

ウェーブレット処理とSVMを用いたMHIによる不審動作監視

石橋 卓弥*, 藤ノ木 健介**, 岡宅 泰邦**

Unusual Behavior Monitoring Method Using MHI by Wavelet Preprocessing and Support Vector Machine

Takuya ISHIBASHI*, Kensuke FUJINOKI**, Yasukuni OKATAKU**

ABSTRACT

This paper prescribes an approach for providing a method of detecting unusual human behavior from video images processed by Motion History Image (MHI) method. The video input data are pre-processed by Gabor filter or Haar wavelet transform and formulate MHI which are classified by SVM learning examples of usual and unusual behaviors. The four types characteristic features derived from MHI data are evaluated.

Key Words: Motion History Image, MHI, support vector machine, SVM, wavelet, Gabor filter, Haar wavelet transform

1. はじめに

セキュリティ意識の高まりや犯罪防止の見地から、各種店内やビルには多くの防犯監視カメラが設置されている。重要な施設では、専門職員やセキュリティ会社員による常時監視が行われている。しかしながら、24時間体制で監視できる組織は限られている。さらに、港湾施設や夜間人通りの少ない街中や郊外での不審者を従来の人によるリアルタイム監視方式では膨大なコストが生じることになる。不審者挙動を通常人の挙動（以下、通常挙動と記す）に対して、非通常挙動と以下記すこととする。本研究の目的は、ビデオカメラによるリアルタイム監視データ（30フレーム/秒）から非通常挙動を自動検出することである。このようなリアルタイム非通常挙動検出は、低コストの監視システムを提供することにつながる。

本研究での通常挙動と非通常挙動の定義は、対象システム毎に定義するものとしている。例えば、許可された人間しか入れない建物の前の道路上を通行する人の通常挙動は、建物の前をまっすぐに通行するのがふつうであるのに対し、非通常挙動者では、物陰に隠れたり、上下に体を移動させたり、道路上を蛇行したり大きく暴れたりする行動などを指す。

ビデオ画像から人物の挙動を認識する手法の1つとして、人物の見かけの動きを表す特徴量に Motion History Image(MHI)が提案されており、

MHIの濃度勾配ヒストグラム⁽¹⁾を人物挙動の特徴路用として用いる方法が提案され、良好な認識結果を得ている^{(2),(3)}。

2. これまでのMHI処理手法

これまで提案されたMHI手法の概要について記す。

2.1 概要

文献[3]で提案されているMHI処理では、まず収集したビデオ画像の複数フレームからMHI処理し、MHI処理したシーン中の人物領域を切出して特徴量を抽出する。抽出した濃度勾配特徴量は次元数が684(6×6×19)次元と大きいので、それを固有空間法（主成分分析法）により10～200次元に圧縮した特徴量を用いている。文献[3]では、30次元時で最も良好な通常挙動と非通常挙動の識別結果を得ている。

2.2 これまでの課題

文献[3]では、次元圧縮した濃度勾配方式が、MHIパターンそのものよりも通常／非通常挙動判定能力が最も良好との結論であるが、単一人物の挙動を前提としており、複数人物の挙動についての有効性は未知である。本論文では単一人物および複数人が関係するMHI画像において、濃度勾配

方式を含めた他の手法も検討し、それらの判定能力を検証する。

3. 提案方式

以下の1~8の手順で画像処理と機械学習を行う。

- 1: サンプル動画の撮影。
- 2: サンプル毎に、フレーム間差分処理。(以下サンプル毎)
- 3: フレーム間差分処理画像のGabor filterあるいは、ハールウェーブレット変換処理による鮮鋭化。
- 4: MHI(Motion History Image)手法による一定フレーム数(例:20フレーム)内の移動体履歴生成。
- 5: MHI処理データから特徴抽出し、MHI特徴ベクトルを生成。
- 6: 上記の高次元MHI特徴ベクトルを計算コスト上から低次元化処理を行う。本論文では、MHI特徴ベクトルを固有空間法(KL展開手法)で次元圧縮した特徴ベクトルをはじめ、いくつかの手法についても有効性を検討する。
- 7: 全MHI特徴ベクトルをSVM(Support Vector Machine)で学習。
- 8: 未知移動体のMHI特徴ベクトルをSVM学習モデルで評価。

