

Dedormable Part Models による映像中の異常行動検出

Anomalous Behavior Detection in Videos based on Deformable Part Models

杉本 有十 黒木 修隆† 廣瀬 哲也† 沼 昌宏†
 Tamotsu Sugimoto Nobutaka Kuroki Tetsuya Hirose Masahiro Numa

1. はじめに

近年、セキュリティへの関心が高まり、様々な場所に監視カメラが設置されるようになってきている。しかし、監視カメラの導入にあたっては映像を注視する監視員が必要となり相応の雇用コストが必要となる。また、長時間に渡る多数の映像の注視は監視員への体力的、精神的負担が大きく、疲労による異常の見落とし等的人為的ミスが発生する可能性がある。そのため、画像処理技術を用いて自動で異常を検出するシステムに関する研究が盛んに行われている。

従来手法 [1] では表 1 の (例 3) のように監視対象物と侵入物の両方が変化する場合に対応できなかった。そこで提案手法では、Deformable Part Models(DPM) [2] を用いて監視対象物と侵入物を同時に検出する。これにより汎用性の高いシステムを構築する。

2. 提案手法

2.1 提案手法の概要

提案手法は図 1 のように DPM を用いて映像中の物体検出を行い、得られた検出領域およびそのスコアから 4 つの特徴量を抽出する。従来の動き特徴量 E 、位置特徴量 P に加えて、DPM のスコアを利用したスコア特徴量 S 、また、監視対象物と侵入物との相対的な距離を利用した相対動き特徴量 R を抽出する。

以上 4 つの特徴量を従来手法と同様に SVM に渡し、あらかじめ学習しておいたデータをもとに、映像内での異常の有無を判定する。

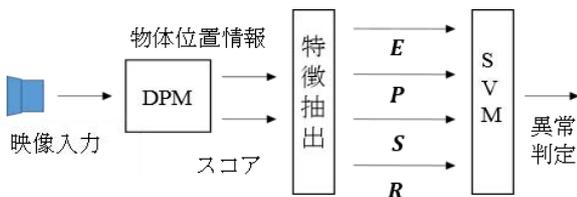


図 1 提案手法の概要

2.2 DPM

DPM とは、HOG 特徴量をベースとし、検出対象をパーツの集合で表現することで、それぞれのパーツの妥当性とパーツの相対位置関係を考慮して物体を検出する手法である。HOG 特徴量のみによる物体検出手法に比べて、検出対象の一部が隠れるオクルージョンに対応することができ、物体の変形にも頑健である。

表 1 汎用監視システムの用途

用途	監視対象物	侵入物
(例 1) 一方通行の違反車両検出	道路 (固定)	車両
(例 2) ATM・ポスト荒らしなどの検出	ATM・ポスト (固定)	人
(例 3) 駐車場荒らしの検出	車・バイク (変動)	人

2.3 スコア特徴量 S

DPM による人検出の際、閾値 th を超えたスコアについてはさらに 8 段階に分類し、分布を調べる。この処理を観測フレーム $1 \sim T$ に関して行い、ヒストグラム $S(i)$ を累積し、8 次元の特徴量とする。

DPM のスコアはモデルとの類似度を示しており、モデルとの類似度が低いほどスコアも低くなる。さらに、姿勢がモデルの形とずれている場合や体の一部が隠れている場合もスコアが低くなる。したがって、しゃがみこむ、物陰に隠れるなどの不審者特有の行動はスコアが変動するため、異常行動検出に有効な特徴量が得られると考えられる。

2.4 相対動き特徴量 R

監視対象物の中心座標と侵入物の中心座標を求め、両者の相対的な動きを 8 方向に量子化し、各方向の移動量をヒストグラム $R(i)$ として蓄積する。監視対象物の位置が動く場合はそれも DPM により検出する。対象物が固定されていて全く動かない場合はあらかじめ対象物の中心座標を決定する。図 2 に相対動き特徴量の概要を示す。不審者は周りを確認するために対象物の周りをうろつくことが多く、異常行動の場合にはヒストグラム R が通常よりも分散する傾向がある。

