

色の類似性に基づいた形状特徴量 CS-HOG の提案

CS-HOG : Color Similarity-based HOG feature

後藤 雄飛† 山内 悠嗣† 藤吉 弘亘†

Yuhi Goto†, Yuji Yamauchi†, Hironobu Fujiyoshi†

† 中部大学

† Chubu University

E-mail: yuhi@vision.cs.chubu.ac.jp

Abstract

従来の物体検出手法では, HOG 特徴量に代表されるように物体の形状を捉える局所特徴量が多く利用されている. 近年では, 色情報を利用した局所特徴量として Color Self-Similarity(CSS) 特徴量が提案されている. CSS 特徴量は色の類似度を算出し, 同一物体らしさを観測することにより, 物体検出に有効な特徴を表現することができる. また, CSS 特徴量は HOG 特徴量のような形状を捉える特徴量と併用することにより, 検出性能が向上することが報告されている. そこで, 本研究では色の類似性に基づいて物体形状を観測する CS-HOG 特徴量を提案する. CS-HOG 特徴量は, 色の類似性を用いた同一物体らしさを利用することで, 物体領域を推定して形状を捉えることができる. そのため, 輝度の勾配に基づく HOG 特徴量と比較して, 物体形状を明確に観測することが可能となり高精度な物体検出が実現できる. 評価実験より, CS-HOG 特徴量は HOG 特徴量, CSS 特徴量と比較して約 22.5 ~ 27.2%. HOG 特徴量と CSS 特徴量を併用する手法と比較して約 4.2% 識別精度が向上した.

1 はじめに

物体検出技術は, 車載カメラによる Intelligent Transport System(ITS:高度道路交通システム), 監視カメラによるセキュリティやマーケティングなど, 多くの分野で実用化が期待されている. 多くの物体検出手法は, 学習サンプルから抽出した局所特徴量と統計的学習手法を用いて構築した識別器により実現している. 高精度な物体検出を実現するためには, 物体の特徴を捉えるような局所特徴量を設計することが重要である. 物体の特徴を表現する局所特徴量を設計する手法として, これまでに Histograms of Oriented Gradients(HOG) 特徴量 [1], Edge Orientation Histograms(EOH) 特徴量 [2], Edgelet 特徴量 [3] など, 輝度の勾配に基づいて物

体形状を捉える局所特徴量が多く提案されている. 中でも, HOG 特徴量は局所領域において勾配の方向に勾配強度を累積した特徴量であり, 局所領域で正規化処理を行うため, 照明変化や幾何学的変化に対して頑健な特徴量となる.

形状を捉えるこれらの特徴量は画像の輝度の勾配に基づいているため, 色情報は利用されていない. カラー画像は, グレースケール画像の 3 倍の情報量を持つが, 人における衣類や自動車におけるボディーなど対象ごとに色が異なるため, 物体検出に有効な特徴量を抽出することが困難とされていた. しかし, 色情報を用いた局所特徴量として Color Self-Similarity(CSS) 特徴量 [4] が提案され, 色情報が物体検出に有効であることが確認されている. CSS 特徴量は, 二つの局所領域の色ヒストグラムから色の類似性を捉え, 同一物体らしさや非同一物体らしさを観測することで, 物体検出に有効特徴を表現をする. このように, 高精度な物体検出を実現するためには, 物体の特徴を効果的に表現する局所特徴量の設計が重要な鍵となる.

そこで, 本研究では物体の特徴を効果的に表現する局所特徴量として Color Similarity-based HOG(CS-HOG) 特徴量を提案する. CS-HOG 特徴量はカラー画像を利用し, 色の類似性に基づいて物体形状を捉える局所特徴量である. CS-HOG 特徴量は, 色の類似性を用いた同一物体らしさを利用することで, 物体領域を推定して形状を柔軟に捉えることができる. これまでの輝度の明暗関係を利用した勾配の場合, 検出対象ごとに物体と背景の明暗関係が反転する恐れがある. そのため, HOG 特徴量は明暗関係による勾配の反転を防ぐ処理を行っている. これに対して, CS-HOG 特徴量は色の類似性を用いて物体領域を推定することで, 物体領域と背景領域から勾配を取得して形状を求めることができる. そのため, 検出対象ごとに統一した勾配を求めることを可能にし, HOG 特徴量と比べて柔軟な特徴表現をする. また, CS-HOG 特徴量は色の類似性と物体形状の関係性に着目することで, 対象物体に似た形




