

人物動線データ分析による逸脱行動人物の検出

鈴木 直彦[†] 平澤 宏祐[†] 田中 健一[†] 小林 貴訓[‡] 佐藤 洋一[‡] 藤野 陽三^{††}

† 三菱電機株式会社 先端技術総合研究所 〒661-8661 兵庫県尼崎市塚口本町 8-1-1

‡ 東京大学 生産技術研究所 〒153-8505 東京都目黒区駒場 4-6-1

†† 東京大学 工学系研究科 〒113-8656 東京都文京区本郷 7-3-1

E-mail: † {Suzuki.Naohiko@dw, Hirasawa.Kosuke@cs, Tanaka.Kenichi@ah}.MitsubishiElectric.co.jp

‡ {yosinori, ysato}@iis.u-tokyo.ac.jp, †† fujino@civil.t.u-tokyo.ac.jp

あらまし 近年ユビキタスコンピューティングの発展に伴い、様々な空間において画像センサ・GPS・レーザーレーダーセンサなどのデバイスを用いた移動体位置の連続的検出が可能になっている。そこで本研究では、人物移動経路の時系列データ群(人物動線データ群)の理解を行うため、人物動線データのパターン分類および逸脱行動人物検出手法の開発を目的とする。(1)過去に得られた人物動線データ群の分類および逸脱行動人物検出(2)学習された人物動線パターンを用いたリアルタイム逸脱行動人物検出の2つの利用シーンに対応した手法を提案している。提案手法の有効性を検証するために実空間で得られた人物位置の時系列データ群による評価実験を行い、有効な結果が得られることが分かった。本研究における提案手法は、店舗におけるマーケティング分析、様々なセキュリティシステムなどへの応用が考えられる。

キーワード Hidden Markov Model, 動線, セキュリティ, マーケティング

Pattern Classification and Detection of an Abnormal Behavior Person in Human Trajectories

Naohiko SUZUKI[†] Kosuke Hirasawa[†] Kenichi TANAKA[†] Yoshinori KOBAYASHI[‡]
Yoichi SATO[‡] and Yozo FUJINO^{††}

† Advanced Technology R&D Center, Mitsubishi Electric Corp.

8-1-1 Tsukaguchi-Honmachi, Amagasaki-shi, Hyogo, 661-8661 Japan

‡ Institute of Industrial Science, Tokyo University 4-6-1 Komaba, Meguro-ku, Tokyo, 153-8505 Japan

†† Graduate School of Engineering, Tokyo University 7-3-1 Hongo, Bunkyo-ku, Tokyo, 113-8656 Japan

E-mail: † {Suzuki.Naohiko@dw, Hirasawa.Kosuke@cs, Tanaka.Kenichi@ah}.MitsubishiElectric.co.jp

‡ {yosinori, ysato}@iis.u-tokyo.ac.jp, †† fujino@civil.t.u-tokyo.ac.jp

Abstract Recently, development of vision sensors, GPS, and laser radar enables continuous detection of human positions in various situations. On the other hand, it is important to understand information of mobility trajectory for development of service on positions data. Therefore, in this research, we propose a new method that classify human movement patterns and detect an abnormal behavior person, so that we understand human movement. The method consists of two phases: (i) classification of past human trajectories and detection of an abnormal behavior person, (ii) detection of an abnormal behavior person in real-time based on learned human trajectories patterns. We show the method can classify human trajectories patterns and detect an abnormal person using observed data in real space. The method aims to be applied to marketing analysis, security system with video, and so on.

