

屋外環境下における移動体識別に用いる入力特徴の AdaBoost による評価

AdaBoost Based Feature Importance Evaluation for Object Classification in Visual Surveillance

土屋 成光† 藤吉 弘巨†

Masamitsu Tsuchiya†, Hironobu Fujiyoshi†

† 中部大学 工学部情報工学科

† Department of Computer Science, Chubu University

E-mail: {tsuchiya, hf}@vision.cs.chubu.ac.jp

Abstract

本稿では、屋外環境で撮影された映像中の移動体を自動車/人/複数の人/自転車のタイプに識別する際の入力特徴を提案し、その特徴量の識別能力に対する貢献度について述べる。移動体検出後の画像から、形状に着目した特徴量(2種類)、テクスチャに着目した特徴量(4種類)、時間情報に着目した特徴量(1種類)の計7種類の特徴量を求め、識別器の入力とする。識別能力の向上には、識別器の向上と有効な入力特徴の選択が重要である。そこで、各特徴量が各クラスの識別能力への程度貢献しているかを調べるために、AdaBoostの学習過程で選択された弱仮説の特徴量の割合から識別能力への貢献度を求める。識別器としてニューラルネットワークを用いた際の識別結果と比較した結果、提案する貢献度と識別能力の間に正の相関があり、特徴選択における一指標となることを示す。

1 はじめに

屋外に設置したカメラ映像から移動体の検出・識別は、屋外自動ビデオ監視システムの研究分野で重要なテーマであり、多くの研究が行われている[1]。移動体を認識するには、フレーム間差分等の移動体検出後の画像から特徴量を計算し、識別器に入力して人や車に判別する。識別能力を向上させるには、高精度な識別器の構築と入力特徴の選定が重要な課題である。汎化能力の高い識別器として、学習をベースとしたAdaBoost.M2[2]やニューラルネットワーク(ANN)[3]、サポートベクターマシン[4]等が提案されている。これらの識別器は、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ことができる。しかし、たとえ識別器の能力が向上しても、その入力特徴がクラスの分離を表現できないと、

高精度な識別能力は期待できない。特に、屋外環境下で撮影された人や自動車等の認識では、同一対象における見えの違い、車種等の種別の多様性、天候等の照明変動に影響を受けない特徴量を選択する必要がある。

既に、多くの屋外監視カメラ映像からの移動体識別法が提案されている[1, 5, 6, 7, 8]。文献[5]では人、自動車の2クラスの識別に、dispersednessとAreaという2つの特徴量を線形判別関数に用いて識別する手法が提案されている。また、文献[1]では、前述のパラメータに加え、縦横比や、移動体のサイズ変化を考慮するためにカメラのズームパラメータを入力特徴とし、ANNによる識別を実現している。しかし、これらの特徴量は形状のみに着目したものであるため、その識別能力には限界がある。文献[6]では、物体の n 次モーメントなどのモーメント特徴を主体とした11次元の形状特徴を入力とし、判別空間中で重み付き K 最近傍法を適用した線形判別分析により、物体を人2種、車両3種、ノイズその他の計6種への識別を91%の精度で実現している。しかし、画像の見えをベースとした特徴量のみを用いるこの手法では、対象物の向きによる変動を吸収することができないため、画像を分割して、見えが同じになるようにしなくてはならないというデメリットがある。次に、テクスチャに着目した特徴量として、画像からエッジのヒストグラムを入力として、SVMにより人を検出(2クラス識別)する手法が提案されている[7]。また、文献[8]では空間と時間変化に着目し、Haar-like waveletsを用いたAdaBoostによる人の検出法を提案している。文献[7][8]の手法は、人の検出を対象としているが、自動車等の多クラス識別への応用が可能であると考えられる。しかし、これらの移動体識別に関する従来の研究では、入力特徴量が人や自動車等の識別対象に対して、どの程度重要であるかの検討が行われていない。また、どのような特徴量を選択すれば良い