図1 HOG 特徴量

状による誤検出を抑制できる．このように，CS-HOG 特徴量により色の類似性に基づいて適応的に物体形状を捉えることで，高精度な物体検出を実現する．

2 形状特徴と色の類似特徴

物体検出を実現するには，学習サンプルから抽出した局所特徴量を用いて学習した識別器を利用する手法が一般的である．物体の形状を捉える局所特徴量として Dalal らが HOG 特徴量を提案した．従来の物体検出手法は，HOG 特徴量に代表されるようにグレースケール画像から物体の形状を捉える局所特徴量が多く利用されている．これに対して，カラー画像の色情報を利用した局所特徴量として，Walk らが CSS 特徴量を提案した．CSS 特徴量は，色の類似性に着目することで物体検出に有効な特徴表現を可能にする．本章では，提案する CS-HOG 特徴量と関連の深い局所特徴量として，形状特徴である HOG 特徴量と，色の類似特徴である CSS 特徴量について述べる．

2.1 形状特徴：HOG 特徴量

Histograms of Oriented Gradients(HOG) 特徴量 [1] は図 1 に示すように，グレースケールの入力画像から，セルと呼ばれる局所領域毎に作成した勾配方向ヒストグラムを特徴量とする．また，複数のセルで構成されるブロック領域毎に特徴量を正規化することで，照明変化や幾何学的変化の影響を受けにくい特徴量となる．

算出手順は，はじめに入力画像を予め定義したサイズに正規化し，あるピクセルの輝度値 $L(x, y)$ の勾配強度 m と勾配方向 θ を式 (1) ～ 式 (3) より算出する．

$$m(x, y) = \sqrt{L_x(x, y)^2 + L_y(x, y)^2} \quad (1)$$

$$\theta(x, y) = \tan^{-1} \frac{L_y(x, y)}{L_x(x, y)} \quad (2)$$

$$\begin{cases} L_x(x, y) = L(x+1, y) - L(x-1, y) \\ L_y(x, y) = L(x, y+1) - L(x, y-1) \end{cases} \quad (3)$$

算出した勾配方向 θ は $0^\circ \sim 360^\circ$ の値で算出されるが， 180° より大きくなる方向は 180° 引いて $0^\circ \sim 180^\circ$ と




図2 CSS 特徴量

する．これにより，検出対象と背景領域の輝度の明暗関係に依存しない勾配方向を得ることができる．次に，算出した勾配強度 m と勾配方向 θ を用いて，式 (4) によりセル c ($M \times M$ ピクセル) における勾配方向ヒストグラム $v_c = \{v_c(1), v_c(2), \dots, v_c(N^{hog})\}$ を作成する．

$$v_c(f(\theta)) = \sum_x \sum_y m(x, y) \delta[f(\theta)] \quad (4)$$

ここで， $f(\theta)$ は勾配方向 θ を N^{hog} 方向に量子化した値， $\delta[\cdot]$ はクロネッカーのデルタ関数を表しており，二つの要素が等しい場合は 1，それ以外は 0 を出力する関数である．このように，セル c 毎にヒストグラム化することにより，局所領域内の微小な幾何学的変化に対して頑健な特徴量となる．最後に，式 (5) を用いて各セル c で作成した勾配方向ヒストグラム v_c を，複数のセルで構成されるブロック ($K \times K$ セル) 領域ごとに正規化する．

$$v_c(n) = \frac{v_c(n)}{\sqrt{\sum_{k=1}^b v_c(k)^2 + \epsilon}} \quad (\epsilon = 1) \quad (5)$$