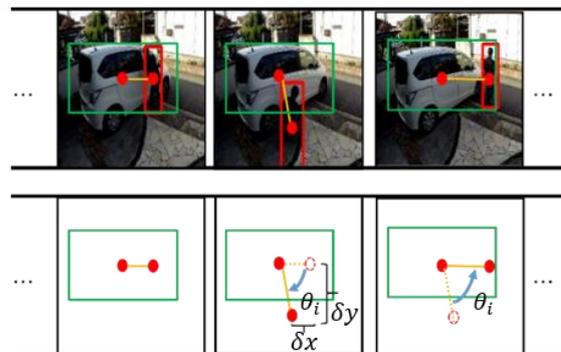


図 2 相対動き特徴量の概要

2.5 SVMによる異常の判定

4つの特徴量 E , P , S および R をSVMに入力する. 例えば 320×240 の映像に対して処理を行うと, E は8次元, P は768次元となるため [1], 計 $(8+768+8+8)=792$ 次元の特徴ベクトルを作成する. これをバギング構成のSVMに入力することにより, 異常の判定を行う.

3. ポスト荒らしおよび車上荒らし検出への応用

本研究では, 提案手法をポスト荒らしおよび車上荒らし検出に応用し, 評価実験を行う.

3.1 実験内容

百崎らの手法 [1] を従来手法とし, Deformable Part Models を用いた手法を提案手法として評価実験を行う. 実験映像はポスト荒らし, 車上荒らしの演技をビデオカメラで事前に撮影したものである. 正解データと不正解データをポスト荒らし検出ではそれぞれ52個ずつ, 車上荒らし検出では34個と13個用意した. 撮影した映像のサイズは, ポスト荒らし検出は 320×240 pixel, 車上荒らし検出は 432×240 pixelである. 検出率の評価指標には, 出力の正確性を示す適合率, 網羅性を示す再現率, これらの調和平均であるF値を用いる.

3.2 結果と考察

表2にポスト荒らしの検出結果, 表3に車上荒らしの検出結果を示す. 特に車上荒らし検出ではF値が大幅に向上していることが分かる. これは従来手法では図3のように車両, 人, 日射条件の変化をまとめて検出してしまい, 正しい判断ができなかったのに対して, 提案手法では図4のように物体間の相対関係を正しく認識したためである.

表2 ポスト荒らし検出の精度

手法	適合率 [%]	再現率 [%]	F 値[%]
従来手法	85.6	90.4	87.9
提案手法	87.5	92.3	89.8

表3 車上荒らし検出の精度

手法	適合率 [%]	再現率 [%]	F 値[%]
従来手法	85.1	46.2	59.9
提案手法	97.9	92.3	95.0

4. まとめ

本論文では, 異常検出システムにおける汎用性と精度の改善を目的とし, Deformable Part Models による物体認識を導入した. また, 従来の特徴量に加えて, スコア特徴量と相対動き特徴量を追加した.

本手法を評価するために, ポスト荒らし, 車上荒らしの異常検出実験を行った結果, 従来手法に対してF値が向上したことで, より汎用的に利用できることを確認した. 今後は特徴抽出部において Deep learning の導入を検討する予定である

5. 参考文献

- [1] 百崎将志, 西田喬士, 辻亮弥, 熊谷拓也, 黒木修隆, 沼昌宏, “汎用監視システムの構築”, 第38回 知能システムシンポジウム, pp.166-172, 2011年3月.
- [2] Pedro Felzenszwalb, Ross B. Girshick, David McAllester and Deva Ramanan, “Object Detection with Discriminatively Trained Part Based Models,” IEEE Computer Vision and Pattern Recognition, 2008.



図3 従来手法による検出結果例

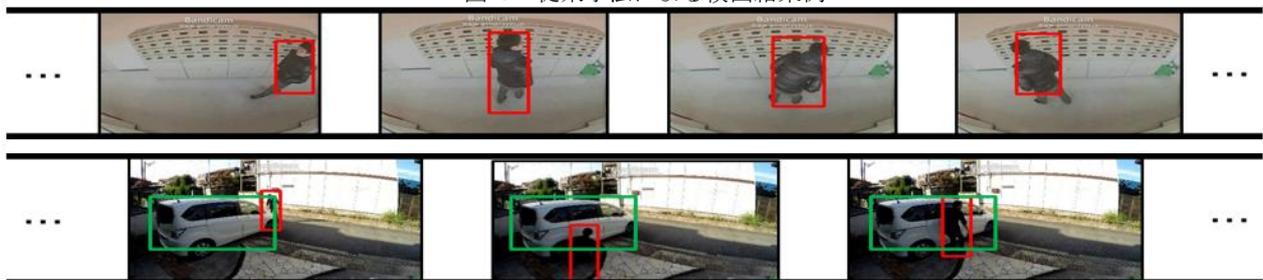


図4 提案手法による検出結果例