かは、客観的な評価が困難であるため検討されていない。

そこで、本稿では、まず屋外環境下で撮影された映像における移動体を自動車/人/複数の人/自転車のタイプに識別するための入力特徴として、形状に着目した特徴量、テクスチャに着目した特徴量、時間情報に着目した特徴量を提案する。次に、各特徴量の識別能力への寄与を調べるために、AdaBoostの学習過程で選択された弱仮説の割合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 移動体識別のための特徴量

本研究では、ピクセル毎にしきい値を適応的に設定するフレーム間差分 [9] により移動体を検出する (図1参照)。

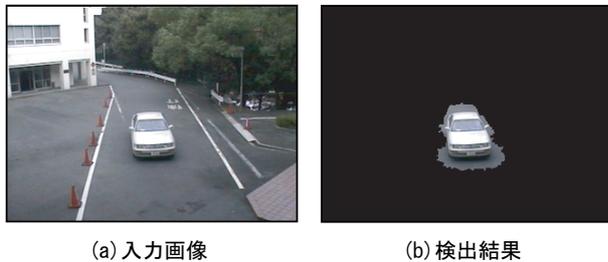


図1 フレーム間差分 [9] による移動体検出

検出されたピクセル群を空間クラスタリングにより、セグメントし、そのセグメント領域の画像から特徴量を算出し、物体を識別する。識別対象は、自動車 (VH) / 人 (SH) / 複数の人 (HG) / 自転車 (BK) の4クラスとし、識別器への入力特徴として、形状に着目した特徴量 (2種類)、テクスチャに着目した特徴量 (4種類)、時間情報に着目した特徴量 (1種類) を提案する。

- 形状に着目した特徴量
 - 縦横比と主軸の傾き (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)
 - 左上がり方向エッジ (L)
- 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)

以下に、各特徴量の算出方法を述べる。

2.1 形状情報に基づく特徴量

(1) 縦横比と主軸の傾き 移動体検出により検出した物体矩形領域に対して、図2のようにモーメント特徴 (縦横比, 傾き) を求める。 $M_{1,0}$ を重心まわりの x 軸方向の一次モーメント, $M_{0,1}$ を重心まわりの y 軸方向の一次モーメント, $M(\theta)_{1,0}$ を重心を原点として θ 回転した座標系における重心まわりの x 軸方向の一次モーメントであるとすると、物体の縦横比, 主軸の傾きを次式により求める。

$$\text{縦横比} = \frac{M(\theta)_{0,1}}{M(\theta)_{1,0}} \quad (1)$$

$$\text{主軸の傾き } \theta = \frac{1}{2} \tan^{-1} \left\{ \frac{2M_{1,1}}{M_{2,0} - M_{0,2}} \right\} \quad (2)$$

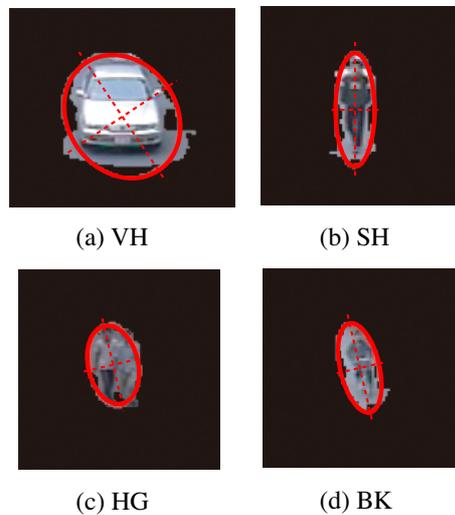


図2 モーメント特徴 (縦横比, 主軸の傾き)

(2) 形状の複雑度 検出したピクセル群から輪郭線を抽出し、周囲長を計算する。求めた周囲長を検出ピクセル数で割り、物体形状の複雑度とする。

$$\text{複雑度} = \frac{\text{周囲長}^2}{\text{面積}} \quad (3)$$

2.2 テクスチャ情報に基づく特徴量

(3) 各方向のエッジ成分 検出ピクセル内のエッジ強度とエッジ連結数を4方向 (垂直, 水平, 右上がり, 左上がり) について求める。まず、次式に示す各方向 $v \in \{V, H, R, L\}$ のエッジ検出オペレータ h_v を用いて、対象画素 (i, j) を含む近傍画素 Ω に対するエッジ強度 $g_v(i, j)$ と、エッジ強度が最大となる方向 $v'(i, j)$ を決定する。

$$h_V = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad h_H = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$$

