

オプティカルフローを用いた異常シーンの検出

Abnormal scene detection using optical flow

大芦 麻衣[†]
Mai Oashi[†]

太田 直哉[†]
Naoya Ohta[†]

概要: オプティカルフローを用いた異常行動検出について報告する。特徴ベクトルは画面全体のオプティカルフローを縦に並べたベクトルを用い、判別方式は部分空間法、マハラノビス距離、およびガウス化変換後のマハラノビス距離によるものの3種類を比較した。オーソドックスな処理の組み合わせであるが、データをガウス化することで性能の向上が見られた。

1 はじめに

防犯カメラのモニターを自動化するため、様々な異常検出手法が試みられている [1, 2]。この中で画像の移動情報であるオプティカルフローを使用する手法 [2] は、人物や物体の動きに異常状態の特徴が出る状況では有効な手法と思われる。本研究でも異常検出のための特徴としてオプティカルフローを用い、正常行動の特徴分布をデータから学習する。異常行動の判定は、学習された正常行動の分布からの距離で行う。特徴分布のモデル化は部分空間または平均と分散でモデル化するオーソドックスな手法を基礎としたが、平均と分散を用いる方法に対しては、データをガウス分布に近づける非線形変換をあらかじめ施す方法も試みた。非線形を導入する手法としてはカーネル法があるが、平均と分散による分布のモデル化はガウス分布を前提としているので、盲目にカーネル化するよりもこのアプローチの方が妥当であると考えた。

2 手法

動画像を構成する2枚のフレームから、画像上の768 (24×32) の点でオプティカルフローを求め、各計算点でのフローの x 成分および y 成分を順に並べ、1536次元ベクトルを構成して特徴ベクトル x とする。次に正常行動の学習用動画像から得た N 個の特徴ベクトル x_i ($i = 1 \dots N$) から、その平均 μ と共分散行列 Σ を計算する。

1番目の判定方法では正常行動のモデル化に部分空間を用いる。共分散行列 Σ をスペクトル (固有値) 分解し、大きい固有値から一定の寄与率になるまで固有ベクトルを選択することで正常行動の部分空間を構成する。後述する実験では、使用する固有ベクトルの数が214で累積寄与率80%、337で90%であった。実験では90%の値337を用いて部分空間を構成した。異常の判定は、入力画像から計算された特徴ベクトル x とこの部分空間との距離を求め、しきい値を超える場合に異常行動と判定する。しきい値は、学習に使用した正常画像の特徴ベク

トルの部分空間までの距離の平均を求め、その2倍とした。なおこの手法は固有フロー (eigen flow) によって正常行動を記述するもので、同様の考え方は顔による個人識別に利用されている [3]。

2番目の判定方法は平均と分散によるものである。次式によってマハラノビス距離 D を計算し、しきい値を超えるものを異常とする。

$$D = \sqrt{(x - \mu)^T (\Sigma + \delta I)^{-1} (x - \mu)} \quad (1)$$

ここで I は単位行列、 δ は小さな定数 (実験では0.001) であり、逆行列の計算の破綻を防ぐ正則化の役割を果たす。判定のためのしきい値は、1番目の方法と同様、学習画像に使用した特徴ベクトルの距離の平均の2倍とした。

3番目の判定方法は、特徴の分布がガウス分布に近づくような変換を行ってからマハラノビス距離を用いる手法である。特徴 x の次元が1次元のときを考えると、その累積ヒストグラム $F(x)$ で x を変換すると一様分布になり、さらにそれをガウス分布の累積ヒストグラム (誤差関数) $G(x)$ での逆関数で変換するとガウス分布になる。そこで特徴ベクトルの各成分 x_j ($j = 1, \dots, 1536$) を次式で変換する。

$$x_{\text{new}j} = G^{-1}(F_j(x_j)) \quad (2)$$

ここで F_j は x_j の累積ヒストグラムである。式 (2) の $x_{\text{new}j}$ を新たな特徴ベクトルの第 j 成分として2番目の手法を適用する。なおガウス分布に近づける変換として Box-Cox 変換が知られているが、ここで述べた手法の方が直接的であると考え、これを採用した。

上記の変換は多次元分布の各成分の分布 (周辺分布) をガウス分布とするもので、必ずしも多次元のガウス分布になるとは限らないが、少なくともそれに近づくことは期待できる。また各成分の相関は考慮していないことになるが、変換後に計算される共分散行列で考慮されることになる。

ここで実験画像から計算されたオプティカルフローの1つの成分を変換した例を図2に示す。図2(a)が元のデータのヒストグラムであるが、0の部分に非常に大きなピークがある。これは物体 (人物) が該当するオプティカルフローの計算点に入っていないフレームが多いためである。これは一般的なことと思われるので、値の絶対値が 10^{-3} 以下のデータを除いてヒストグラムを作成した。それを示したのが図2(b)であり、これをもとに変換した結果の分布が図2(c)である。なお0付近の

