

特徴点追跡結果を用いた動きのモデル化と例外行動検出

Abnormal Action Detection using Feature Point Tracking

都築勇司† 西村孝‡ 藤吉弘巨‡ 森次郎†

Yuji TSUDUKI†, Takashi NISHIMURA‡, Hironobu FUJIYOSHI‡, Jiro MORI†

†大日本印刷 ‡中部大学 工学部情報工学科

†Dai Nippon Printing, ‡Chubu University

E-mail: hf@cs.chubu.ac.jp

Abstract

本稿では、特徴点追跡の結果より定常的な動きを、移動方向のヒストグラムに混合正規分布を当てはめてモデル化し、モデル外の動きを例外行動として自動的に検出する手法を提案する。混合正規分布の当てはめには、EM アルゴリズムを用いる。通常の EM アルゴリズムでは移動方向のような周期性を表現できないため、周期性を表現できる EM アルゴリズムを提案する。提案手法はまず、SIFT 特徴量を用いた Mean-Shift 探索による特徴点追跡結果を行い、特徴点の移動方向ヒストグラムから画像の異常領域毎に混合正規分布を用いた定常的な移動方向のモデルを作成する。検出時には、特徴点移動方向を入力とし、正規分布内であれば定常的な動き、そうでなければ異常な動きとして判定する。提案手法は、人検出などの前処理が不要であるため、前処理における失敗の影響を最小限に抑えることが可能となる。提案手法の応用例として、コンビニ等の店舗内において商品に注目する人の動きを検出する手法とその有効性を示す。

1 はじめに

近年、駅構内やコンビニ等に監視カメラが設置され、防犯や事故防止等に利用されている。しかし、監視カメラの映像から犯罪や事故等につながるような行動を判断するのは人間であり、常に複数の映像をモニタリングする必要がある。そのため、疲労による見落としや、コストの問題等が発生する。このような背景の下、犯罪や事故につながるような異常行動を自動的に検出する研究が多く取り組まれている [1]-[3]。

青木らは、Hidden Markov Model (HMM) [4] を用いて定常行動を学習し、入力された行動パターンが、定常モデルに当てはまらない場合、例外行動として認識する手法を提案している [1]。この手法では、人領域を抽出する必要があり、複数人の画像データ等では、個々

の人領域の抽出が困難であるため、前処理の検出精度の影響が大きい。

南里らは、立体高次局所自己相関特徴 (CHLAC) を用いて例外行動の検出法 [2] を提案している。画面内で頻繁に行われる動作を定常動作とし、異常動作をその定常動作の特徴分布から逸脱するものとして定義する。動作特徴として立体高次局所自己相関特徴を用いており、この特徴の加法性の性質と部分空間法を組み合わせることによって、画面内に複数人いる場合でも、個々の人物の切り出しやトラッキング無しで学習および検出することができる。しかし CHLAC は画像全体から得られる特徴量であるため、例外行動の発生した領域を特定できないという問題がある。

青木らは、移動体の重心の軌跡により例外行動を判定する手法 [3] を提案している。人物の位置や姿勢の情報をもとに人物の動作や行動パターンを行動パターン毎に分類して学習し、すべての行動モデルの事後確率が、指定されたしきい値以下のときを例外行動として検出する。しかし、移動体の重心の軌跡の動き情報から例外行動かを判断するため、手や足の小さな動きからは異常な行動として検出されない問題がある。

本稿では、特徴点追跡の結果より、定常的な動きを移動方向のヒストグラムに混合正規分布を当てはめてモデル化し、モデル外の動きを例外行動として自動的に検出する手法を提案する。混合正規分布の当てはめには、EM アルゴリズムを用いるが、通常の EM アルゴリズムでは移動方向のような周期性を表現できないため、周期性を表現できる EM アルゴリズムを提案する。定常的な動きモデルを画像中の小領域ごとに作成し、例外行動の判定を行うことで、例外行動の発生した領域を検出することが可能となる。また、移動体の重心の軌跡ではなく、各特徴点の追跡結果を用いるため、手や足などの動きを利用した例外行動の検出が期待できる。さらに、移動体領域の検出を必要としないため提案手法は、前処理における失敗の影響を抑えることができる。提案手法の応用例として、コンビニ等

の店舗内において商品に注目する人の動きを検出する手法について提案し, その有効性を示す.

2 特徴点追跡を用いた動きのモデル化

本手法は, 特徴点追跡の結果より定常的な動きをモデル化し, モデル外の動きを例外行動とすることで検出を行う. ただし, 定常的な動きのモデルは, 対象とする環境, カメラの位置などにより変化するため, 一意に定めることは困難である. そこで, 対象とする環境における定常的な動きを含む映像から, 動きのモデルを作成し, これに基づき例外行動の検出を行う. モデルの表現には, 特徴点の移動方向の発生頻度を用い, 検出時には発生頻度の低い方向の動きを例外行動として検出する. しかし, 学習時の移動方向のヒストグラムを直接モデルに用いると, 全ての移動方向に十分なデータを作成するためには, 非常に長時間の学習が必要となる. そこで, 発生頻度は移動方向のヒストグラムに混合正規分布を当てはめたものを用いる. 混合正規分布を当てはめることにより, 短い学習時間で有効な行動モデルを作成することが可能となる. 混合正規分布の当てはめには EM アルゴリズムを用いる. 以下に, 特徴点追跡手法と周期性を考慮した EM アルゴリズムについて述べる.