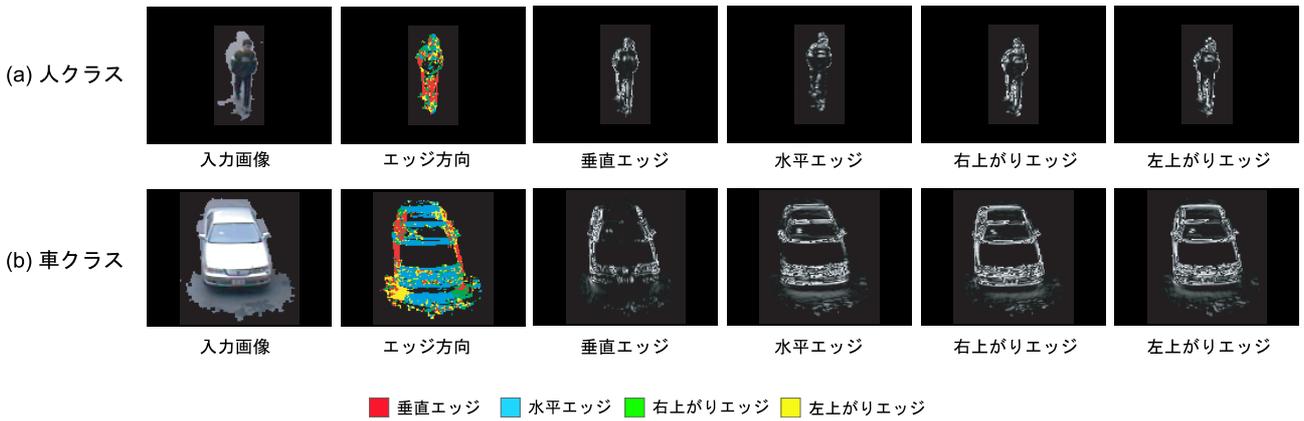


図3 エッジ検出結果

$$h_R = \begin{bmatrix} 0 & 1 & 2 \\ -1 & 0 & 1 \\ -2 & -1 & 0 \end{bmatrix} \quad h_L = \begin{bmatrix} 2 & 1 & 0 \\ 1 & 0 & -1 \\ 0 & -1 & -2 \end{bmatrix}$$

エッジ強度

$$g_v(i, j) = \sum_{(m, n) \in \Omega} f(m, n) h_v(i - m, j - n) \quad (4)$$

エッジ方向

$$v'(i, j) = \underset{v \in \{V, H, R, L\}}{\operatorname{argmax}} g_v(i, j) \quad (5)$$

次に、各方向ごとに検出ピクセル全体 O でのエッジ強度特徴 $G(v)$ を次式より求める。エッジ強度特徴

$$G(v) = \frac{\sum_{(i, j) \in O} g_v(i, j) \cdot \delta_K[v'(i, j) = v]}{\sum_{(i, j) \in O} \max_v (g_v(i, j))} \quad (6)$$

δ_K は Kronecker's delta である。

エッジ連結数は、各方向毎に物体領域内の同方向エッジの連結性を計算して求める。垂直エッジの連結数 $C(V)$ を求める際には、図4(a)に示す注目ピクセルの8近傍内の垂直方向ピクセル(グレーのピクセル) Ω_V に対して、同じ方向のエッジが存在するか否かを求める。

エッジ連結数

$$C(v) = \frac{\sum_{(i, j) \in O} \sum_{(m, n) \in \Omega_v} \delta_K[v'(i, j), v, v'(m, n)]}{\sum_{(i, j) \in O}} \quad (7)$$