[†] 群馬大学工学部



図1 実験で使ったシーン




図2 特徴ベクトルの成分のヒストグラム

表1 各判定方法の評価値

判定法	精度	再現率	F 値
1	0.7703	0.9816	0.8632
2	0.8491	0.9922	0.9151
3	0.8917	0.9738	0.9310

データを特別扱いするのは変換関数を求めるときのみで、データの変換過程では0付近のデータも変換関数でそのまま変換する。

3 実験

自動販売機が設置された場所にカメラを設置し、正常行動(歩く、立ち止まる、お金を入れる、ボタンを押す、飲み物を取る等)と異常行動(自動販売機を壊そうとする動作)を撮影した。図1はその動画の1フレームを表示したものである。正常行動から約5000フレームを学習用動画とし、その動画とは独立に、テスト用として約1000フレームの正常行動、異常行動の動画を用意した。

各手法によって求められた正常空間との距離を図3に示す。これらのグラフの縦軸が距離であり、横軸は経過時間(秒)である。また時間の下にある番号の時点で、動画には以下のような動きが撮影されている。①、④ジュースを購入する動作、②購入を終え、歩いて帰っていく動作、③通路を他の人が歩いている状況、⑤自動販売機の前で傘(現実の画像では、ハンマーなどを想定)を振り回す動作、⑥傘を大きく振って、自動販売機を叩く動作、⑦小刻みに傘を振って、自動販売機を叩く動作である。図3のグラフに引かれた横線はしきい値であるが、これを超えるシーンを異常行動と判定する。

これらの結果から計算した精度、再現率、F 値を表3に示す。方法1と方法2の比較では、精度、再現率共に方法2の方が良く、F 値も大きくなっている。ガウス分布化する方法3では、方法2に比べて再現率は多少悪くなっているが精度がそれ以上に向上し、総合的にはF 値が向上している。

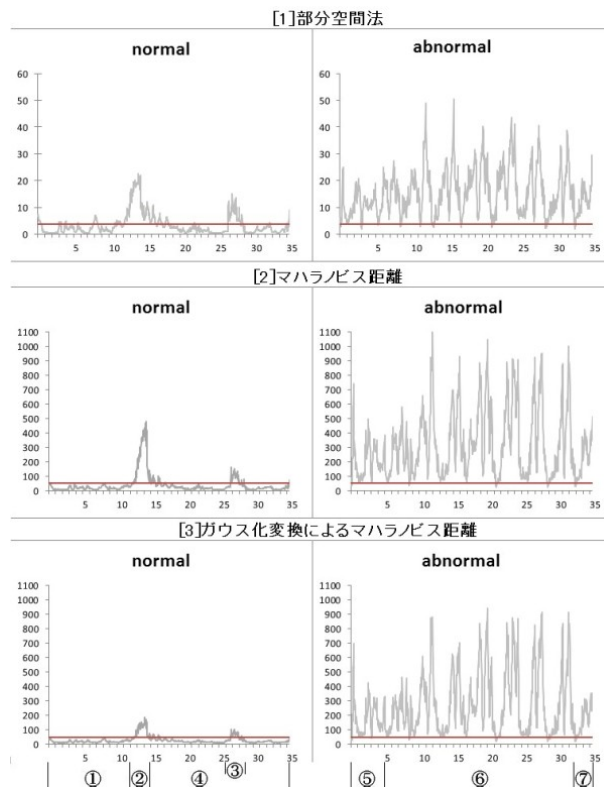


図3 正常行動空間からの距離(横線はしきい値)

4 まとめ

オプティカルフローを特徴ベクトルとし、それをオーソドックスな判別方式である部分空間法およびマハラノビス距離による方法と組み合わせる手法により、異常行動の検出を実験し、性能を評価した。将来の課題としては以下のことが挙げられる。現在、一時刻のオプティカルフローを使っているが、ある一定時間内のオプティカルフローを特徴とするように変更することである。またカーネル法を用いた他の判別方式との比較や、様々なシーンでの実験なども将来の課題である。

謝辞 本研究においては群馬大学の加藤毅准教授に多大なる助言を得た。また本研究の一部は科研費基盤研究(C)(No.21500156)によった。

参考文献

[1] 南里卓也, 大津展之, “複数人動画からの異常動作検”, 情報処理学会論文誌, Vol.46, No.SIG 15 (CVIM 12), pp. 43-48.

[2] 数藤恭子 他, “人物の位置と動き方向の学習に基づくリアルタイム非正常検出”, 信学技報 PRMU2008-22, pp.19-24, 2008/6.

[3] X. Liu, T. Chen, and B. V. K. V. Kumar, “Face authentication for multiple subjects using eigenflow”, Pattern Recognition, Vol. 36, Issue 2, pp. 313-328, 2003/2.