ここで， b はブロック内の勾配方向の数 ($K \times K \times N^{hog}$)， ϵ は分母が 0 になることを防ぐための定数である．ブロック領域は，1 セル毎に正規化対象セル領域が重なるように移動しながら正規化する．正規化後の勾配方向ヒストグラム v_c は， $v_c = \{v_c(1), v_c(2), \dots, v_c(b)\}$ となる． 64×128 ピクセルの入力画像に対して，ブロック領域は $\{(64/M) - (K-1)\} \times \{(128/M) - (K-1)\}$ 個となる．この場合，HOG 特徴量の特徴ベクトルは， $M = 8$ ， $K = 2$ ， $N^{hog} = 9$ のとき 105 個のブロック領域により正規化処理が行われるため， $2 \times 2 \times 9 \times 105 = 3,780$ 次元となる．

2.2 色の類似特徴：CSS 特徴量

Color Self-Similarity(CSS) 特徴量 [4] は図 2 に示すように，二つのセル領域において作成した色ヒストグラムの類似度を特徴量としている．二つの局所領域における色の類似度を観測することで，検出対象の同一物体らしさや非同一物体らしさを捉える特徴量である．




図3 CSS 特徴量の可視化

また，色の類似度を特徴量とすることで，検出対象の色に依存されにくいという利点がある．

算出手順は，入力画像を予め定義したサイズに正規化し，分割したセル c ($M \times M$ ピクセル) の色ヒストグラム $\mathbf{p}_c = \{p_c(H, 1), p_c(H, 2), \dots, p_c(H, N^{css}), \dots, p_c(V, N^{css})\}$ を作成する．式 (6) に示すように色ヒストグラム $\mathbf{p}_c$ は，セル毎に HSV 表色系 $\{H$: 色相, S : 彩度, V : 明度 $\}$ で表される各ピクセルの色 $I_c(x, y, H)$, $I_c(x, y, S)$, $I_c(x, y, V)$ を累積することで作成する．

$$p_c(r, n) = \sum_{x=1}^M \sum_{y=1}^M \delta[f(I_c(x, y, r)), n] \quad (6)$$

ここで， r は HSV 表色系の各要素 ($r=H, S, V$)， n は量子化番号 ($n=1, 2, \dots, N^{css}$)， $f(I_c(x, y, r))$ は色 $I_c(x, y, r)$ を量子化した値を表している．二つのセル c_i, c_j から作成した色ヒストグラム $\mathbf{p}_{c_i}, \mathbf{p}_{c_j}$ を用いて，セル間の色の類似度 $s(c_i, c_j)$ を式 (7) に示すユークリッド距離を利用して算出する．

$$s(c_i, c_j) = \sqrt{\sum_{r \in \{H, S, V\}} \sum_{n=1}^{N^{css}} (p_{c_i}(r, n) - p_{c_j}(r, n))^2} \quad (7)$$

ヒストグラム間の距離の算出は，一般的にヒストグラムインタセクションや Bhattacharyya 距離が用いられる．本研究では文献 [4] と同様に，予備実験の結果，ユークリッド距離が最も有効に働いたため，類似度の算出




図4 HOG 特徴量と CSS 特徴量の比較

法として採用する． 64×128 ピクセルの入力画像に対して，セル c は $(64/M) \times (128/M)$ 個となる．この場合，CSS 特徴量の特徴ベクトルは， $M = 8$ のとき 128 個のセルから全ての組み合わせについて計算するため， $128C_2 = 8,128$ 次元となる．

どのように物体の特徴を表現しているのかを確認するために，CSS 特徴量を可視化する．図 3 に，画像サンプル内の一つのセル (矩形) に注目した際の CSS 特徴量を可視化した画像を示す．各サンプルの右の画像は，CSS 特徴量が高いほど赤色，低いほど青色で表現している．図 3 に示すように人を対象としたとき，CSS 特徴量は検出対象 (人) の場合，衣類におけるセルの類似度は高くなり，背景領域は類似度が低くなる傾向がみられる．一方，非検出対象 (背景画像) には，類似度にばらつきが生じていることがわかる．このように，CSS 特徴量は色の類似性に着目することで，人の衣類などの同一物体らしさや背景等の非同一物体らしさを表現していることがわかる．