2.3 時間軸情報に基づく特徴量

(4) オプティカルフローの分散 人と二輪車のような見えが似ている物体においては、形状やテクスチャ情

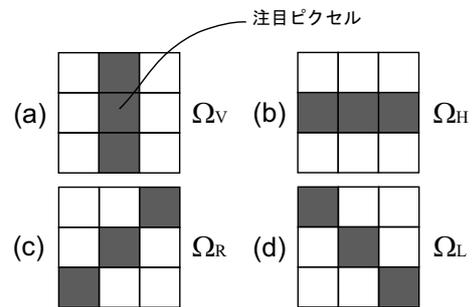


図4 連結ピクセル Ω_v ($v \in \{V, H, R, L\}$)

報から種別を識別することは困難である。そこで、物体の動きを表す特徴として、オプティカルフローを用いる。剛体である自動車や二輪車のフローの向きは一定方向に観測され、非剛体である人のフローは足等に向きのばらつきが生じる傾向がある(図5参照)。本稿では、フローの検出に特徴点の追跡手法である KLT 法 [10] を用いる。

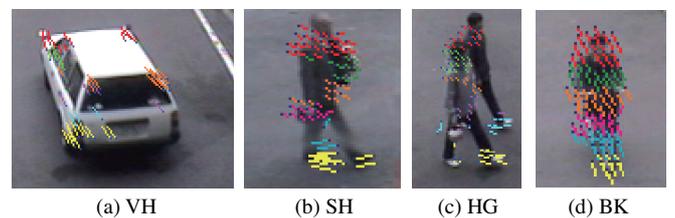


図5 フロー算出結果

図6(b)に示すように、物体矩形領域を6分割し、各分割領域内のフローの向きの分散を求める。各ブロックの分散は、人の場合は足等 (B_6) の下部になるほど分散が高くなる。一方、車の場合は一様なフローの向きとなり変化がない。これを直線の傾きで表し、特徴量とする。以下にその算出手順を示す。

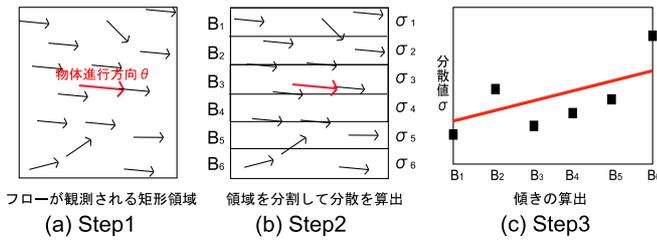


図6 フローの分散の計算

Step1 全フローの向きをヒストグラムを求め、その中央値を移動物体の進行方向 θ とする (図 6(a) 参照) .
 Step2 物体矩形領域を x 軸と平行に $B_1 \sim B_6$ の 6 ブロックに分割し、各分割領域 B_i 内のフローの角度 D_{ij} とフローの数 N_i と進行方向 θ から分散 σ_i を計算する (図 6(b) 参照) .

$$\sigma_i = \frac{1}{N_i} \sum_{j=1}^{N_i} (D_{ij} - \theta)^2 \quad (8)$$

Step3 σ_i から最小二乗法により直線の傾き FG を求め、特徴量として用いる (図 6(c) 参照) .

$$FG = \frac{6 \sum_{i=1}^6 x_i \sigma_i - \sum_{i=1}^6 x_i \sum_{i=1}^6 \sigma_i}{6 \sum_{i=1}^6 x_i^2 - \left(\sum_{i=1}^6 x_i \right)^2} \quad (9)$$

これまでに述べた、形状情報、テクスチャ情報、時間情報に基づく計 12 個の特徴量を、0 から 1 の範囲の値に正規化し、識別器への入力特徴として用いる .

3 AdaBoost による特徴量の貢献度

2 クラス識別器を各クラスについて AdaBoost で作成する . AdaBoost 学習の際に選択される各弱仮説の重みを用いて特徴量の貢献度を評価する .

3.1 学習サンプル

学習には、屋外の 2 カ所に設置したカメラより撮影した各識別クラス (VH:自動車 / SH:人 / HG:複数の人 / BK:自転車) について 10 シーケンスの動画像を計 40 シーケンス用いる . 1 シーケンスから 40 フレーム分の特徴量を抽出し、20 フレーム分の 200 枚の画像を学習用に用いる . 残りの 20 フレーム分の 200 枚は評価用に用いる .