2.1 SIFT 特徴を用いた Mean-Shift 探索による特徴点の追跡法

Scale Invariant Feature Transform (SIFT) [5] は, 回転・スケール変化・照明変化による画像の変化に不変な特徴量を画素毎に記述することが可能である. また, この特徴量は近傍ピクセルでは類似度が高くなるという傾向がある. 本研究では, 都築等により提案された SIFT 特徴量から得られる重み分布の重心へと移動する Mean-Shift による特徴点追跡 [7] を用いる.

特徴点追跡の処理の流れを図 1 に示し, 以下に詳細を述べる.

2.1.1 初期追跡点検出

初期フレームの画像より初期追跡点を検出する. 初期追跡点には, SIFT で検出されるキーポイントを用いる. 各点には, SIFT で記述された 128 次元のベクトル $\mathbf{v} = (v_0, \dots, v_{127})$ とスケール s を参照用データとして保持する.

2.1.2 Mean-Shift 探索

SIFT は, スケールによって特徴を抽出する範囲を変えるため, 追跡対象の画像上での大きさが変化する場合, 適応してスケール値を更新する必要がある.

そこで, Mean-Shift 探索 [6] では, 画像空間の移動量 $\Delta \mathbf{x} = (\Delta u, \Delta v)$ とスケール空間の移動量 Δs を求める. SIFT 特徴量から求めた重み分布を用いて, 画像空間とスケール空間の移動量を交互に求め, 現フレームでの最適な位置とスケール値に移動するよう計算を繰り返す.

step1 画像空間の Mean-Shift

追跡中心 \mathbf{x} の周辺画素 $\mathbf{x}_i (i = 0, \dots, N)$ 及び参照用スケール s の SIFT 特徴ベクトルと \mathbf{x} における参照用ベクトル \mathbf{v} との距離より重み $\omega(\mathbf{x}_i, s)$ を求める.

$$\omega(\mathbf{x}_i, s) = \exp\left(\frac{-d(\mathbf{x}_i, s)^2}{2\sigma_d^2}\right) \quad (1)$$

$$d(\mathbf{x}_i, s) = \|\text{SIFT}(\mathbf{x}_i, s) - \mathbf{v}\| = \sqrt{\sum_{k=0}^{127} (v_{i,k} - v_k)^2} \quad (2)$$

$$\text{SIFT}(\mathbf{x}_i, s) = \mathbf{v}_i = (v_{i,0}, \dots, v_{i,127}) \quad (3)$$

σ_d は, SIFT の類似度を重みに変換するカーネル関数のパラメータである. $\text{SIFT}(\mathbf{x}_i, s)$ は, 座標 \mathbf{x}_i においてスケール s で SIFT 特徴ベクトルを出力する関数である. 求めた重み $\omega(\mathbf{x}_i, s)$ を用いて画像空間上の移動量 $\Delta \mathbf{x}$ を求める. 前フレームの追跡領域周辺に注目した探索を行うため, 式 (5) に示す画像空間のカーネル関数 $K_{loc}(\mathbf{x}, \sigma_{xy})$ を用い, 移動量 $\Delta \mathbf{x}$ を次式より求める.

$$\Delta \mathbf{x} = \frac{\sum_{i=0}^N K_{loc}(\mathbf{x}_i - \mathbf{x}, \sigma_{xy}) \omega(\mathbf{x}_i, s) (\mathbf{x}_i - \mathbf{x}_0)}{\sum_{i=0}^N K_{loc}(\mathbf{x}_i - \mathbf{x}, \sigma_{xy}) \omega(\mathbf{x}_i, s)} \quad (4)$$

$$K_{loc}(\mathbf{x}, \sigma_{xy}) = \exp\left(\frac{-(x^2 + y^2)}{2\sigma_{xy}^2}\right) \quad (5)$$

移動量 $\Delta \mathbf{x}$ から, $\hat{\mathbf{x}} = \mathbf{x} + \Delta \mathbf{x}$ により, 追跡点座標をシフトする.

step2 スケール空間の Mean-Shift

次に, Step1 より求めた移動後の座標 $\hat{\mathbf{x}}$ でのスケール空間における移動量 Δs を求める. Δs は追跡対象の大きさの変化に合わせる値であり, 参照用スケール s と追跡対象の大きさの変化率を掛けた値が推定すべき値となる. 参照用スケール s が大きければ Δs の値も大きくなるため, スケール空間での探索をする場合, 参照用スケール s に合わせて探索範囲を変えなくてはならない. そこで, 探索を行う空間の軸をスケール値ではなく, スケールの変化率 S とし, ΔS を探索する. 画像空間の場合と同様に, 式 (11) を重みとして以下の式により変化率を求める.

$$\Delta S = \frac{\sum_{j=0}^M K_{scale}(S_j - 1, \sigma_s) \omega(\hat{\mathbf{x}}, s S_j) (S_j)}{\sum_{j=0}^M K_{scale}(S_j - 1, \sigma_s) \omega(\hat{\mathbf{x}}, s S_j)} \quad (6)$$

$$K_{scale}(S, \sigma_s) = \exp\left(\frac{-S^2}{2\sigma_s^2}\right) \quad (7)$$

ここで $S_j (j = 0, \dots, M)$ は, 例えば $S_j = (\dots, 0.9, 1.0, 1.1, \dots)$ のような, 1.0 を中央として等間