以下で、手順を詳細に記す。

3.1 Gabor Filterによる前処理

Gabor Filterは線型フィルタの一種で、そのインパルス応答は調和関数とガウス関数をかけたもので、式(3.1.1)で表現される。

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + y'^2}{2\sigma^2}\right) \cos\left(2\pi \frac{x'}{\lambda} + \psi\right) \quad (3.1.1)$$

$$x' = x \cos \theta + y \sin \theta \quad y' = -x \sin \theta + y \cos \theta$$

図1にGabor Filter処理(以下、GF処理)した例を示す。1コマのGF処理では、各座標点での強度 g は、 g が最大となる θ での値である。各座標点で、20度刻みで式(3.1.1)を計算するため、計算量が多くなる。Intel corei3CPU(3.2GHz)での1コマ(128×72)の処理が4000msec~5000msecであり、20~30コマで1つのMHIイメージ生成に時間を要する。

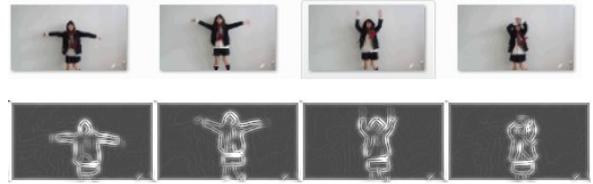


図1 Gabor Filter処理例

3.2 3角形ハールウェーブレット変換(THWT: Triangular Haar Wavelet Transform)⁽⁴⁾による前処理

フーリエ変換が全空間あるいは全時間幅にわたって、言い換えれば無限に続く局在性を有しない三角関数や複素指数関数を用いるため、変換後の周波数領域では空間/時間に関する情報は完全に失われている。このフーリエ変換の短所を補うために適当な窓関数を乗じてフーリエ変換する短時間フーリエ変換があるが、この考えを発展させたのがウェーブレット変換である。本論文では、深さ1の離散ハールウェーブレット基底を用いたハールウェーブレット基底の特徴は、無限次元L2空間での正規直交基底を構成するので、完全再構成が可能である。

本論文では、レベル1の有限離散ハールウェーブレット(Haar Wavelet)基底関数を用いる。GFの1フレーム当たりの処理の約10分の1と高速であり、直交基底のため元画像の完全再構成が可能である。

本論文では、ハールウェーブレットをリフティング(昇降法)スキームで構成する。リフティングでは、まずデータ $x(t)$ を偶数番目と奇数番目に分割する。偶数番目は低周波成分(coarse component)を表し、奇数番目は高周波成分(detail component)を表す。

$$\text{偶数成分} : x_{\text{even}}(t) = x(2t)$$

$$\text{奇数成分} : x_{\text{odd}}(t) = x(2t + 1)$$

各成分は、元の信号サンプルの半分の数だけであり、この奇数と偶数への分割をLazytransformationと呼ぶ。次に、偶数成分と奇数成分の差分を $d(t)$ とし、それをもとに平均成分 $c(t)$ を得る。

$$d(t) = x_{\text{odd}}(t) - x_{\text{even}}(t)$$

$$c(t) = x_{\text{even}}(t) + d(t) / 2$$

それぞれの処理は prediction と update と呼ばれ、 $c(t)$ は低周波成分 (coarse component) を表し、 $d(t)$ は高周波成分 (detail component) を表す。リフティングのスキームを図2に示す。ここでリフティングの各ステップを反転させれば、構造上元の $x(t)$ を再構成することができる。