Keyword Hidden Markov Model, Trajectory, Security, Marketing Research

1.はじめに

近年画像センサ・RFID・GPS・携帯端末・レーザレ

ーダセンサ等のデバイスおよび情報処理技術の発展に

伴い、人物などの移動体の移動行動を連続的に取得す

ることが可能になりつつある[1][2][3]。これらのセンサデバイスが広く設置されることにより、センサデバイスから得られる移動体の位置情報・ID情報を用いた様々なサービスが提案されている。多数設置された監視カメラを用いたセキュリティ、車両移動情報を用いた高度ITS、個人の購買行動に対応したマーケティング、被災者情報を用いた災害避難誘導などの多様なアプリケーションを考えられている。一方、社会の安心・安全への関心の高まりにより、様々な空間に多くのカメラが設置され、多くの映像データに記録されているようになっている。しかし、監視システムにおいて、長時間でかつ多数のカメラの映像記録データから不審行動人物などの目的のシーンを探索する作業は、膨大な作業量を要するという問題がある。これらの問題を解決するには、映像データから得られる人の動きを検知し、不審行動人物を自動的に発見する手法が必要である。セキュリティに関するレポート[4]によれば、不特定多数の人物が利用する店舗や駅などの空間では、不審行動人物は、うろうろする・複数人で来て注意をそらす等の多様な行動特徴を持っている。つまり、不特定多数人物が利用する空間において不審行動人物を発見するには、特定な行動パターンの検出だけではなく、他の一般の行動パターンから逸脱している行動パターンを行っている人物を検出することが求められる。

これらの関連研究としては、[5-12]がある。Staufferら[5]は、学習したベクトル量化符号帳に基づき、教師無し学習により人物・車両などの動線の階層的な分類を行っている。Fuら[6]は、Spectral Clusteringを用いて車両軌跡情報を時間・空間の二階層に分けて分類し、どのクラスにも属さない軌跡情報を異常事象として検出している。青木ら[7]は、画像上の特徴点列をHMMによりモデル化し、閾値を用いた繰り返し学習に基づき、人物行動パターン獲得手法を提案している。吉田ら[8]は、データマイニング手法を用いて、多様な人物動線データ群から代表動線の検出している。数藤ら[9]は、映像中の人物の重心軌跡情報に対して1クラスSVMを適用し、非定常イベントの検出手法を提案している。Porikliら[10]は、追跡に用いた画像上のオブジェクトの特徴量をHMMに適用し、Spectral Clusteringを用いて、ベクトルの内積から移動体の行動パターン分類と非定常イベント検出を行っている。Wangら[11]は、動線の時空間的情報および対象のサイズ情報を用いた動線間の同一性指標および比較信頼性指標により、人物・車両の分類と異常事象検出手法を提案している。Nguyenら[12]は、HMMの拡張モデルであるAHMEM(Abstract Hidden Markov mEmory Model)を用いることにより、低次元の観測データに基

づいた高次元の人物行動データ理解のための手法を提案している。Huら[14]は、画像中の差分ピクセルデータを空間的特徴と時間的特徴を分けて階層的にクラスタリングを行い、車両動線パターンの検出を行っている。

本研究では多様なセンシングデバイスから得られる人物動線データ群から人物行動パターンを自動的に分類する手法および他の一般的な行動パターンから逸脱している行動パターンを検出する手法に関する提案を行う。HMM(Hidden Markov Model)を用いて人物動線データの時空間的特徴をモデリングし、多次元尺度構成法により獲得した人物行動パターンを用いて、どの人物行動パターンにも合致しないものを逸脱行動として検出する。

本研究の構成は以下の通りである。2章で人物動線データ群の分類および逸脱行動検出手法を述べる。3章で実際の人物動線データ群に提案手法を適用した実験結果を示す。4章で本研究のまとめを述べる。

2. 提案手法

2.1. 概要

本研究では、單一カメラの視野より広域の空間を移動する人物の移動経路情報(人物動線データ群)の時空間的な特徴に着目し、人物行動パターンを自動分類する手法およびどの人物行動パターンからも逸脱している行動パターンの人物を検出する手法について提案する。提案手法では、様々なセンシングデバイスに対応するため、サイズやカラー情報などの画像上の特徴量を用いないものとする。また従来研究では、基本的に單一カメラ視野を対象としていたため、人物や車両の移動経路が、直線的なものや、1~2回方向が変化するものに適した手法がほとんどである。本研究では、店舗内における回遊・滞留などの複雑な要素を有する移動経路の時空間特徴を総合的に評価することができる手法を提案する。さらに、監視システムで求められる過去の記録データからの不審行動人物検索とリアルタイム不審行動人物検出の両者に対応した枠組みの構築を目指す。