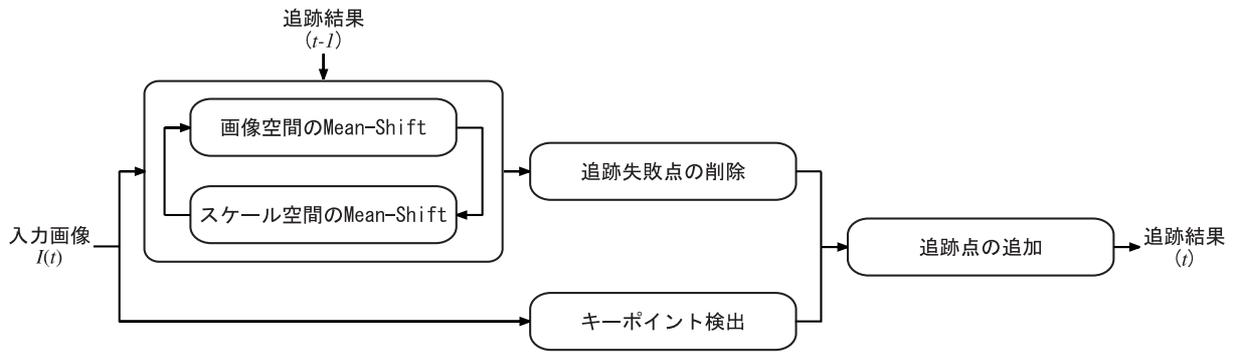


図1 特徴点追跡の流れ

隔で増加する数列である．これは参照用スケール s に対する倍率であり，1.0 は参照用スケール s をそのまま用いる場合である．ただし $S_0 > 0$ である．カーネル関数への入力に $S - 1$ を用いるのは，現在の値である $S = 1$ においてカーネル関数の出力が最大となるようにするためである．求めた変化率 ΔS から， $\hat{s} = s\Delta S$ により，スケールを更新する．

step3 繰り返し処理

step1, step2 の処理を $|\Delta x| < \epsilon_{xy}$, $|\Delta S - 1.0| < \epsilon_s$ を満たすまで各空間の Mean-Shift 探索を交互に繰り返し，最適な追跡点座標とスケールを求める． ϵ_{xy} と ϵ_s はしきい値である．

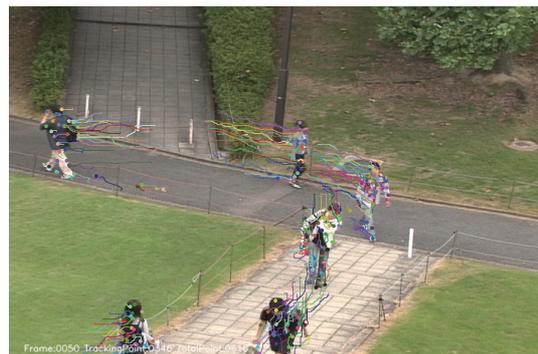
2.1.3 追跡失敗点の削除と追加

移動後の座標 x での SIFT の特徴ベクトルを求め，式 (2) により求めた参照用ベクトルとの距離 $d(x, s)$ がしきい値以上の場合，追跡に失敗したと判断し削除する．また，新たに画像内に進入した移動体の追跡を行うために，特徴点の追加を行う．初期追跡点と同様に，キーポイントとして検出された点を新たな追跡点として登録する．ただし，追跡中の点と同じ位置が検出される場合もある．各追跡点から一定以上の距離があるキーポイントのみを追加する．

図2に，SIFT 特徴量に基づく Mean-Shift 探索による特徴点追跡結果を示す．人領域にある複数の特徴点を追跡できているのがわかる．次に，この特徴点追跡結果を用いて得られる移動方向ヒストグラムに混合正規分布の当てはめを行う．

2.2 周期性を考慮した EM アルゴリズム

EM アルゴリズム [8] は，観測できない隠れたパラメータが存在する時に最尤推定を行うための汎用手法であり，混合分布以外にも隠れマルコフモデルやグラフィカルモデルの学習に応用されている．EM アルゴリズムは Newton 法や勾配法と同様，反復法によって局所最適解を求めるアルゴリズムであるが，他の手法に比べて次のような長所をもつ．



50フレーム



2050フレーム

図2 特徴点追跡例

- 尤度が単調に増加
- 収束の初期の段階では Newton 法と同程度の速さ
- 実装が容易

EM アルゴリズムはパラメータをある適当な初期値に設定し，E ステップ (Expectation Step) と M ステップ (Maximization Step) と呼ばれる二つの手続きを繰り返すことにより ξ の値を逐次更新する方法であり，次のように定式化される．

1. パラメータの初期値を適当な $\xi = \xi^{(0)}$ とする
2. $p = 0, 1, 2, \dots$ に対して次の二つのステップを繰り返す

(a)E ステップ: 完全データの対数尤度 $\log f(\mathbf{x}|\xi)$ の, データ y とパラメータ ξ^p に関する条件付き平均を求める.