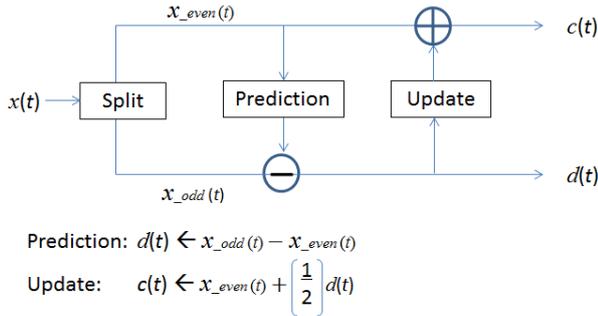


図2 リフティングのスキーム

入力ビデオ画像のフレーム間差分を上記リフティングスキームで4角度方向 (0° , 90° , $+45^\circ$, -45°) についてTHWT処理を行い、それらの最大値をその点のTHWT値とした。

図3は、図1と同様の元画像をTHWT処理したものである。



図3 THWT処理例

3.3 MHI生成

THWT処理した隣接フレーム(例; 20フレーム)のフレーム間差分を取り、フレーム差分履歴を1フレームに集約するのがMHI処理である。MHI処理では、式(3.3.1)によって動画の過去から現在までの所定期間のフレーム間の変化を1枚の静止画像に蓄積することにより求められる。

$$H\tau(x, y, t) = \begin{cases} \tau & \text{if } D(x, y, t) = 1 \\ \max(0, H\tau(x, y, t-1) - 1) & \text{otherwise} \end{cases} \quad (3.3.1)$$

MHI処理に使用する元画像フレームを図4, MHI処理結果例を図5に示す。図5はGFとTHWTによるMHI処理結果である。

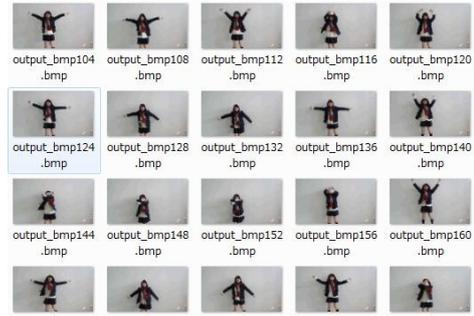


図4 MHI作成に用いたフレーム



(a) GF処理結果



(b) THWT処理結果

図5 MHI処理結果

3.4 特徴抽出

MHIの濃度勾配方向ヒストグラムを、人物挙動の特徴量として、4種類を想定した。

(1) 1番目は、文献[3]で使用されている濃度配方向 $\theta(x, y, t)$ の分布で次式(3.4.1)により算出する。

$$\theta(x, y, t) = \tan^{-1} \left(\frac{H\tau(x, y+1, t) - H\tau(x, y-1, t)}{H\tau(x+1, y, t) - H\tau(x-1, y, t)} \right) \quad (3.4.1)$$

20度刻みで $\theta(x, y, t)$ を算出する 128×72 の画像領域を 8×6 の小領域に分割し、そこでの各座標でのMHIの濃度勾配量とする。濃度勾配特徴量は $8 \times 6 \times (360/20) = 864$ 次元データとなるが、固有空間法で14次元に削減したベクトル量(固有顔)を特徴量とする。図6に濃度勾配特徴量の例を示す。画面領域全体で動きのある角度方向は限られるので、0度方向の頻度が大きくなっている。

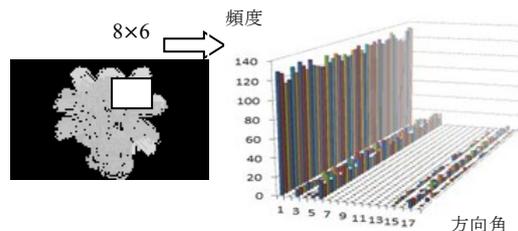


図6 864次元濃度勾配特徴量例

(2) 2番目の特徴量は、各角度($t=0, 20, \dots, 340$)の頻度総計 $= \sum_{x,y} \theta(x, y, t)$ を特徴量(18次元)とするものである。