3.2 AdaBoost による学習

本研究では、特徴量の評価を行うため、単純に 2 クラス識別器 $H(x)$ を $H^{VH}, H^{SH}, H^{HG}, H^{BK}$ のように各クラスに対して構築し、各クラス毎に学習過程で選択された弱仮説に注目する . 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 9 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 . 学習の際、各 2 クラス識別器の構築に用いる学習入力サンプルは全て同じデータ x と、次式により設定するラベル y を用いる (式 (9) は対象クラスが VH の場合の例) .

$$y_i = \begin{cases} +1, & \text{if } x_i \in VH \\ -1, & \text{otherwise} \end{cases} \quad (10)$$

このとき、他クラスの positive サンプルが自クラスにおいて negative サンプルとして学習される .

図 7 は自動車 (VH) と非自動車 (SH, HG, BK) の 2 クラス識別を、垂直方向エッジ連結成分のしきい値処理によって実現する際の最良のしきい値を探索する例である . まず、学習サンプルから両クラスのヒストグラムを求め、次に、誤識別率を最小とするしきい値 th を探索し、弱識別器 h はしきい値処理で実現する .

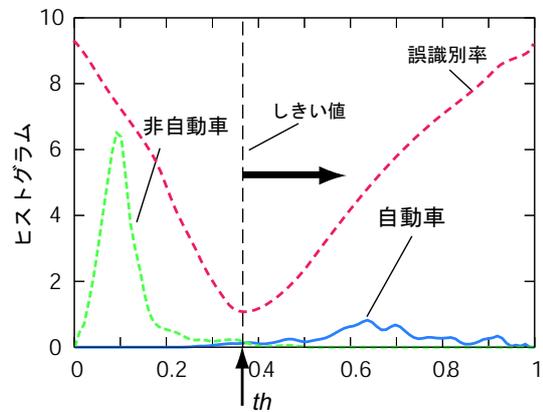


図7 弱識別器の例 (VH クラス)

学習回数 t 回目における弱識別器 $h_t^{p,th}(x)$ は、 $t-1$ 回目の学習結果より重み付けされたデータに対して、全ての特徴量 p に対して、各特徴量毎にしきい値 th を求める . 次に、全ての特徴量 p とそのしきい値 th による弱識別器のうち、最良の識別率を得られるものを採用する (図 8) .

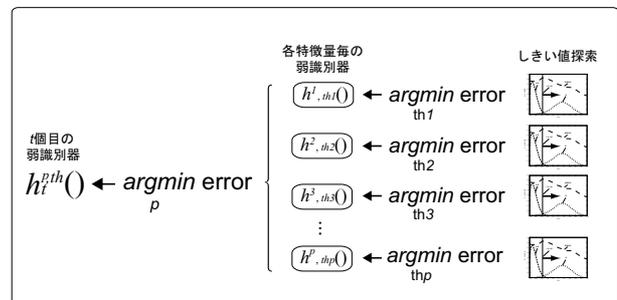


図8 弱識別器の選択

$$h_t^{p,th}(x) = \underset{(0 \leq th, p)}{\operatorname{argmin}} \left\{ \sum_i \delta_K(y_i, \operatorname{sgn}(x_i^p - th)) \right\} \quad (11)$$

AdaBoost では、識別関数 $h_t(x)$ が誤識別を起こしたデータを重視して再学習を行う . この処理を反復した

後, これらの識別関数のアンサンブルによって最終的な識別関数を生成する. 最終的な識別関数は次式で表される.

$$H_T(\mathbf{x}) = \sum_{t=1}^T \alpha_t h_t(\mathbf{x}). \quad (12)$$

ここで, α_t とは t 番目の弱識別器による識別結果の信頼度を表し, 最終的な識別に対して弱識別器 h_t の結果が影響する度合いである.