本研究の提案手法の全体の枠組みを図1に示す。提案手法は、<Phase 1>過去の人物動線データから人物動線パターンを検出する学習フェーズと、<Phase 2>リアルタイムの人物動線パターンを用いて逸脱行動人物検出を行うリアルタイム検出フェーズの2段階に分けられている。まずPhase 1では、HMMを用いて個々の人物動線データを表現し、個々の人物動線データの距離を演算する。ここで他の全ての人物動線データに対して距離が大きくなるものを逸脱行動人物データとして

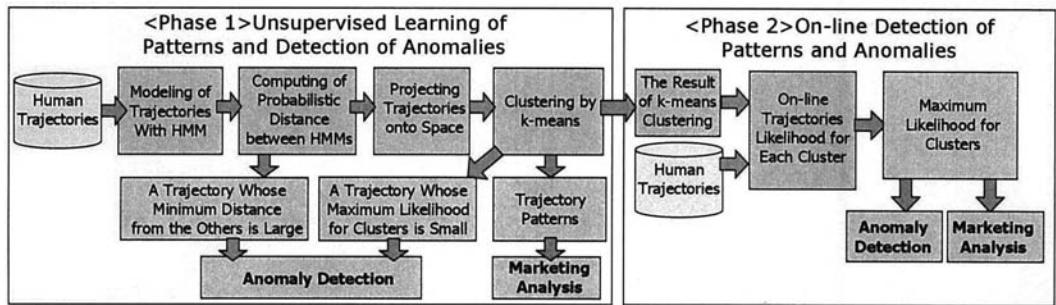


図 1. 提案手法の全体スキーム

検出する。次に各人物動線データ間の距離情報を用いて任意次元の空間へ各人物動線データを射影する。射影された人物動線データを k-means クラスタリングによって分割することにより、複数の人物行動パターンを得る。Phase 2 では、Phase 1 で得られた人物行動パターンを HMM で表現し、リアルタイムで得られる人物動線データを各人物動線パターンに対応した HMM に適用することにより、逸脱行動人物か判定を行う。学習フェーズおよび評価フェーズの二つのフェーズを設けることにより、評価対象データ数が膨大なケースにおいても少ない演算量で評価することができる。

2.2. 人物動線データ

センシングデバイスから得られる人物動線データ \mathbf{R}_i を位置 (x_{it}, y_{it}) により、式(1)のように定義する。

$$\mathbf{R}_i = \{x_{it}, y_{it}, t\} \quad t=1 \dots T_i \dots \dots \dots \quad (1)$$

各人物動線データのデータ長を同一にするため、速度 v_{it} を要素に追加し、正規化した人物動線データ $\overline{\mathbf{R}}_i$ を式(2)に示す。

$$\overline{\mathbf{R}}_i = \{x_{it}, y_{it}, v_{it}, t\} \quad t=1 \dots T_0 \dots \dots \dots \quad (2)$$

2.3. HMM を用いた人物動線データのモデル化

HMM を用いて正規化された人物動線データ $\overline{\mathbf{R}}_i$ を表現する。状態 $S_i \rightarrow S_j$ 間遷移確率を a_{ij} とする。ただし人物動線の特徴を検出するため、正規化された各時間毎の遷移確率を考慮し、評価対象の遷移確率を単純な遷移確率と時間単位毎の遷移確率の積 $a_{ij} \leftarrow a_{ij}^\alpha * a_{ij}(t)^{1-\alpha}$ とする。また、遷移 $S_i \rightarrow S_j$ にある観測データ o_t の観測確率を $b(o_t)$ とする。観測確率の要素は各状態内の位置・方向・速度で決定される。HMM に適用する状態 S_i は、対象空間内の二次元位置に応じて定義する。

2.4. 人物動線データ間の距離

Juang ら[18]が提案している HMM 間の距離を用いて人物動線データ間の距離を定義する。HMM パラメータをそれぞれ λ_1, λ_2 , λ_1 を学習した際に利用した長さ T の時系列データを \mathbf{O}_1 , 時系列データの HMM に対する尤度を $L(\mathbf{O}|\lambda)$, 学習に用いたデータ個数を m とすると、2 つの HMM 間の距離は式(4)で示される。

$$D(\lambda_1, \lambda_2) = \frac{1}{m} \sum_m \frac{1}{T} [\log L(\mathbf{O}_1|\lambda_1) - \log L(\mathbf{O}_1|\lambda_2)] \dots \dots \dots \quad (4)$$