$$Q(\xi) = E[\log f(\mathbf{x}|\xi)|y, \xi^{(p)}] = \int f(\mathbf{x}|y, \xi^{(p)}) \log f(\mathbf{x}|\xi) dx \quad (8)$$

(b)M ステップ: $Q(\xi)$ を最大化する ξ を ξ^{p+1} とおく

2.2.1 EM アルゴリズムによる混合正規分布当てはめ

EM アルゴリズムを混合正規分布の当てはめに適用した場合の計算方法を示す. E ステップでは以下の式により条件付き平均を求める.

$$Q(\pi, \mu, \sigma) = \sum_{i=1}^N \sum_{k=1}^K \frac{\pi_k^{(p)} \phi(y_i|\mu_k^{(p)}, \sigma_k^{(p)})}{g(y_i|\pi^{(p)}, \mu^{(p)}, \sigma^{(p)})} \log(\pi_k \phi(y_i|\mu_k, \sigma_k)) \quad (9)$$

$$\phi(y|\mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y-\mu)^2}{2\sigma^2}\right) \quad (10)$$

ここで π, μ, σ は各正規分布の重み, 平均, 標準偏差である.

M ステップでは $Q(\pi, \mu, \sigma)$ の最大化問題を解くことになる. 基本的にはパラメータに関して微分した関数のゼロ点を求めればよいが, π に関しては $\sum_{k=1}^K \pi_k = 1$ という条件があるので, ラグランジュの未定乗数法を用いることで各パラメータを以下の式で求めることができる.

$$\pi_k^{(p+1)} = \frac{\pi_k^{(p)} \Phi_k^{(p)}}{\sum_{j=1}^K \pi_j^{(p)} \Phi_j^{(p)}} \quad (11)$$

$$\mu_k^{(p+1)} = \frac{1}{\Phi_k^{(p)}} \sum_{i=1}^N \hat{\phi}_k^{(p)}(y_i) y_i \quad (12)$$

$$\sigma_k^{(p+1)} = \sqrt{\frac{1}{\Phi_k^{(p)}} \sum_{i=1}^N \hat{\phi}_k^{(p)}(y_i) y_i^2 - (\mu_k^{p+1})^2} \quad (13)$$

$$\hat{\phi}_k^{(p)} \equiv \frac{\phi(y|\mu_k^{(p)}, \sigma_k^{(p)})}{g(y|\pi^{(p)}, \mu^{(p)}, \sigma^{(p)})} \quad (14)$$

$$\Phi_k^{(p)} \equiv \sum_{i=1}^N \hat{\phi}_k^{(p)}(y_i) \quad (15)$$

実際の処理では E ステップの計算を行う必要はなく, M ステップの式 (11), (12), (13) を繰り返し計算することでパラメータを求める.

2.2.2 周期性を持つデータを扱う際の問題点

本研究では, 移動方向 d と速度 v を混合正規分布によりモデル化する. ここで問題となるのが移動方向 d に対する当てはめである. 移動方向 d は角度で表され, 値は $0 \leq d < 2\pi$ となる. しかし, 角度は周期性を持

つため, 本質的には $0 = 2\pi$ という関係がある. そのため, 0 付近の値と 2π 付近の値の差は小さくなくてはならない. 通常の EM アルゴリズムの混合正規分布の推定ではこの点を考慮していないため, 0 付近のクラスと 2π 付近のクラスを異なる正規分布で表現しなくてはならない. これは確率密度関数の不連続性や, 当てはめに必要な正規分布数が多くなることから望ましくない. 特に正規分布数の増加は, 初期値依存が大きくなることやオーバーフィッティングが発生しやすいことなどにもつながる. そこで, 周期性を持つデータののための正規分布当てはめの方法について検討する.

2.2.3 周期性を持つデータへの対処

一般の EM アルゴリズムによる正規分布当てはめで, 周期性を持つデータが扱えない原因は, 確率密度関数を表現する正規分布式 (10) が周期性を表現できないためである. 正規分布は平均 μ から y が離れるほど $\phi(y)$ の値が小さくなる. 本来 $\mu = 0$ のとき $y = 2\pi$ では値出力は最大となるべきであるが, 式 (10) にそのまま値を代入すると値は小さくなる. そこで, 確率密度関数の表現に用いる正規分布の式を以下のように変形することで周期性の表現を行う.

$$\Delta d = \begin{cases} 2\pi - |\mu - d| & |\mu - d| > \pi \\ |\mu - d| & |\mu - d| \leq \pi \end{cases} \quad (16)$$

$$\phi(y|\mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{\Delta d^2}{2\sigma^2}\right) \quad (17)$$

また, パラメータ推定で問題となるのが平均 μ である. EM アルゴリズムによる μ の推定式 (12) は入力値 y の重み付き平均と考えることができる. 平均の求め方そのままを角度にも用いると, 0 と 2π の平均が π となってしまう, 本来推定すべき 0 , もしくは 2π とはならない. そこで, 平均の推定にはベクトルの合成を用いる.

$$a = \frac{1}{\Phi_k^{(p)}} \sum_{i=1}^N \hat{\phi}_k^{(p)}(y_i) \cos(d_i)$$

$$b = \frac{1}{\Phi_k^{(p)}} \sum_{i=1}^N \hat{\phi}_k^{(p)}(y_i) \sin(d_i)$$

$$\mu = \tan^{-1} \frac{a}{b} \quad (18)$$

2.3 混合正規分布の当てはめ

周期性を持つデータに対する当てはめの有効性を確認する. 通常の EM アルゴリズムと, 周期性を持つデータに対する当てはめを行う EM アルゴリズムの比較を行う. 図 3 に正規分布数 $k = 2$ としたとき, 2 つの正規分布の当てはめ例を示す.