(3) 3番目の特徴量は、 128×72 次元MHIイメージを576次元、144次元の縮小画像にしたものを特徴量とする場合である。

(4) 4番目の特徴量は、図6の864次元濃度勾配の中で、0度方向と、頻度がゼロとなっている角度を除いた選択的濃度勾配分布を使用した。図7に示すように9つの角度方向のみを特徴量

($8 \times 6 \times 9 = 432$ 次元)として使用する。

通常挙動と非通常挙動の各動作パターンとそれらのMHIと濃度勾配分布の代表例を図8, 図9に示す。

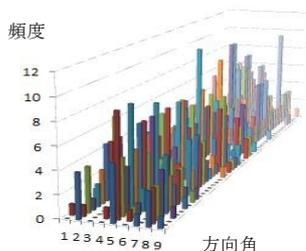
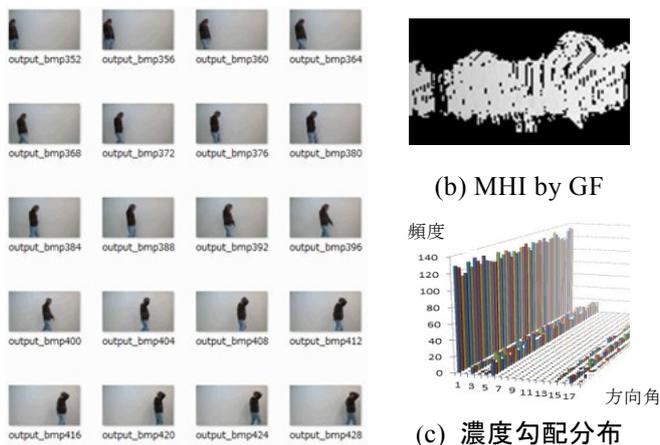
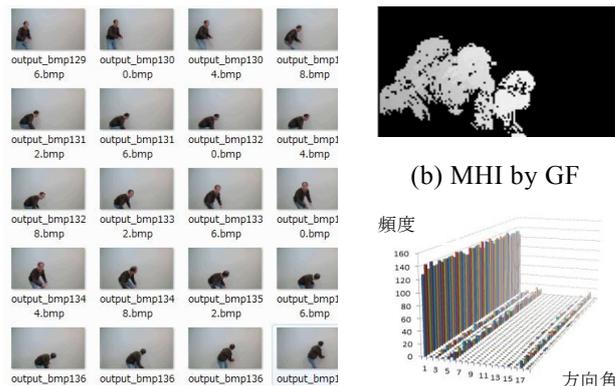


図7 432次元濃度勾配特徴量例



(a) 通常挙動 (20コマ)

図8 通常挙動



(a) 非通常挙動 (20コマ)

(c) 濃度勾配分布

図9 非通常挙動 1

図8の通常挙動は、普通に前を向いて前進しているのに対し、図9の非通常挙動は、あたりを伺うようにしゃがんだりして移動している。MHIパターンにはかなりの違いが見られるが、濃度勾配分布ではそれほど大きな違いは見られない。

3.5 サポートベクターマシン

サポートベクターマシン (Support Vector Machine, SVM) ^{(5),(6)}は2クラス分類のための機械統計学習手法の一つで、SVMは基本構造が単純パーセプトロンの線形しきい素子ながらも、多層パーセプトロンに劣らない高い汎化性能を有する。以下、パターン識別器として利用するSVMの識別アルゴリズムについて説明する。