ただし式(4)は非対称式のため、実際には HMM λ_1 と λ_2 間の距離は式(5)となる。

$$D_{ave}(\lambda_1, \lambda_2) = \frac{1}{2} (D(\lambda_1, \lambda_2) + D(\lambda_2, \lambda_1)) \dots \dots \dots \quad (5)$$

また、HMM の学習データが少ない場合、未学習の状態遷移が発生するのを防止するため、人物動線データを用いて学習をした HMM パラメータ λ_{all} を用いて、式(6)のように各人物動線データから得られる HMM パラメータ λ_i の補正を行う。

$$\lambda_i \leftarrow \lambda_i^\beta \lambda_{all}^{1-\beta} \quad \text{ただし } 0 < \beta < 1 \dots \dots \dots \quad (6)$$

このとき、各人物動線データの HMM 間の距離を用いて、過去に得られた人物動線データ群から逸脱行動人物を検出する。具体的には、他の人物動線データ間の距離の最小値がある閾値以上のものを逸脱行動人物として検出する。

2.5. 人物動線データの空間への射影

多次元尺度構成法(MDS)を用いて、2.4 節で示した人物動線データ間の距離情報から人物動線データを空間ベクトルとして射影する。多次元尺度構成法は、対象間の類似性の程度を示す測度が与えられたとき、対象を多次元空間内の点として表現する手法である。多次

元尺度構成法の手法のうち, Young-Householder 変換を用いた手法を適用する[15][16].

多次元尺度構成法を用いた適用手法の概要を以下に示す. まず N 個の人物動線データの相互距離 $D_{ave}(\lambda_i, \lambda_j)$ の二乗値を要素とする $N \times N$ の距離行列 \mathbf{D} を作成する. 次に Young-Householder 変換(式(7)・(8))を用いて距離行列 \mathbf{D} を変換する. 行列 \mathbf{J} は中心化行列であり, 単位行列 \mathbf{I}_N および N 個の要素全ての値が 1 である行列 $\mathbf{1}_N$ を用いて示される.

$$\mathbf{B} = -\frac{1}{2} \mathbf{JDJ}^t \dots \dots \dots \quad (7)$$

$$\mathbf{J} = \mathbf{I}_N - \frac{1}{N} \mathbf{1}_N \mathbf{1}_N^t \dots \dots \dots \quad (8)$$

射影された後の人動線データ $\overline{\mathbf{R}_i}$ に対応した M 次元空間ベクトルを $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{iM})$, ベクトル \mathbf{x}_i を各行に並べた行列を $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N)^t$ とする. このとき $\mathbf{B} = \mathbf{XX}^t$ となる.

ここで行列 \mathbf{B} の固有値および固有ベクトルを用いて空間ベクトル \mathbf{X} を求める. 値の大きい方から降順に並べた \mathbf{B} の固有値 r_1, r_2, \dots, r_M ($r_1 \geq r_2 \geq \dots \geq r_M \geq 0$) の平方根をそれぞれ対角成分とする $M \times N$ 行列を $\mathbf{\Lambda} = diag(\sqrt{r_1}, \sqrt{r_2}, \dots, \sqrt{r_M})$, 各固有値に対応する正規化した固有ベクトル $\mathbf{v}_1 = (v_{11}, \dots, v_{1N})^t, \mathbf{v}_2, \dots, \mathbf{v}_M$ を各列に並べた $N \times M$ 行列を $\mathbf{V} = (\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_M)$ としたとき, 求めるべき射影後の空間ベクトル \mathbf{X} は式(9)により得られる.

$$\mathbf{X} = \mathbf{V}\mathbf{\Lambda} \dots \dots \dots \quad (9)$$

2.6. 人物動線データの分類および逸脱行動人物検出

Porikli ら[10]による Spectral Clustering を用いた手法ではベクトルの内積で類似度を評価しているため, 元の人物動線データの情報を表現できない場合がある. そこで k-means クラスタリングを用いて空間に射影された人物動線データの分類を行う.