Algorithm The AdaBoost algorithm

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

図9 AdaBoost の学習アルゴリズム

3.3 AdaBoost によるマルチクラス識別

人 (SH) クラスを対象とした識別器を構築する場合, ラベル y を SH に属する場合 +1, そうでない場合 -1 と設定し, 識別器 H^{SH} を 3.2 節の AdaBoost 学習アルゴリズムにより構築する. 同様に, 複数の人 (HG) クラスを対象とした識別器 H^{HG} , 自転車 (BK) を対象とした識別器 H^{BK} を構築し, それらを総合して物体を識別する. これら全ての 2 値識別器に対するデータセットは全て共通である. 未知入力パターンがどのクラスに属しているかを識別するには, 各クラス毎に学習した 2 値識別器を統合する必要がある. そこで, 各識別器における重み α をその総和で正規化した α' を求める.

$$\alpha'_t = \frac{\alpha_t}{\sum_{i=0}^T \alpha_i} \quad (13)$$

求めた α' を用いて, 次式に示すように各識別器の出力を求め, 最大となる出力に対応したクラスを識別結果とする.

$$\text{Class} = \underset{c}{\operatorname{argmax}} H^c(\mathbf{x}) = \sum_{t=1}^T \alpha'_t h_t(\mathbf{x}) \quad (14)$$

$H^c(x)$ はクラス c ごとに重みを正規化した識別器である.

3.4 特徴量の貢献度

弱仮説として選択された特徴量と, その弱仮説の正規化後の重みである α' は, その識別対象クラスの識別に重要な要素である. そこで, 学習後の AdaBoost に

おいて選択された各特徴量の弱仮説から, 貢献度 C_p を以下のように定義する.

$$C_p = \sum_{t=1}^T \alpha'_t \cdot \delta_K[P(h_t) = p] \quad (15)$$

p は特徴ベクトル次元, すなわち特徴量の種類である. $P()$ 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. この C_p を各クラス識別器において選択された弱仮説群から求めると, 各特徴ベクトル p がその識別器の識別能力にどの程度貢献するかを示す指標となる. 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となることが期待できる.

4 実験

4.1 識別性能の評価

評価用データに対する, AdaBoost によって作成した識別器の識別率を表 1 に, ANN による識別器の識別率を表 2 に示す. ANN の構成は, 入力層ユニット 12 個, 中間層ユニット 100 個, 出力層ユニット 4 個とした. 学習には, AdaBoost の学習に用いた同じサンプルを用いた. 表 1 と表 2 を比較すると, 全体にやや AdaBoost の識別率が下回っている. しかし, 共に VH クラスが最も識別率が高く, 次に高いものが BK クラスである点等, 各クラスの識別結果の傾向が類似していることがわかる.