一般に、訓練サンプルを $\{(x_i, y_i); i = 1, 2, \dots, n\}$ とし、入力パターン $x_i \in \mathbb{R}^d$ とした線形識別関数 $f(x)$ は次式(3.5.1)で表される。

$$f(x) = w^t x + b \quad (3.5.1)$$

ここで、係数 w は線形識別器の重みベクトル b は非負値バイアス項である。 $f(x) = 0$ を満たす任意の $d - 1$ 次元の識別関数は以下で表される。

$$\{x \in X: (w^t x) + b = 0\} \quad (3.5.2)$$

しかし、式(3.5.2)からだけでは、定数 $\lambda (\neq 0)$ を w, b にかけたものすべてが、線形識別関数とみなされてしまう。そのため、クラスを分割する超平面から、最近傍であるサンプル点までの距離(幾何学マージン γ)を最大とする w, b を求めることで、最適超平面を構成する。マージンは式(3.5.3)であらわされる。

$$\gamma(w, b) = \min_{i=1, \dots, n} \frac{|(w^t x) + b|}{\|w\|} \quad (3.5.3)$$

w , b に定数 λ をかけてもマージンは変化しないので、一意の解を得るため、以下の条件を設ける。

$$\min_{i=1, \dots, n} |(w^t x) + b| = 1 \quad (3.5.4)$$

式(3.5.4)の制約条件は以下と等価である。

$$\psi_i((w^t x) + b) \geq 1 \quad i = 1, \dots, n \quad (3.5.5)$$

したがって、SVMの学習は、以下の制約つき最適化問題を解くことに帰着する。

目的関数 : $\min \|w\|^2$

制約条件 : $\psi_i((w^t x) + b) \geq 1 \quad (i = 1, \dots, n)$

以上の制約つき最適化問題を双対問題化するため、ラグランジュ乗数 α を導入し、

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i \{ \psi_i((w^t x_i) + b) - 1 \} \quad (3.5.6)$$

というラグランジュ関数を得る。最適化問題を解くには、このラグランジュ関数を α_i について最大にし、ここで α_i および b について最小化する必要がある。すなわち、 w および b に関する停留点

$\frac{\partial L}{\partial w} = 0, \frac{\partial L}{\partial b} = 0$ について解くと

$$\frac{\partial L(w, b, \alpha)}{\partial w} = w - \sum_{i=1}^n \alpha_i \psi_i x_i = 0,$$

$$\frac{\partial L(w, b, \alpha)}{\partial b} = \sum_{i=1}^n \alpha_i \psi_i = 0 \quad (3.5.7)$$

の関係を得る。この式(3.5.7)より

$$w = \sum_{i=1}^n \alpha_i \psi_i x_i, \quad \sum_{i=1}^n \alpha_i \psi_i = 0 \quad (3.5.8)$$

が成立する。式(3.5.8)を式(3.5.6)へ代入すると

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i \{ \psi_i((w^t x_i) + b) - 1 \} = \frac{1}{2} \sum_{i,j=1}^n \psi_i \psi_j \alpha_i \alpha_j (x_i^t x_j) - \sum_{i,j=1}^n \psi_i \psi_j \alpha_i \alpha_j (x_i^t x_j) + \sum_{i=1}^n \alpha_i = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \psi_i \psi_j \alpha_i \alpha_j (x_i^t x_j)$$

となる。これより、双対問題となる以下の凸最適化問題を得ることができる。

目的関数:

$$L(\alpha) = \max. (\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \psi_i \psi_j \alpha_i \alpha_j (x_i^t x_j))$$