2.5 節で得られた人物動線データ $\overline{\mathbf{R}_i}$ に対応した M 次元空間ベクトル \mathbf{x}_i を用いた人物動線データのパターン分類手法を以下に示す.

- (1) k-means クラスタリングにより M 次元空間ベクトル \mathbf{x}_i のクラスタリングを行う. ただし, 3.4 で逸脱行動人物と検出されたデータはクラスタリング対象データから省く.
- (2) k-means クラスタリングで得られたクラスタに含まれる人物動線データ $\overline{\mathbf{R}_i}$ を用いて各クラスタ毎

の HMM を構築する.

- (3) (2)で得られた各 HMM に対する尤度の最大値がある閾値以下のデータを逸脱行動として検出する.
- (4) (3)で逸脱行動として検出されたデータを省いて再度 k-means クラスタリングを実施し, 人物動線データのパターンを得る.

一般に k-means クラスタリングは初期値およびクラスタ数によって, 得られるクラスタリング結果が異なる. そこで, 以下に示す手法を用いて k-means クラスタリングによる人物動線データのパターン分類を行う.

クラスタ数 K の条件下において, 初期値に対してランダムサンプリングを行い, 以下の式(10)で示すクラス内歪みを最小にする初期値を選択する. ただし \mathbf{x}_i は射影後のデータ, μ_k は k-means クラスタリング後のクラスタ k の重心, C_k はクラスタ数, n_k はクラスタ内のデータ個数である.

$$V_k = \sum_{k=1}^K \sum_{i=1, i \in C_k} \frac{1}{n_k} (\mathbf{x}_i - \mu_k)^2 \dots \dots \dots \quad (10)$$

次にクラスタ数 K の評価指標について述べる. 最適なクラスタ数を求める一般的には困難である. そこで Milligan ら[17]によるクラスタ数決定手法の比較において, 良い結果が得られている Calinski ら[18]による評価指標(以下 $CH(K)$, 式(11))を適用し, 最適なクラスタ数 K を求める.

$$CH(K) = \frac{\text{trace H} / (K-1)}{\text{trace U} / (N-K)} \dots \dots \dots \quad (11)$$

ただし式(11)の各値は以下の通りである.

$$\text{trace H} = \sum_{k=1}^K n_k \|\mu_k - \mu\|^2 \quad \mathbf{H}: \text{クラス間分散行列}$$

$$\text{trace U} = \sum_{k=1}^K \sum_{i=1}^{n_k} \|\mathbf{x}_{ki} - \mu_k\|^2 \quad \mathbf{U}: \text{クラス内分散行列}$$

μ : 全体データセントロイド, \mathbf{x}_{ki} : クラス k のデータ

2.7. リアルタイム検出人物動線データからの逸脱行動人物およびパターン検出

2.6 節で得られた複数の人物行動パターンに対応した HMM λ_k ($k = 1 \dots K$)を作成し, 正規化人物動線データ $\overline{\mathbf{R}_i}$ の人物行動 HMM λ_k に対する尤度を $L(\overline{\mathbf{R}_i} | \lambda_k)$ とする. このとき, ある人物動線データの尤度が最も高い人物行動 HMM パターン $\lambda_{k_{\max}}$ は式(12)として示される.

$$k^{\max} = \arg \max_k L(\overline{\mathbf{R}_i} | \lambda_k) \dots \dots \dots \quad (12)$$

ここで、尤度 $L(\mathbf{R}_t | \lambda_{k_{\max}})$ がある閾値以下になる人物動線データを逸脱行動人物として判定する。つまりどの人物行動パターンにも当てはまらない人物動線データを逸脱行動人物として判定する。このステップにおける演算は、HMM に対する尤度演算を行うのみなので、高速に逸脱行動人物を検出することができる。また、人物動線データの尤度最大値を用いて、人物動線データ群のパターン分類も同時に実施することができる。

3. 評価実験

3.1. 概要

実際の某店舗で得られた人物動線データ群に提案手法を適用し評価実験を実施した。まずある時間帯の人物動線データ群の人物行動パターン自動分類および逸脱行動人物検出の評価を行い、得られた人物行動パターンを用いて別の時間帯の人物動線データ群から逸脱行動人物を検出した。評価実験の対象店舗は約 6m × 約 8m 程度の小規模店舗である。

