

1. はじめに

ビデオ監視や ITS における高精度な物体識別能力の実現には、識別器の構築と入力特徴の選定が重要な課題である。SVM や Neural Network (ANN) 等の識別器は、非線形な識別境界により汎化能力の高い識別を実現する。しかし、入力特徴がクラス分離を表現できないと、その識別能力は低下する。本研究では、弱識別器を逐次学習し、重みつき多数決で最終的な識別結果を得る Adaboost を用いて構築した識別器から各特徴量の識別能力に対する貢献度を求め、特徴量評価の指標として用いることを提案する。

2. 物体識別に用いる特徴量

屋外環境下で撮影された人や自動車等の認識には、見えの違い、車種、照明の変動等に影響を受けない特徴量を選択する必要がある。本研究では、移動体検出後、物体識別の入力として、形状、テクスチャ、時間に基づく情報からなる以下の7つの特徴量を用いる。

- 形状に着目した特徴量
 - 正規分布の縦横比と傾き (AS)
 - 複雑度 (CS)
- テクスチャに着目した特徴量
 - 垂直方向エッジ (V)
 - 水平方向エッジ (H)
 - 右上がり方向エッジ (R-U)
 - 左上がり方向エッジ (L-U)
- 時間変化に着目した特徴量
 - オプティカルフローの分散 (OF)

本稿では、移動体を、上記の特徴量を用いて自動車 (VH)、人 (SH)、複数の人 (HG)、自転車 (BK) に識別するタスクを目的とする。

3. Adaboost による各特徴の識別に対する貢献度の評価

学習には、屋外の2カ所に設置したカメラより撮影した画像から、各識別クラス (VH/SH/HG/BK) について400枚の画像を取得し、200枚の画像を学習用に、残りの200枚を評価用に用いる。まず、VH, SH, HG, BKの各クラスに対して、対象クラスかそうでないかを出力とする2クラス識別器 H^c を、図1に示すアルゴリズムにより構築する。 c は対象クラスのラベルである。この際、各2クラス識別器構築に用いる学習入力サンプルは全て同じデータ x と、(1)式により設定するラベル y を用いる ((1)式は対象クラスが VH の場合の例)。

$$y_i = \begin{cases} +1, & \text{if } x_i \in VH \\ -1, & \text{otherwise} \end{cases} \quad (1)$$

このとき、他クラスの positive サンプルが自クラスにとっての negative サンプルとして学習される。2クラス識別器の出力は、全弱仮説の重み $\sum_{i=0}^T \alpha_i$ の過半数を得た推論結果 (入力 x は自クラスである/他クラスである) となる。ここで、 α_t は t 番目の仮説 h_t の識別性能から決定された重みであり、正規化すると、ある弱仮説の重みは

$$\alpha'_t = \frac{\alpha_t}{\sum_{i=0}^T \alpha_i} \quad (2)$$

となる。よって2クラス識別器は、各 $h_t(x)$ の推論結果結果 (1/0) が与えられたとき、 $\sum_{i=0}^T \alpha'_i h_i(x)$ が 0.5 以上であれば入力 x は対象クラスであると判別する。この値は、識別器ごとに正規化された、入力データが対象クラスであるという判断に対する一意の確信の度合である。よって、その値を比較することで、入力データを最も対象クラスらしいクラスへ識別する。最終的な結果は、(2)式のように全識別器の重みつき多数決を行うことで、マルチクラス識別としての結果を出力する。

$$Class = \underset{c \in \{VH, SH, HG, BK\}}{\operatorname{argmax}} H^c(x) = \sum_{t=1}^T \alpha'_t h_t(x) \quad (3)$$

貢献度 Adaboost の学習において、弱仮説は最もよく識別できる識別器が選ばれ、その識別性能に応じて重み α が付与される。そこで、弱仮説として選択された特徴量から、