制約条件:

$$\sum_{i=1}^n \alpha_i \psi_i = 0, \alpha_i \geq 0 \quad (i = 1, \dots, n)$$

この解を α^* とし、式(3.5.8)を式(3.5.1)へ代入すると、分類されるパターンと超平面との内積で評価される次式(3.5.9)に書き換えられる。

$$f(x) = \text{sign}(\sum_{i=1}^n \alpha_i \psi_i (x_i^t x) + b) \quad (3.5.9)$$

ただし、 x_i は $\alpha_i^* > 0$ となるサンプルに限定。

以上が線形SVMの識別関数となる。

4. MHIによる識別実験

2通りの通常/非通常挙動ビデオデータを使用した評価実験を実施し、MHI特徴量の評価を行った。

4.1 通行シーン 1

カメラの前をまっすぐ1人ないし2人で通行するシーンを通常挙動とし、図10のようなシーンを非通常挙動と分類した場合での識別実験である。

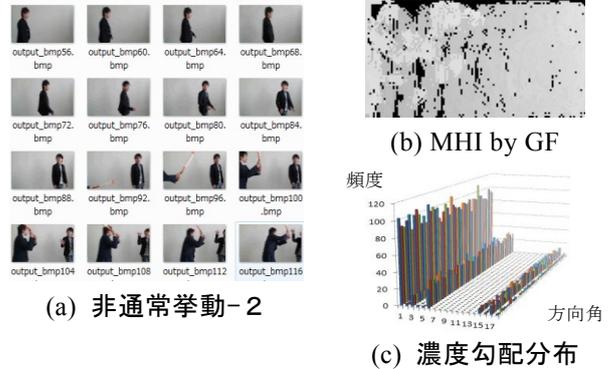


図 10 非通常挙動 2

以下3.4節で記した、特徴量候補による評価実験結果を記す。

(a) 14次元濃度勾配分布による識別

864(8×6×360/20)次元MHIデータを固有空間法で14次元に縮約した特徴量をSVM評価データとする。MHIデータはGFおよびTHWTの2通りで処理して比較する。通常挙動データ数は46、非通常挙動データ数は33である。

SVM訓練データは通常挙動、非通常挙動それぞれ14サンプルであり、SVM学習は非線形カーネル(シグモイド関数)で行った。

表1 14次元濃度勾配分布による識別結果

誤認識率% (SVM閾値=0)		
判定対象データ	GF	THWT
通常挙動	38%(12/32)	学習
非通常挙動	47%(9/19)	不可

(b) MHI濃度勾配の角度分布による識別

MHI濃度勾配の各角度($t=0, 20, \dots, 340$)の頻度総計 $= \sum_{x,y} \theta(x, y, t)$ を特徴量(18次元)とした場合での識別機能を調べた。SVM学習は線形カーネルを用いた。訓練データは通常挙動、非通常挙動とも4サンプルずつである。

表2.1 MHI濃度勾配の角度分布による識別結果

誤認識率% (SVM閾値=0)		
判定対象データ	GF	THWT
通常挙動	50%(19/38)	5%(2/43)
非通常挙動	28%(7/25)	69%(20/29)

表2.2 MHI濃度勾配の角度分布による識別結果

誤認識率% (SVM閾値=0.2)		
判定対象データ	GF	THWT
通常挙動	52%(20/38)	25%(11/43)
非通常挙動	16%(4/25)	38%(11/29)

(c) 576次元, 144次元 MHI画像による識別

128×72次元MHI画像を576次元, 144次元の縮小画像にした場合での識別機能を調べた。SVM学習は線形カーネルを用いた。

表3.1 576次元MHI画像による識別結果

576次元, 誤認識率% (SVM閾値=0)		
判定対象データ	GF	THWT
通常挙動	44%(19/43)	23%(10/43)
非通常挙動	28%(8/29)	52%(15/29)

表3.2 576次元MHI画像による識別結果

576次元, 誤認識率% (SVM閾値=0.2)		
判定対象データ	GF	THWT
通常挙動	49%(21/43)	51%(22/43)
非通常挙動	14%(4/29)	31%(9/29)

表3.3 576次元MHI画像による識別結果

576次元, 誤認識率% (SVM閾値=0.3)		
判定対象データ	GF	THWT
通常挙動	49%(21/43)	81%(35/43)
非通常挙動	14%(4/29)	10%(3/29)