表 1 AdaBoost による識別結果

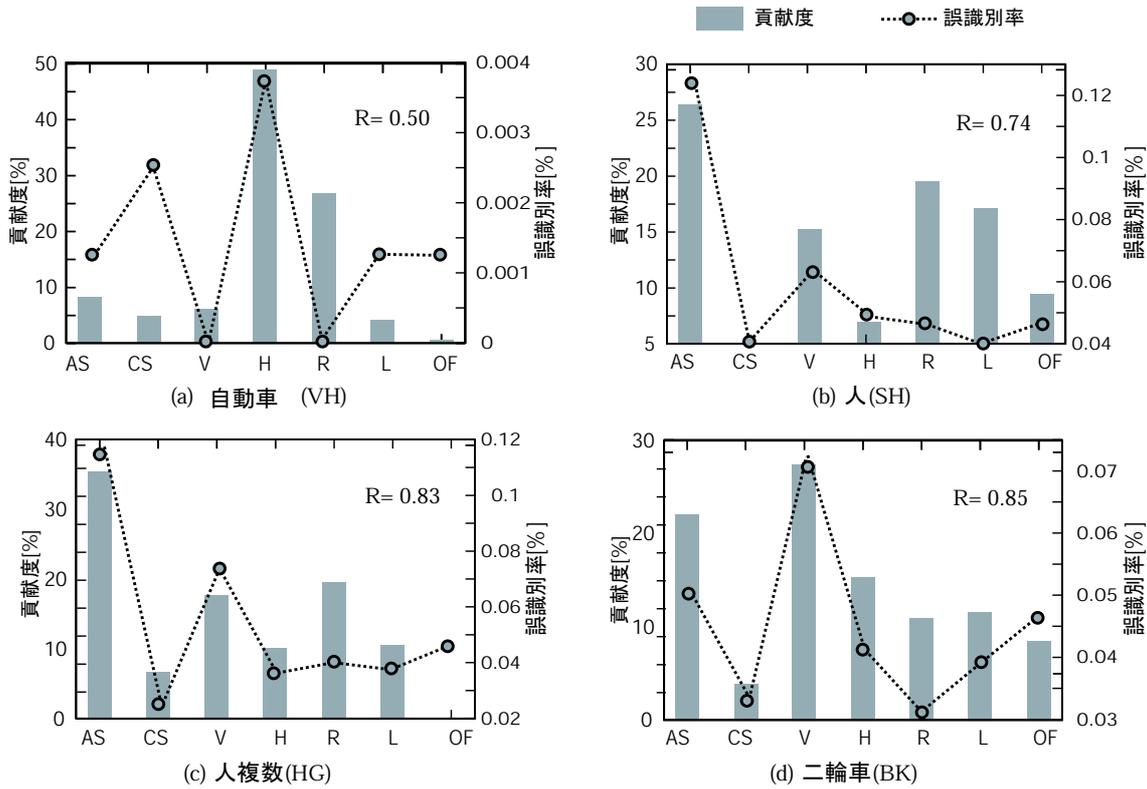
		Out					
		VH	SH	HG	BK	correct	[%]
In	VH	199	0	0	1	199	99.5
	SH	0	176	11	13	176	88.0
	HG	0	16	177	7	177	88.5
	BK	0	11	6	183	183	91.5
	Sum					735	91.9

表 2 ANN による識別結果

		Out					
		VH	SH	HG	BK	correct	[%]
In	VH	200	0	0	0	200	100.0
	SH	0	181	11	8	181	90.5
	HG	0	6	189	5	189	94.5
	BK	3	7	0	190	190	95.0
	Sum					760	95.0

4.2 貢献度

ある特徴量が識別能力に貢献している場合, その特徴量を用いずに構築した識別器の識別能力は貢献度に



AS:縦横比と主軸の傾き, CS:形状の複雑度, V:垂直方向エッジ, H:水平方向エッジ
R:右上がり方向エッジ, L:左上がり方向エッジ, OF: オプティカルフローの分散

図 10 貢献度と誤識別率

反比例して低下する．そこで，ある特徴量を使用せず識別器を構築し，その識別率と貢献度を比較することで貢献度の有効性を確認する．図 10 に，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を示す．また，図中の R は貢献度と誤識別率との相関係数である．相関係数は一般に，0.3 以上で相関あり，0.7 以上で強い相関ありとみなされるため，ある特徴の貢献度とその特徴量を用いない場合の誤識別率には強い正の相関があることがわかる．また，貢献度が高い特徴量ほど，それをを用いずに構築した識別器の誤識別率が上がることがわかる．VH クラスの相関係数は，他のクラスと比べてあまり高くない．これは，VH クラスの識別において，ある特徴に対して，同様の性質を持つ特徴が他に存在するためであると考えられる (VH クラスの場合，右上がり方向エッジと水平方向エッジ)．車と人との識別に対して水平方向エッジが有効であることは一般に知られており，本稿においても識別に対して高い貢献度を有している．しかし，車と人より抽出されるエッジ成分は全体に大きく異なり，他の方向エッジ成分，例えば右上がり方向でも，この 2 クラス間を同様に分離することが可能である場合がある．このような場合，最も精度の高い分離が可能な水平方向エッジ成分の有無は識別性能に影響

を及ぼすが，それと類似した特徴量の分布を持ち，やや精度の低いその他の方向エッジ成分の有無は識別率にさほど影響しないことと考えられる．

4.3 特徴量の評価

以下に，貢献度と識別結果から得られる各クラスに対する選択された特徴量の傾向を示す．

自動車クラス VH クラス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．二番目に高い右上がり成分のエッジ情報に関しては，除いてもエッジ成分同士で他が補い合うため，その変化は誤識別率にさほど影響しない．