2.3 HOG 特徴量と CSS 特徴量の比較

HOG 特徴量と CSS 特徴量の特徴表現の特性について比較する．HOG 特徴量と CSS 特徴量を可視化して比較したものを図 4 に示す．HOG 特徴量は，局所領域内の輝度から得られる勾配を利用して物体の形状を表現する．しかし，図 4 の検出対象に示すように，画像のグレースケール画像はカラー画像と比較して，物体と背景の輝度が類似してしまう場合がある．このような画像から HOG 特徴量を算出すると，検出対象の形状を明確に捉えることができない．一方，局所領域間の色の類似性を表現する CSS 特徴量は，グレースケール画像より情報量の多いカラー画像を利用することで，物体と背景と色の違いを捉えることができてい．このように，HOG 特徴量は物体形状を局所的に捉えるこ




図5 CS-HOG 特徴量の算出手順





図6 局所領域とピクセル間の色の類似度の算出


とができる反面，輝度の情報に依存してしまうという問題がある．図4の非検出対象の例は，画像中に検出対象ではない物体が含まれる場合を示している．このとき，CSS 特徴量は物体の詳細な形状を表現できないため，検出対象に似た特徴を捉えてしまい誤検出となる恐れがある．このように，CSS 特徴量はカラー画像による色情報を利用することで，物体と背景の領域を捉えることができる反面，詳細な物体の特徴を表現できないという問題がある．そこで，本研究ではこのような HOG 特徴量と CSS 特徴量の特性を活かし，両者の長所を捉えることができる局所特徴量を設計する．次章より，本研究で設計する CS-HOG 特徴量について説明する．

3 色の類似性に基づいた形状特徴： CS-HOG 特徴量

本研究では，色の類似性に基づいて形状を捉える Color Similarity-based HOG (CS-HOG) 特徴量を設計する．CS-HOG 特徴量は，色の類似度を利用した同一物体らしさを用いることにより，物体と背景の境界を示す形状を明確に表現することが可能である．HOG 特徴量と比較して物体の特徴を効果的に表現することができるため，高精度な物体検出が期待できる．CS-HOG 特徴量の算出の流れは，図5に示すように入力画像から局所領域とピクセル間の色の類似度を算出し，色の類似



(a) 類似度画像



(b) 平均類似度画像

図7 類似度画像の可視化

度を用いて形状特徴を算出する．以下より，CS-HOG 特徴量の算出方法について詳しく説明する．

3.1 局所領域とピクセル間の色の類似度の算出

CS-HOG 特徴量の算出手順は，まず，入力画像を予め定義したサイズに正規化し，局所領域 (セル) と各ピクセルの色の類似度を算出する．図6に示すように，注目セル $c' (M \times M \text{ ピクセル})$ から RGB 表色系 $\{R: \text{赤}, G: \text{緑}, B: \text{青}\}$ で表される表される各ピクセルの色 $I_{c'}(x, y, R)$, $I_{c'}(x, y, G)$, $I_{c'}(x, y, B)$ により，注目セル c' 内の色の代表値 $I'(c', r)$ を式 (8) を用いて算出する．

$$I'(c', r) = \frac{1}{M \times M} \sum_x \sum_y I_{c'}(x, y, r) \quad (8)$$

ここで， r は RGB 表色系の各要素 ($r=R, G, B$) を表している．注目セル c' の代表値 $I'(c', r)$ と各ピクセルの色 $I(x, y, r)$ を用いて，CSS 特徴量と同様に式 (9) のユークリッド距離を用いて類似度 $s'(x, y, c')$ を算出する．

$$s'(x, y, c') = \sqrt{\sum_{r \in \{R, G, B\}} (I'(c', r) - I(x, y, r))^2} \quad (9)$$

類似度 $s'(x, y, c')$ は注目セル c' ごとに求められる． 64×128 ピクセルの入力画像に対して，注目セル c' は $(64/M) \times (128/M)$ 個となる．そのため， $M = 8$ の場合は各ピクセルに対して 128 パターンの類似度が求められる (本研究では注目セル c' に対する類似度画像と