表3.4 144次元MHI画像による識別結果

144次元, 誤認識率% (SVM閾値=0)		
判定対象データ	GF	THWT
通常挙動	44%(19/43)	21%(9/43)
非通常挙動	21%(6/29)	55%(16/29)

表3.5 144次元MHI画像による識別結果

144次元, 誤認識率% (SVM閾値=0.2)		
判定対象データ	GF	THWT
通常挙動	47%(20/43)	33%(14/43)
非通常挙動	14%(4/29)	31%(9/29)

表3.6 144次元MHI画像による識別結果

144次元, 誤認識率% (SVM閾値=0.3)		
判定対象データ	GF	THWT
通常挙動	51%(22/43)	51%(22/43)
非通常挙動	14%(4/29)	17%(5/29)

(d) 432次元選択的濃度勾配 MHI画像による識別
9角度方向のみ濃度勾配分布を特徴量(8×6×9=432次元)として使用した場合での識別機能を調べた。SVM学習は線形カーネルを用いた。

表4.1 432次元選択的濃度勾配画像による識別結果

432次元, 誤認識率% (SVM閾値=0)		
判定対象データ	GF	THWT
通常挙動	40%(17/43)	5%(2/43)
非通常挙動	31%(7/29)	52%(15/29)

表4.2 432次元選択的濃度勾配画像による識別結果

432次元, 誤認識率% (SVM閾値=0.3)		
判定対象データ	GF	THWT
通常挙動	42%(18/43)	7%(3/43)
非通常挙動	28%(8/29)	35%(11/29)

4.2 通行シーン2

4.1節と同様に4つの特徴量候補による実験結果を記す。また、通行シーン2の通常挙動、非通常挙動の例を図11に示す。通常挙動データ数は90、非通常挙動データ数は20である。



図 1 1 通常，非通常挙動例

(a) 14次元濃度勾配分布による識別

表5 14次元濃度勾配分布による識別結果

誤認識率% (SVM閾値=0)		
判定対象データ	GF	THWT
通常挙動	46%(35/76)	学習
非通常挙動	30%(3/10)	不可

(b) MHI濃度勾配の角度分布による識別

表6.1 MHI濃度勾配の角度分布による識別結果

誤認識率% (SVM閾値=0)		
判定対象データ	GF	THWT
通常挙動	28%(24/86)	学習
非通常挙動	50%(10/20)	不可

表6.2 MHI濃度勾配の角度分布による識別結果

誤認識率% (SVM閾値=0.2)		
判定対象データ	GF	THWT
通常挙動	41%(35/86)	学習
非通常挙動	25%(5/20)	不可

(c) 576次元，144次元 MHI画像による識別

表7.1 576次元MHI画像による識別結果

576次元，誤認識率% (SVM閾値=0)		
判定対象データ	GF	THWT
通常挙動	52%(45/86)	59%(51/86)
非通常挙動	10%(2/20)	35%(7/20)

表7.2 576次元MHI画像による識別結果

576次元，誤認識率% (SVM閾値=0.2)		
判定対象データ	GF	THWT
通常挙動	65%(56/86)	91%(78/86)
非通常挙動	5%(1/20)	10%(2/20)

表7.3 144次元MHI画像による識別結果

144次元，誤認識率% (SVM閾値=0)		
判定対象データ	GF	THWT
通常挙動	7%(6/86)	62%(53/86)
非通常挙動	60%(12/20)	50%(10/20)

表7.4 144次元MHI画像による識別結果

144次元，誤認識率% (SVM閾値=0.1)		
判定対象データ	GF	THWT
通常挙動	49%(42/86)	73%(63/86)
非通常挙動	10%(2/20)	30%(6/20)

(d) 432次元選択的濃度勾配画像による識別

表8.1 432次元選択的濃度勾配画像による識別結果

432次元，誤認識率% (SVM閾値=0)		
判定対象データ	GF	THWT
通常挙動	10%(9/86)	40%(34/86)
非通常挙動	90%(18/20)	55%(11/20)