通常の EM アルゴリズムでは, 移動方向が 320 度から 40 度にわたる分布の当てはめができていないことが

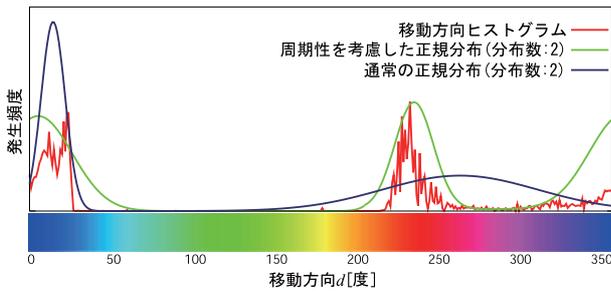
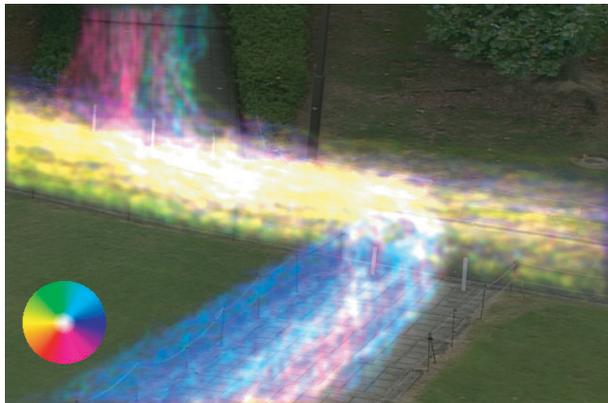


図3 混合正規分布の当てはめ例 ($k=2$)

わかる。これは、平均 μ のパラメータ推定に問題があり、移動方向の角度が 0 から 2π にわたった正規分布の当てはめに失敗するからである。一方、平均 μ のパラメータ推定にベクトルの合成を用いると、 220 度から 260 度と、 320 度から 40 度のそれぞれに正規分布の当てはめが可能であることがわかる。



(a) 移動方向の発生頻度



(b) 検出結果

図4 例外行動の検出例

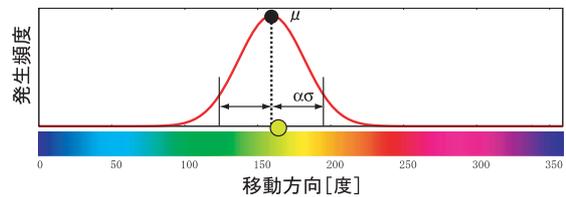
3 定常的な動きモデルを用いた例外行動検出

例外行動の判定には、モデルのパラメータである各正規分布の平均 μ_k と標準偏差 σ_k を用いる。特徴点の移動方向 d と μ_k との距離が $\alpha\sigma_k$ 以上であればモデルに含まれない例外行動として検出する。判定式を次式

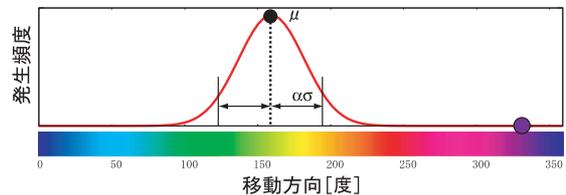
に示す。

$$\min_k |d - \mu_k| > \alpha\sigma_k \quad (19)$$

係数 α は $\alpha > 0$ であり、小さくするほど検出判定は厳しくなる。本稿の実験では全て $\alpha = 1.5$ としている。この値は予備実験に決定したものである。



(a) 定常行動



(b) 例外行動

図5 特徴点の移動方向と行動モデルとの比較

図4(a) は約1時間の歩行者の移動方向の頻度を可視化した画像であり、画像中央を横切る道では左方向への移動が定常的であることがわかる。図5は、このモデルを用いた例外行動の検出結果である。定常的な移動である左方向に進む人の動き(図5(a))では、モデルの