3.2. 人物動線データ群取得

まず対象エリア全体の人物動線データを取得するために、実際の某店舗にカメラ 10 台を設置し、各カメラの映像データの記録を行った。また、カメラのキャリブレーションを行い、画像上の座標系から実空間の座標系への変換パラメータ推定を行った。

次に PC 上のマニュアル操作で人物動線データを作成した。画像上に写っている人物の両足の中間点を手動で指定し、画像座標から実空間の座標への変換を行い、 $z=0$ の 2 次元平面上の各人物の人物動線データ群を得た。人物動線データの取得サンプリングは 1sec である。

3.3. 本実験における適用手法

本実験では、HMM で一般に利用される曖昧な情報源ではなく、店舗内を図 2 のように区切った 11 個の実空間上の位置を状態として定義している。また 2.5 節で示した行列 \mathbf{B} の固有値の大きさから、人物動線データを射影する空間の次元数 $M=4$ とした。

3.4. 実験対象人物動線データ群

実験に用いた人物動線データ群を図 3-4 に示す。図 3 は人物行動パターンの学習に用いたある平日の 15 時～16 時のデータ、図 4 はリアルタイム逸脱行動人物検出に用いたある平日の 14 時～15 時のデータである。

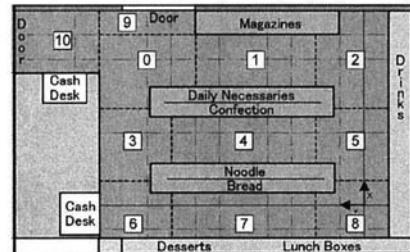


図 2. 状態定義

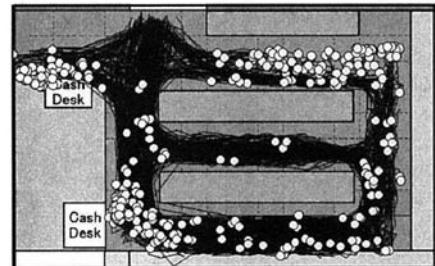


図 3 学習に用いたある 1 時間の人物動線データ群
(計 149 人、○は 30 秒以上の人物滞留箇所)

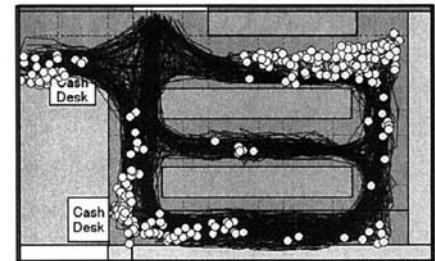


図 4. リアルタイム検出用のある 1 時間の人物動線データ群(計 130 人、○は 30 秒以上の人物滞留箇所)

3.5. 学習人物動線データ群における逸脱行動人物検出およびパターン分類結果

学習に用いたある日の 1 時間の人物動線データ群における逸脱行動人物検出結果を図 5 に示す。また人物動線データ群のパターン分類の際のクラスタ数 K の評価指標である $CH(K)$ の値を図 7 に示す。 $CH(K)$ の式形より K が 2 のときに値が大きくなることを考慮すると、図 7 より最適なクラスタ数 K が 4 であることが分かる。クラスタ数 $K=4$ における最適な初期値を用いた人物動線データ群のパターン分類の結果を図 6 に示す。

