを適用することで、クラスタリングを用いない場合よりも逸脱行動の検出率が向上する事実を確認した。これらの結果を元に、一連の流れを自動化するアルゴリズムを構築する予定である。

最後に外れ値検出の本質的な課題に関して述べる。外れ値検出手法はあくまでも「外れ値」を検出しているに過ぎず、検出されたデータが何であるかは最終的には人間が判断することが必須である [9] [4]<sup>(注3)</sup>。実証実験により、どのような行動が「外れ値」として検出されるのかという知見を蓄積しつつ、手法の汎用性を高めていきたい。

## 文 献

- [1] B.Schölkopf et.al. Estimating the support of a high-

(注3)：学習手法の性能ではなく、変数などの入力空間の設計の妥当性の検証である。

- dimensional distribution. *Neural Comput*, Vol. 13, pp. 1443-1471, 2001.
- [2] Chih-Chung Chang and Chih-Jen Lin. *LIBSVM: a library for support vector machines*, 2001. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [3] Supriya.Rao et.al. Abnormal activity detection in videosequence using learnt probability densities. *TENCON2003*, Vol. IROS 2003, pp. 369-372, 2003.
- [4] Runar Unnthorsson.et.al. Model selection in one class v-svms using rbf kernels. *Proc.of 16th Int.Cong.CAMADEM*, 2003.
- [5] "B. Schölkopf and A.J. Smola". *"Learning with Kernels — Support vector machines, Regularization, Optimization, and Beyond"*. "MIT Press", 2002.
- [6] Jerome H. Friedman Trevor Hastie, Robert Tibshirani. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer-Verlag, 2001. ISBN:0387952845.
- [7] 高畠泰斗, 香田正人. 1 クラス svm と近傍サポートによる領域判別. *オペレーションズ・リサーチ*, Vol. 51, , 11 2006.
- [8] 斎藤三郎. *再生核の理論入門*. 牧野書店, 2002. ISBN:978-4-7952-0149-1.
- [9] 小野田崇. One-class svm に基づく水力発電所におけるリスクマネジメント. *オペレーションズ・リサーチ*, Vol. 51, , 11 2006.
- [10] 南里卓也, 大津展之. 複数人動画画像からの異常動作検出. *信学技報*, Vol. PRMU-77, , 2004.
- [11] 馬場賢二, 榎原孝明, 湯浅裕一郎. 画像処理による人流計測システム. *東芝レビュー*, 第 690 巻, pp. 35-38, 2006.
- [12] 文部科学省. 「安全・安心な社会の構築に資する科学技術政策に関する懇談会」報告書. <http://www.mext.go.jp/>, 2004.
- [13] 豊嶋伊知郎, 服部可奈子, 吉田琢史, 板倉豊和, 小磯貴史. 多段階のパターン認識を用いた歩行軌跡データからの顧客行動判別. *情処研報*, No. CVIM-153-27, pp. 173-178, 2006.
- [14] 豊嶋伊知郎, 服部可奈子, 吉田琢史, 板倉豊和, 折原良平. 教師データ作成の観点から見た, データマイニング技術の行動分析への応用例. *信学技報*, 第 106 巻 of *CST2006-42*, pp. 25-30, 2007.
- [15] 鈴木直彦, 平澤宏祐, 田中健一, 小林貴訓, 佐藤洋一, 藤野陽三. Hidden markov model を用いた逸脱行動人物検出. *信学技報*, 第 106 巻 of *PRMU2006-46*, pp. 43 48.