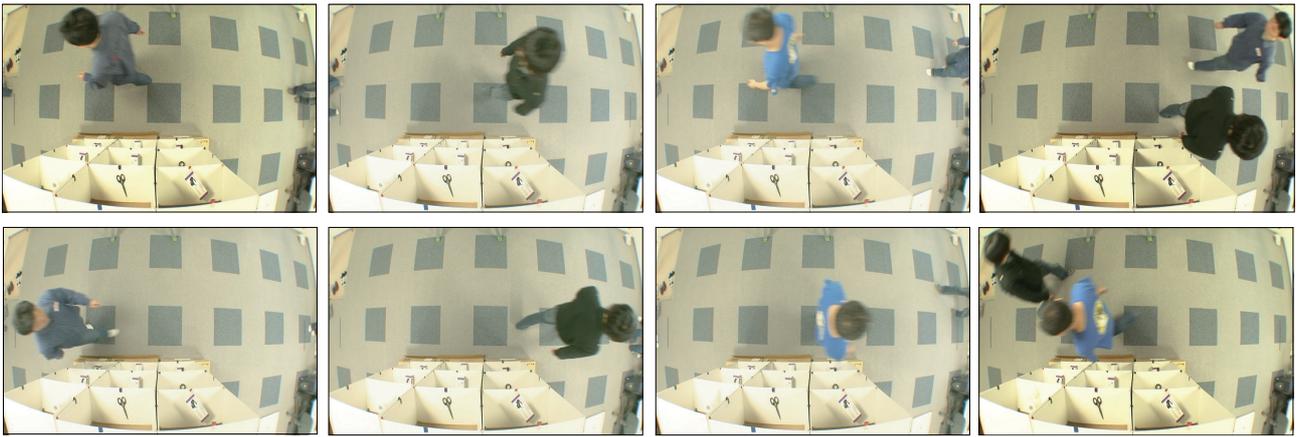


図6 商品棚を通過する人の学習用画像

正規分布からの距離が近い移動方向であるため、定常行動として認識される。一方、モデルの定常行動から外れる右方向に進む人の動き（図5(b)）では、モデルの正規分布から離れた移動方向を観測されるため、定常モデル外として検出される。図4(b)に例外行動の検出例を示す。モデルの発生頻度の高い移動方向に移動する人（赤色の円）は、モデルに示す動きと一致するため、定常行動と判断されている。一方、モデルの発生頻度が低い移動方向に移動している人（青色の円）は、モデルから外れた動きとなるため、行動モデル外としてその特徴点が検出されていることがわかる。

4 マーケティングへの応用

コンビニやスーパーマーケット等の販売店において、購買者の年齢や性別、商品の人気は売り上げにかかわる重要な情報である。このような情報は、マーケティングとしてレジや売り上げの記録等から収集されているが、多くは人手によるものであり、コストが問題となっている。また、店舗内での購買者の動き、どのような商品に興味を持つのか、商品の配置による宣伝効果など、売り上げに大きく影響すると考えられる。提案手法をマーケティングに応用することにより、購買者の商品に対する注目行動の検出を行う。店舗内での人の動きは大きく分けて以下の2種類であると考えられる。

- 商品棚を通過する動き
- 商品注目行動

商品棚を通過する動き以外は、商品を手取る、かごに入れる、棚に戻すなどの商品注目行動に関連するものであり、これらを自動的に検出することでマーケティングに重要な情報を抽出することを目指す。商品棚を通過する動きは、通路の順方向、逆方向への動きがほとんどであるため、これらをモデル化し、モデル以外の例外の動きを商品注目行動として検出する。

表1 AB領域の通過人数

領域	左方向	右方向
A	31	22
B	8	31

4.1 商品棚を通過する動きの行動モデルの学習

商品注目行動は多種多彩であるため、それらをモデル化するのではなく、商品棚を通過する動きを定常行動としてモデル化する。従って、学習には商品棚の前を通過する図9に示す画像を用いる。今回は、商品棚やレジ等の位置関係から、人の流れが右側通行になりやすい店舗を仮定し再現した。行動モデルは、図7(a)に示すように、画像を縦横それぞれを5分割にした、計25の小領域ごとに作成する。また、混合正規分布の当てはめには、正規分布数を $k = 2$ とする。学習データのモデル化の結果を確認するため、図7(a)中のAとBの領域における左右方向の通過人数を表1に示す。Aの領域では、左右方向に進む人が多く、Bの領域では左方向に通過する人が多い。このときの学習で得たAとBの混合正規分布は図7(b)(c)である。Aの混合正規分布では、進行方向の180度と0度に進む人の動きが観測され、Bの混合正規分布でも、進行方向の180度と0度に進む動きが観測されるが、右側通行のため180方向の動きが弱く表現されている。以上のように、学習画像に含まれる動きを領域毎にモデル化されたことがわかる。