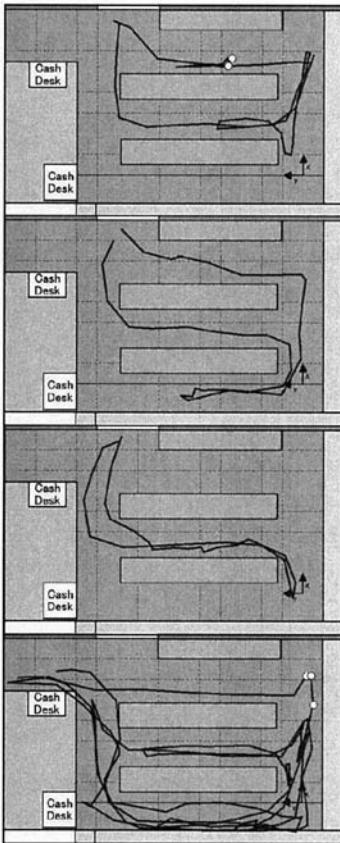


図 5. 学習に用いた人物動線データ群からの逸脱行動人物検出結果

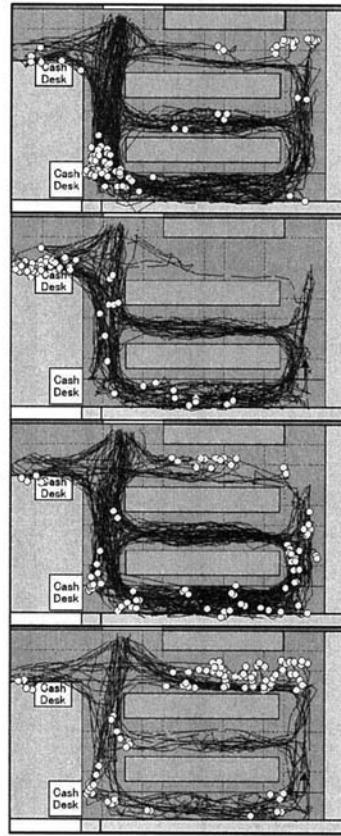


図 6. 学習に用いた人物動線データ群のパターン分類結果

3.6. リアルタイム検出人物動線データからの逸脱行動人物検出

3.5 節で得られた人物行動パターンを用いて、学習に用いたデータ群とは異なる時間帯の図 4 に示した人物動線データ群における逸脱行動人物の検出を行った。逸脱行動として検出された人物動線データを図 7 に示す。

3.7. 考察

実際の人物動線データ群を用いて提案手法の評価実験を行った結果、過去データにおける逸脱行動人物検出・人物行動パターン分類、リアルタイムに検出した人物動線データからの逸脱行動人物検出ができることが分かった。図 5 の結果では、レジを通過せずに店舗内を周回している人物を自動的に検出している。監視システムで求められる不審行動人物のリアルタイム検出・大量記録データからの不審行動人物検出が可能

となる。また、図 6 の自動行動パターン分類結果から、2 つの基本的購買パターン(図 6 上から 1・2 番目)・周回パターン(図 6 下から 2 番目)・立ち読みパターン(図 6 最下)を自動的に分類できていることが分かる。回遊・滞留などを含む複雑な顧客購買行動の傾向を自動的に抽出できている。

提案手法では、レジ位置などの対象空間に関する事前知識を必要とせずに人物動線データ群を学習しているため、オペレータによる設定が不要となる。また、HMM および固有値分解により人物の位置時系列データから人物行動パターンの傾向を安定的に学習することができるため、特定の空間・センサに依存せずに、様々な空間における移動体の経路データの分析へと応用することが可能となる。

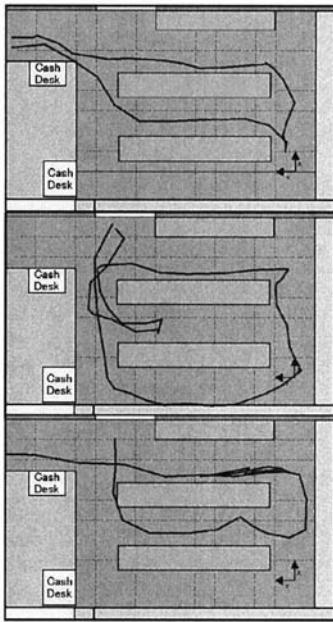


図 7. リアルタイム検出人物動線データ群からの逸脱行動人物検出結果

4.まとめ

本研究では、様々なデバイスより得られる人物動線データ群から他の人物とは異なる逸脱行動人物を検出する手法および人物行動パターンの自動分類する手法の提案を行った。某店舗における実際の人物動線データ群に対して提案手法を適用した結果、事前知識を必要とせずに逸脱行動人物の検出および人物行動パターンの自動分類を行うことができた。

