

輝度値の時系列変化に基づく高精度な移動物体検出手法

石井 圭典[†] 北澤 仁志[†]

東京農工大学[†]

1. はじめに

動画解析の重要課題のひとつである移動物体検出では、日照変動や草木の揺れなどのノイズを移動物体として誤検出することや、輝度変化の小さい部分を見落とす問題がある。

現在、背景差分法により抽出された領域の幅や高さ、面積等の空間的情報を特徴量として機械学習を行い、移動物体領域とノイズ領域に分類する手法が挙げられている [1]。しかし空間的情報のみでは移動物体検出に必要な情報が欠落していると考えられる。

本研究では、背景差分により抽出された領域の空間的情報に加えて、時間的情報として過去数十フレームの輝度値の時系列変化を示す Wavelet 係数を特徴量として用いた。環境変動に頑健で見落しの少ない移動物体検出が実現できることを示す。

2. 輝度値の時系列情報

2-1. 単一ガウス分布に基づく背景差分法

1つのピクセルに着目した輝度値の時系列変化について、元の輝度値、IIR Filtering の値、 $\pm 2.8\sigma$ の閾値、の4本を図1に示す。時系列波形を見ると歩行者や車などの急峻な変動、日照変動のゆるやかな変動といったように各変動に明確な違いがある。抽出漏れとなった歩行者についても時系列波形上ではその他とは明確な違いが表れている。




図 1. 単一ガウス分布の時系列波形

2-2. 混合ガウス分布に基づく背景差分法

2-1 で示した時系列の 1100~1900[frame]の範囲について混合ガウス分布に基づいて描画したものを図2に示す。ガウス関数の数は4つで、閾値は $\pm 2.5\sigma$ としそれぞれ high, low としてグ

ラフ上に示している。移動物体として判断された場合に非0の値をX軸上にflagとして示している。単一ガウス分布では見落としした歩行者が正しく抽出されているが、細かいノイズが多く、また、移動物体の影響でガウス分布が広がることにより移動物体の見落としが起こり得る。




図 2. 混合ガウス分布の時系列波形

2-3. 各変動の時系列波形

歩行者、日照変動、草木の揺れについて前後数十フレームの輝度値変化を描画したものを図3, 4, 5に示す。各変動に明確な違いが出ていることが分かり、この違いが識別・分類精度向上に利用可能であると考えられる。




図 3. 歩行者




図 4. 日照変動




図 5. 草木の揺れ

3. Wavelet 変換

時系列データを表現する方法として、フーリエ変換、Wavelet 変換、記号マッピング、線分表現、区分線形化等が挙げられるが、本研究では時系列を表現する方法として HaarWavelet 変換を用いた。以下で変換方法について説明する。

離散入力信号 $S_{0,n}: n = 0, 1, 2, \dots, N-1$ に対して、Wavelet 係数と Scaling 係数に分解していく処理を繰り返す。1つ目の添え字はスケールを表し、0が原信号、数字が増えるにつれてよりマクロに信号を捉える。式と図を示す。図6の例では原信号が4点の場合であるが、原信号が増えるにつれて分解する回数も増えていく。

High Precision Moving Objects Detection Method based on Time Series Variation of Intensity.

[†] Keisuke Ishii and Hitoshi Kitazawa (Tokyo University of Agriculture and Technology)

Wavelet 係数 : $T_{m+1,n} = \frac{1}{\sqrt{2}}[S_{m,2n} - S_{m,2n+1}]$
 Scaling 係数 : $S_{m+1,n} = \frac{1}{\sqrt{2}}[S_{m,2n} + S_{m,2n+1}]$




図 6. Wavelet 変換の処理

4. 実験

4-1. 使用動画像

固定カメラで路上を撮影した動画像から、単一ガウス分布に基づく背景差分法により歩行者、自転車、自動車、日照変動、草木の揺れを含んだ前景領域を抽出した後、抽出領域から特徴量を取り出し機械学習を用いて移動物体領域とノイズ領域を分類する。使用動画像の例を図 7 に示す。画像サイズは 640*480[pixel]、フレームレートは約 5[frame/sec]である。



図 7. 使用動画像の例

4-2. 時系列情報の取得方法

背景差分により抽出されたピクセルの 8 隣接連結領域の輝度値の平均をとり、そのフレームでの抽出領域の輝度値とする。同様の平均処理を過去 31 フレームにおいても同じピクセル位置で行い、計 32 点の輝度値の時系列情報を得る。