4.2 検出方法

入力画像に特徴点追跡を行い、次式を満たす点を検出し、各領域毎で次式の条件を満たす特徴点の割合がしきい値以上である時、商品注目行動として検出する。

$$c < \frac{p_{out}}{(p_{in} + p_{out})} \quad (20)$$

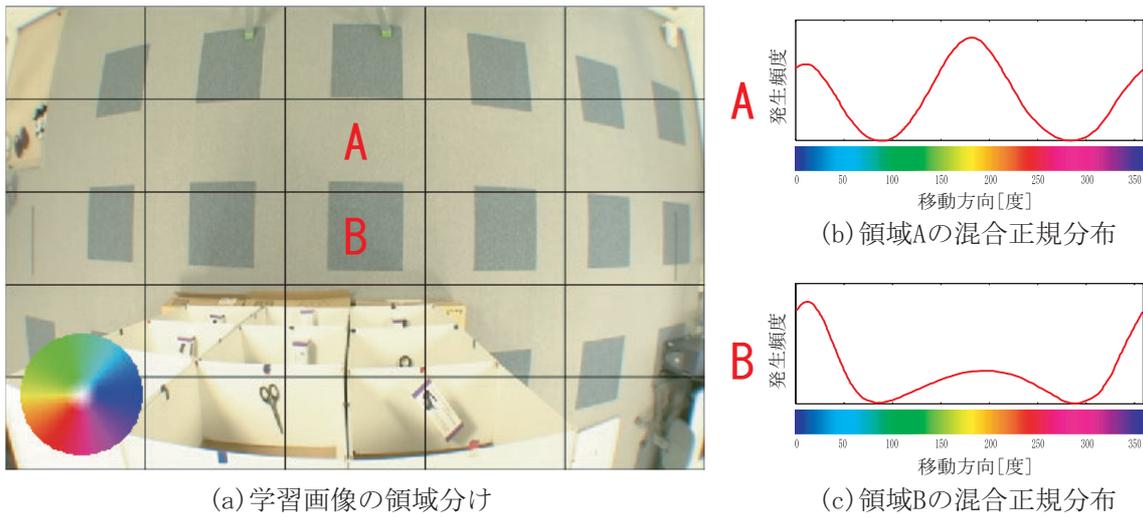


図7 学習画像の領域分けと各領域のモデル

p_{in} は各領域内の行動モデルに当てはまる追跡点の数を示し, p_{out} は, 行動モデルに当てはまらない追跡点の数を示している. c はモデルから外れた特徴点の割合のしきい値である.

1 フレームの特徴点の動きは画像のノイズ等により, 定常運動にもかかわらず, 特徴点が定常外の方向に移動することがある. そのため, 1 フレームの検出結果のみを用いた商品注目行動の検出は誤検出が多くなりやすい. そこで, 検出精度を上げるため, 過去のフレームの検出結果を用いて商品注目行動を検出する. 検出は, 定常モデルから離れたフレーム数を人単位で蓄積し, しきい値以上のフレーム数で検出されると, 商品注目行動として検出する.

4.3 実験結果

定量的に評価を行うため, 商品注目行動をする人の検出率と商品棚を通過する動きのみの人の誤検出率を求める. 商品注目行動の検出率を図8に示す.

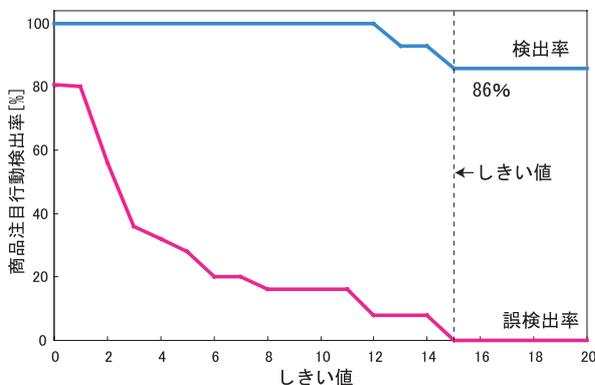


図8 商品注目行動の検出率

しきい値が15としたとき, 商品注目行動の検出率は86%を得ることができた. 商品注目行動は, 商品に手を伸ばす, 立ち止まる, 商品に向かう, しゃがむ, 商品を眺める等, 単純な行動ではない. 提案手法では, このような商品注目行動の複雑なモデルを作成しないで, 単純な店舗内の移動モデルのみを用いて, 商品注目行動を高精度に検出をすることができた.

図9に商品注目行動検出例を示す. 図9(a)は検出に成功した例, 図9(b)は未検出の例, 図9(c)は誤検出の例である. 未検出には大きく別けて2通りの場合がある. 1つは動きが少なく, 追跡点がほとんど発生していない場合である. 動いていない場合では, 追跡点の動きが安定しないため, 3フレームにおいて移動方向の変化が少ない追跡点のみを使うため, 動いていない物では追跡点が減少するためである. もう1つは追跡点は多数存在するが, 行動モデルに近い動きをしているため検出できない場合である. これはモデルが商品注目行動と移動の違いを表現できていないためである. 誤検出の場合は, 移動中の手や足の動きなどを検出する機会が多い. これは体全体と比べて手足は動きのばらつきが大きいためである.

今後はこれらの問題を対処するために, 特徴点のクラスタリングを行う必要がある. これにより, 1つの特徴点の動きだけではなく, 周囲の特徴点の動きを考慮することで, 移動体全体の移動方向がわかる. その情報を用いることで, 移動中における手足の動きの問題を解決することが期待できる.