人クラス モーメント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 BK との判別に関しては，動きの特徴である時間変化の特徴も有効であることがわかる．

人複数クラス 人クラスと同様にモーメント特徴の貢献度が高く，有効であることがわかる．

二輪車クラス モーメント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 との判別に

関しては、時間変化の特徴である OF の貢献度が共に高く、有効であることがわかる。

総括して、車両を識別する際はエッジ情報より得られた特徴のみでほぼ判別できることが確認できた。また、車両以外の人、人複数、二輪車を識別する際はモーメント特徴を用いたものが有効であることがわかる。また、人単体と二輪車という外見的特徴が近い物体同士の識別では動きの特徴であるオプティカルフローより得られる特徴量が有効であることが判明した。また、本手法では、フレーム間差分による切り出しを行うため、物体の複雑度 CS はあまり正確な情報でなくなる。そのため、全体に貢献度が低いことがわかった。

5 まとめ

本稿では、屋外環境下で撮影された映像における移動体を自動車/人/複数の人/自転車のタイプに識別するための入力特徴として、形状に着目した特徴量(2種類)、テクスチャに着目した特徴量(4種類)、時間情報に着目した特徴量(1種類)を提案した。

各特徴量が各クラスの識別能力への程度貢献しているかを調べるために、AdaBoost による識別器を構築し、弱仮説として採択された特徴量の割合から識別能力への貢献度を定義した。評価の結果、本稿で定義した貢献度と識別性能の間には正の相関があり、提案する貢献度の有効性を確認した。このような貢献度を予め求めることで、ANN 等において大量学習サンプルによる長時間の学習を行う前に、特徴量を選別することが可能となる。

今後は、各特徴量ごとに個別に AdaBoost で学習させた弱識別器集合に貢献度を考慮した重み付けを行うことで、再学習することなく入力特徴を追加可能な識別手法について検討を行う予定である。

参考文献

- [1] R. Collins, A. Lipton, H. Fujiyoshi, and T. Kanade, "Algorithms for cooperative multisensor surveillance," Proc. of the IEEE, Vol. 89, No. 10, October, pp. 1456 - 1477, 2001.
- [2] Y. Freund and R.E. Schapire. "A decision-theoretic generalization of on-line learning and an application to boosting", Journal of Computer and System Sciences, Aug, 1, 55, 119-139, 1997.
- [3] Rumelhart d.E.,McClelland J.L.and the PDP Research Group: " Paralell Distributed Processing ", 1, The MIP Prss, 1986.
- [4] Corinna Cortes and V. Vapnik, "Support-Vector Networks", Machine Learning, 20, 1995.
- [5] A. Lipton, H. Fujiyoshi, and R.S. Patil. "Moving target detection and classification from real-time video."

Proc. of the 1998 Workshop on Applications of Computer Vision, 1998.

- [6] 長谷川修, 金出武雄, "一般道路映像中の移動物体の識別・色の推定と特定対象の検出", 情報処理学会論文誌, Vol.44, No.7, pp.1795-1807, 2003.
- [7] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," In Proc. of the IEEE Conference on Computer Vision and Pattern Recognition, San Diego, CA, pp.886-893, 2005
- [8] P. Viola, M. J. Jones, D. Snow. "Detecting Pedestrians Using Patterns of Motion and Appearance", Proc. of the Ninth IEEE International Conference on Computer Vision (ICCV'03) - Volume 2, 2003.
- [9] 小村剛史, 藤吉弘亘, 矢入郁子, 香山健太郎, 吉水宏, "歩行者移動支援のための道路状況配信システム", 情報処理学会 コンピュータビジョンとイメージメディア研究会 2004.
- [10] B. D. Lucas and T. Kanade., "An Iterative Image Registration Technique with an Application to Stereo Vision." International Joint Conference on Artificial Intelligence, pp. 674-679, 1981.