Algorithm The Adaboost algorithm

1. **Input:** n , Training dataset (x_i, y_i)
 2. **Initialize:** $w_1(i) = 1/n (i = 1 \dots n)$, $h_0(x) = 0$
 3. **Do for** $t = 1, \dots, T$. $\epsilon_t(h) = \sum_i^n I(y_i \neq h(x_i))w_t(i)$
 - (a) $\epsilon_t(h_{(t)}) = \min \epsilon_t(h)$
 - (b) $\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \epsilon_t(h_{(t)})}{\epsilon_t(h_{(t)})} \right)$
 - (c) $w_{t+1}(i) = w_t(i) \exp(-\alpha_t h_{(t)}(x_i) y_i)$
 4. **Output:** Final hypothesis with weights α_t
- $$\operatorname{sign}(H_T(x)), \text{ where } H_T(x) = \sum_{t=1}^T \alpha_t h_t(x)$$

図1: Adaboost 学習アルゴリズム

各特徴量が最終的な識別器に貢献している度合いを表す貢献度 C_p を以下のように定義する。

$$C_p = \sum_{t=1}^T \alpha'_t \cdot \delta_K [P(h_t), p] \quad (4)$$

p は特徴ベクトル次元、すなわち特徴量の種類であり、 $P()$ は、選択された弱仮説に採用された特徴量を求める関数である。また、 α' は (3) 式により正規化した重み、 δ_K は Kronecker's delta である。貢献度 C_p は対象クラスの識別能力に対して特徴ベクトル p がどの程度寄与するかを示す指標となる。

4. 実験結果

各特徴量に対する貢献度と、その特徴量を用いずに学習した ANN 識別器における誤識別率 (未検出データと誤検出データの和の割合) を図2に示す。また、図中の R は貢献度と誤識別率との相関係数である。提案する貢献度とその特徴量を欠損した際の誤識別率には強い正の相関があることがわかり、貢献度が高いとその誤識別率が高くなることとわかる。

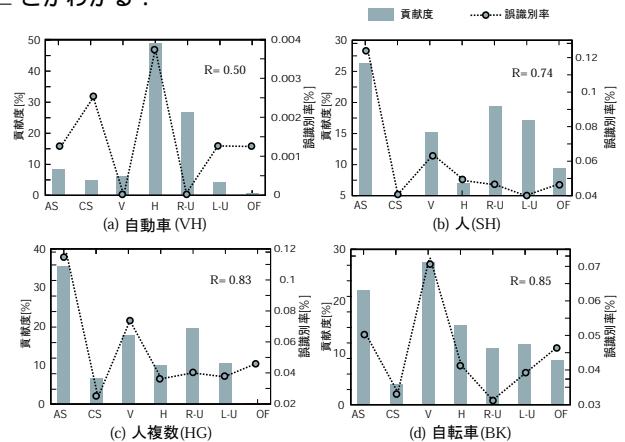


図2: 貢献度と誤識別率

選択された特徴量

図2から、自動車クラス (VH) の識別にはエッジ情報、特に水平成分の特徴が貢献度が高く、かつ誤識別率も高いことから最も識別に貢献しているといえる。二番目に高い右上成分のエッジ情報に関しては、当該特徴量を除いてもエッジ情報同士で補い合うため、その変化は誤識別率に顕著に影響しない。また、人単体クラス (SH)、人複数クラス (HG)、自転車クラス (BK) においては形状特徴の貢献度が高く、有効であることがわかる。見えがよく似た SH、BK の判別にはオプティカルフローを用いた時間変化の特徴が有効であることが判明した。

5. おわりに

本稿では、Adaboost を用いた入力特徴量の評価として各特徴量の貢献度を提案し、識別性能に相関があることを示した。このような特徴量の貢献度を予め求めることで、より多くの学習サンプルを用いて高性能な識別器 (例えば ANN) を構築する際の特徴選択の指針に貢献できる。今後は、より頑健な Multi-class Boosting と、各特徴量の相関関係の評価法を検討する予定である。