5 おわりに

本稿では特徴点追跡結果を用いた例外行動検出について提案した. また, EM アルゴリズムで周期性を持つデータの当てはめを提案し, 移動方向の角度が0から

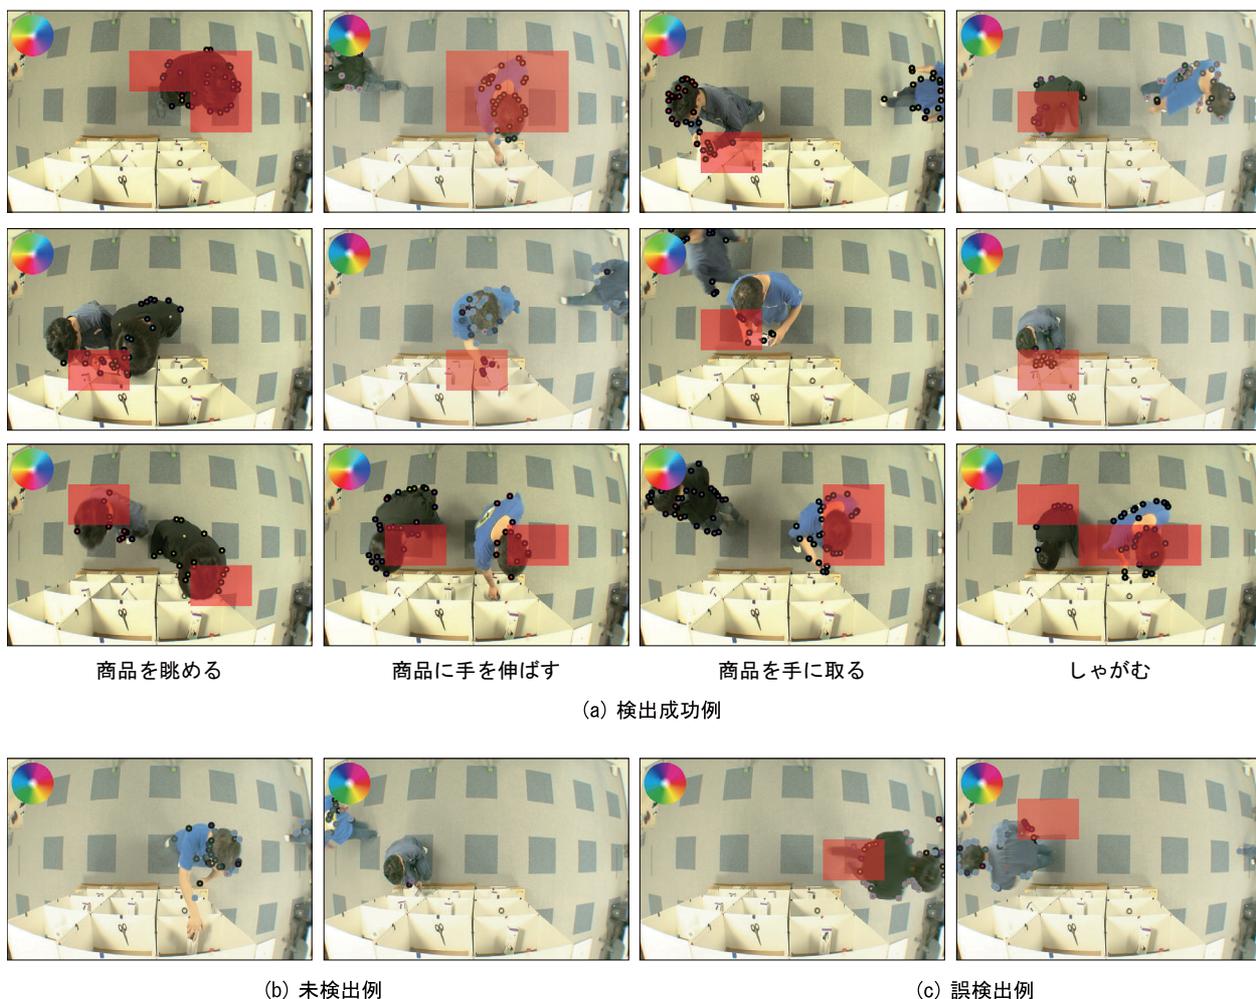


図9 商品注目行動の検出結果

2π にかけての正規分布の当てはめが可能になった。本手法の応用として例外行動検出のマーケティングへの応用について述べた。また、単純な商品棚を通過する動きの行動モデルのみを用いて、商品注目行動を検出率 86% と高い検出精度を得ることができた。商品を手にするなどの行動を検出することにより、商品がどれだけ注目されているかを知ることが可能で、より詳細なマーケティングデータを得ることが可能である。今後の課題として、よりマーケティングに特化した検出方法を検討する予定である。

参考文献

[1] 青木茂樹, 岩井嘉男, 大西正輝, 小島篤博, 福永邦雄, “人物の位置・姿勢に注目した行動パターンの学習・認識と非日常状態検出への応用”, 信学論 (D-II), Vol.J87-D-II, No.5, pp.1083-1093, 2004.

[2] 南里卓也, 大津展之, “複数人動画像からの異常動作検出”, 情報処理学会論文誌 CVIM 12, Vol.46, No.SIG-15, pp.43-50, 2005.

[3] 青木康洋, 岩井儀雄, 谷内田正彦, “全方位画像による例外行動の検出”, 情報処理学会 研究報告 CVIM 154, pp.91-98, 2006.

[4] Rabiner, L. R. “A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition”, Proceeding of the IEEE, Vol.77, No.2, pp.257-286, 1989.

[5] David G.Lowe, “Distinctive image features from scale-invariant keypoints”, Int.Journal of Computer Vision, Vol.60, No.2, pp.91-110, 2004.

[6] D.Comaniciu, P.Meer, “Mean shift analysis and applications”, Proc. IEEE Int.Conf. on Computer Vision, pp.1197-1203, 1999.

[7] 都築勇司, 藤吉弘巨, 金出武雄, “SIFT 特徴量に基づく Mean-Shift 探索による特徴点追跡”, 情報処理学会論文誌 CVIM 20, Vol.49, No.SIG-6, pp.35-45, 2008.

[8] 赤穂昭太郎, “EM アルゴリズムの幾何学”, 情報処理, Vol.37, No.1, pp. 43-51, 1996.