表8.2 432次元選択的濃度勾配画像による識別結果

432次元，誤認識率% (SVM閾値=0.3)		
判定対象データ	GF	THWT
通常挙動	15%(13/86)	100%(86/86)
非通常挙動	90%(18/20)	0%(0/20)

5. 考察

MHI画像をベースにした通常・非通常挙動解析実験結果の考察を記す。実験結果が示すように、GF処理、THWT処理双方ともMHI処理画像を用いた動作挙動の判別性能は、どの特徴量を用いても、30%～50%の識別誤りが生じている。非通常挙動を低く抑えれば、通常挙動識別率が低下し、ほとんどの動きを非通常挙動と認識し、誤アラームの元となる。したがって、本論文で検討した段階では、実用的レベルに達していないと言える。この直接の原因は、

- (1) MHI画像そのものでも通常挙動と非通常挙動でよく似通ったものが混在していた、

(2) 次元圧縮前のMHI画像濃度勾配分布そのもので、通常挙動と非通常挙動でよく似通ったものが混在していた。

の2点に集約される。そのため、SVM学習による良好な分離超平面が生成できず、判別性能が低くなる結果となった。

これらについて、

要因1：入力ビデオデータにおける、通常挙動と非通常挙動の区別の問題があった。

要因2：MHI処理のパラメタ調整とMHI画像からの特徴量抽出に問題があった。

の2点から考察する。

5.1 通常挙動と非通常挙動の定義

入力ビデオデータにおける、通常挙動と非通常挙動の定義が不十分であったと考えられる。適用領域における通常挙動と非通常挙動パターンを限定しておき、それ以外は不明パターン扱いにすることで、不明パターンは発生するが、判別誤り率が減少するものと考えられる。

5.2 MHI処理画像からの特徴量抽出について

MHI処理のパラメタ調整として、式(3.3.1)のパラメタ τ の最適化ができていなかった可能性がある。

また、適用領域が異なれば、用いる特徴量も異なるものと考えられる。例えば、踏み込んではいけない領域が明確であれば、MHI画像の濃度勾配でなく、MHI画像パターンそのものを用いるのが適している。

6. 今後の課題

今後の課題として、

- (1) 入力ビデオデータにおける、通常挙動と非通常挙動を適用領域に適した定義をする必要がある。
- (2) 通常挙動と非通常挙動でのMHI処理画像の差異を大きくする式(3.3.1)のパラメタ τ の最適化を適用領域毎に決定する。

等が挙げられる。

処理性能点からは、GFよりTHWTが10倍以上高速であるため、リアルタイム監視には、THWT方式が望ましい。したがって、THWTを使用した上で、上記(1)、(2)の課題を解決する必要がある。

参考文献

- [1] A. Dala and B. Triggs: "Histograms of Oriented Gradients for Human Detection", Proc. IEEE CVPR2005, pp.886-893(2005).
- [2] A.F. Boblic and J.W. Davis: "The recognition of human movement using temporal templates", IEEE Trans. PAMI, Vol.23, No.3, PP.257-267(2001).
- [3] 竹島徹, 山田啓一: "MHIの濃度勾配ヒストグラムとk最近傍法を用いた動画からの人物の非通常挙動の検出", 田学論C, 131巻2号, pp.425-432(2011).
- [4] Kensuke Fujinoki and Oleg V. Vasilyev, "Triangular Wavelets: An Isotropic Image Representations with Hexagonal Symmetry," EURASIP Journal on Image and Video Processing, Vol. 2009, No. 248581, 1-16 pages (2009).
- [5] N. Cristianini and J. Shawe-Taylor, 大北剛 (訳) サポートベクターマシン入門, 共立出版 (2005).
- [6] SVMlight, http://www.cs.cornell.edu/People/tj/svm_light/.