4-3. 特徴量

本実験で用いた特徴量についてまとめる。

dim10 : 抽出領域の幅、高さ、面積、影面積、R, G, B の各平均値、同一フレーム内の連結領域の個数、合計面積、合計影面積、の計 10 個

dim58 : dim10 の特徴量の他に、dim10 の特徴量を加減乗除して得られる物理的意味を持った 48 個の特徴量を追加した計 58 個

Wavelet : 時系列の Wavelet 係数 (本実験では、32 個のデータ)

TimeSeries : 時系列の値をそのまま時刻順に並べたもの (本実験では、32 個のデータ)

4-4. 使用データセットと使用識別器

使用データセットの教師データラベルの内訳を表 1 に示す。歩行者や車等の移動物体を Positive、日照変動や草木の揺れ等の抽出領域を Negative とした。使用識別器は Real AdaBoost (RAB, 学習 200 回) と SVM を用いた。

表 1. 使用データセットのラベル内訳

| | |
|-------------------|------|
| Positive (移動物体領域) | 431 |
| Negative (ノイズ領域) | 4322 |

4-5. 評価方法

精度の評価は 8-fold cross-validation を用いて、評価基準は Accuracy, Precision, Recall, F 値の 4 つを用いた。

4-6. Real AdaBoost による実験結果

結果を表 2 にまとめて示す。最も精度の良いものを赤色、次点をオレンジ色で示した。空間的情報のみでなく、時間的情報である Wavelet 係数を追加した “dim58+Wavelet” がすべてにおいて最も高い精度であり、時間的情報が識別に有効であることが分かる。しかし、元の輝度値の時系列を時刻順に並べた TimeSeries のデータでは特に識別率に改善は見られず、時系列変化をそのまま扱うのではなく、Wavelet 変換のように何らかの特徴抽出が必要であることが分かる。

表 2. Real AdaBoost による分類結果

| | Accuracy | Precision | Recall | F値 |
|--------------------|----------|-----------|--------|--------|
| dim10 | 87.59% | 39.41% | 68.68% | 50.08% |
| dim58 | 90.22% | 47.36% | 70.77% | 56.74% |
| dim10 + Wavelet | 93.33% | 61.22% | 72.16% | 66.24% |
| dim58 + Wavelet | 96.91% | 85.68% | 79.12% | 82.27% |
| dim10 + TimeSeries | 86.77% | 36.29% | 60.79% | 45.45% |
| dim58 + TimeSeries | 89.98% | 46.64% | 72.39% | 56.73% |

4-7. SVM による実験結果

RAB のものと同様に、SVM の分類結果について表 3 に示す。Cost, γ については識別に用いたデータセットとは別の区間のデータに対して分類を行った際の最適値を用いた。RAB のものに比べ効果は小さいが、Wavelet を追加したものが比較的良好な結果となっている。

表 3. SVM による分類結果

| | (Cost, γ) | Accuracy | Precision | Recall | F値 |
|--------------------|-------------------|----------|-----------|--------|--------|
| dim10 | (10,1) | 95.44% | 76.10% | 72.39% | 74.20% |
| dim58 | (1,1) | 93.96% | 65.79% | 69.61% | 67.64% |
| dim10 + Wavelet | (1,1) | 96.87% | 90.29% | 73.32% | 80.92% |
| dim58 + Wavelet | (1,1) | 95.88% | 77.52% | 76.80% | 77.16% |
| dim10 + TimeSeries | (1,1) | 93.90% | 64.84% | 71.46% | 67.99% |
| dim58 + TimeSeries | (1,1) | 94.23% | 65.01% | 78.89% | 71.28% |

5. まとめと今後の予定

Wavelet 係数を用いて過去の時系列情報を加味することにより、幅や高さ、面積等の空間的情報のみを用いた場合よりも移動物体検出の精度が向上することを示した。

今後は、時系列情報を捉える他の手法も試す。また、背景差分を用いずに時系列変化状況により移動物体を高精度に検出することを目指す。

参考文献

- [1] Y, Tomioka et al., "Sunshine-Change...", IEICE Trans. Inf. & Syst. VOL. E97-D, No. 9, 2014
- [2] 新誠一, 中野和司. "図説ウェーブレット変換ハンドブック", 朝倉書店, 2005 年.