今後は、商業施設・駅・空港などの様々な空間における移動体行動の評価スキームを確立することにより、多様なサービスの実現につなげていきたい。

文 献

- [1] 鈴木達也, 岩崎慎介, 小林貴訓, 佐藤洋一, 杉本晃宏, “環境モデルの導入による人物追跡の安定化,” 信学論(D-II), vol.J88-D-II, no.8, pp.1592-1600, Aug. 2005.
- [2] Y. Kobayashi, D. Sugimura, Y. Sato, K. Hirasawa, N. Suzuki, H. Kage, A. Sugimoto, "3D Head Tracking using the Particle Filter with Cascaded Classifiers," Proc. of the British Machine Vision Conference (BMVC2006), pp.37-46, Sep.2006.
- [3] H. Zhao, R. Shibasaki, "A Novel System for Tracking Pedestrians using Multiple Single-row Laser Range Scanners," IEEE Trans. SMC Part A: Systems and Humans, Vol.35, No.2, pp.283-291, Mar. 2005.
- [4] 都市防犯研究センター, “事業所の防犯点検・防改修,” pp.20-22, (財)都市防犯研究センター, 東京, 2005.
- [5] C. Stauffer, W. Eric L. Grimson, "Learning Patterns of Activity Using Real-Time Tracking," IEEE Trans. Pattern Analysis and Machine Intelligence, vol.22, no.8, pp.747-757, Aug. 2000.
- [6] Z. Fu, W. Hu, T. Tan, "Similarity Based Vehicle Trajectory Clustering and Anomaly Detection," Proceedings of IEEE International Conference on Image Processing (ICIP2005) Vol.2, pp.602-605, Sep. 2005.
- [7] 青木茂樹, 大西正輝, 小島篤博, 福永邦雄, “独居高齢者の行動パターンに注目した非日常状態の検出,” 电学論E, vol.125, no.6, pp.259-265, Jun. 2005.
- [8] 吉田琢史, 小磯貴史, 服部可奈子, 豊嶋伊知郎, 今崎直樹, “顧客動線に基づく店舗内環境評価手法の提案,” 信学技報 AI2004-91, pp.67-71, Mar. 2005.
- [9] 数藤恭子, 若林佳織, 荒川健一, “長時間の監視映像からの非定常シーケンスの検出,” 情報処理学会研究報告 2005-CVIM-151, pp.77-82, Nov. 2005.
- [10] F. Porikli, T. Haga, "Event Detection by Eigenvector Decomposition Using Object and Frame Features," Conference on Computer Vision and Pattern Recognition (CVPRW), pp. 114, June. 2004.
- [11] X. Wang, K. Tieu, W. Eric. L. Grimson, "Learning Semantic Scene Models by Trajectory Analysis," Proc. of ECCV, vol. III, pp. 110-123, 2006.
- [12] N. T. Nguyen, H. H. Bui, S. Venkatesh, G. West, "Recognizing and monitoring high-level behaviors in complex spatial environments," IEEE International Conference on Computer Vision and Pattern Recognition (CVPR-2003), pp.620-625, 2003.
- [13] W. Hu, X. Xiao, Z. Fu, D. Xie, T. Tan, S. Maybank, "A System for Learning Statistical Motion Patterns," IEEE Trans. PAMI Vol.28, No.9, pp.1450-1464, Sep. 2006.
- [14] B. H. Juang, L. R. Rabiner, "A probabilistic distance measure for hidden Markov models," AT&T Technical Journal, Vol.64, No.2, pp.391-408, Feb. 1985.
- [15] G. Young, A. Householder, "Discussion of a Set of Points in Terms of Their Mutual Distances," Psychometrika, Vol.3, pp.19-22, 1938.
- [16] T. Yairi, K. Hirama, K. Hori, "Fast and Simple Topological Map Construction Based on Cooccurrence Frequency of Landmark Observation," IEEE/RSJ International Conference Integration on Intelligent Robots and Systems (IROS2001), pp. 1263-1268, Oct. 2001.
- [17] G. W. Milligan, M. C. Cooper, "An Examination of Procedures for Determining the Number of Clusters in a Data Set," Psychometrika, Vol.50, No.2, pp.159-179, 1985.
- [18] T. Calinski, J. Harabasz, "A Dendrite Method for Cluster Analysis," Communication in Statistics, Vol.3, pp.1-27, 1974.