図 8 HSV 表色系




図 9 CS-HOG 特徴量

呼ぶ)。図 7(a) に，1 枚の検出対象から作成した類似度画像の例を示す。図 7(a) からわかるように，CSS 特徴量と同様に注目セル c' が物体領域に選択されている場合 (セル 45)，色の類似度を利用して同一領域らしさを表現できている。また，注目セル c' が背景領域に選択されている場合 (セル 89)，物体領域は類似度が低くなることが確認できる。図 7(b) は，学習用画像 2,416 枚の検出対象から作成した平均類似度画像を表している。図 7(b) からわかるように，検出対象全体で同一物体領域は類似度が高く，非同一物体領域は類似度が低く表現される傾向があることがわかる。CS-HOG 特徴量は，このように作成した類似度画像の特徴を捉えて物体形状を観測する。

HSV 表色系の利用

文献 [4] では，色の類似度を算出する際に利用する表色系として HSV 表色系が最も有効に働くと報告している。CSS 特徴量は，各要素を量子化してヒストグラム化することで HSV 表色系による距離計算を行っている。しかし，CS-HOG 特徴量における局所領域とピクセル間の色の類似度の算出には，前述の算出方法では HSV 表色系を利用して類似度を求めることができない。HSV 表色系は図 8 に示すように H (色相)， S (彩度)， V (明度) で構成されており，RGB 表色系とは違い各要素の示す原点が大きく異なる。そのため，HSV 表色系の各要素を利用して距離計算をすることができない。そこで，本研究では HSV 表色系を利用して距離計算を行うため，各要素 $\{H, S, V\}$ を式 (10) により座標系 $\{u, r, V\}$ に変換する。

$$\begin{cases} u = S \times \cos H \\ r = S \times \sin H \\ V = V \end{cases} \quad (10)$$

これにより，RGB 表色系と同様に原点が統一の座標系として，HSV 表色系を表現することができる。CS-HOG 特徴量は，このように HSV 表色系を座標系 $\{u, r, V\}$ に変換してから距離計算を行い色の類似度を算出する。

3.2 色の類似度を用いた形状特徴の算出

CS-HOG 特徴量は図 9 に示すように，局所領域とピクセル間の色の類似度により作成した類似度画像を用いて形状特徴を観測する。形状特徴は，注目セル c' ごとに作成された類似度画像を利用して，HOG 特徴量同様に各ピクセルの勾配をセル c ごとにヒストグラム化したものを特徴量とする。算出手順は，はじめに注目セル c' より算出した類似度 $s'(x, y, c')$ を利用して，各ピクセルの勾配強度 m' と勾配方向 θ' を式 (11) ～ 式 (13) より算出する。

$$m'(x, y, c') = \sqrt{s'_x(x, y, c')^2 + s'_y(x, y, c')^2} \quad (11)$$

$$\theta'(x, y, c') = \tan^{-1} \frac{s'_x(x, y, c')}{s'_y(x, y, c')} \quad (12)$$

$$\begin{cases} s'_x(x, y, c') = s'(x+1, y, c') - s'(x-1, y, c') \\ s'_y(x, y, c') = s'(x, y+1, c') - s'(x, y-1, c') \end{cases} \quad (13)$$

HOG 特徴量は，輝度値の明暗関係による勾配方向 θ' の反転を防ぐため， 180° より大きくなる勾配方向 θ を 180° 引いた方向で求めている。提案する CS-HOG 特徴量は，注目セル c' との同一物体らしさを色の類似度を利用して表現しているため， $0^\circ \sim 360^\circ$ 全ての勾配方向 θ' を用いて特徴表現をすることができる。次に，注目セル c' の類似度画像より算出した勾配強度 m' と勾配方向 θ' を用いて，式 (14) によりセル c ($M \times M$ ピクセル) における勾配方向ヒストグラム $V'_c(c') = \{v'_c(1, c'), v'_c(2, c'), \dots, v'_c(N^{cshog}, c')\}$ を作成する。

$$v'_c(f(\theta'), c') = \sum_x \sum_y m'(x, y, c') \delta[\theta', f(\theta')] \quad (14)$$

ここで， $f(\theta')$ は勾配方向 θ' を N^{cshog} 方向に量子化した値を表している。CS-HOG 特徴量では，勾配方向ヒストグラム $V'_c(c')$ は，注目セル c' ごとに作成される。よって， 64×128 ピクセルの入力画像に対して $M = 8$ の場合，1 つのセル c に対して 128 パターンの勾配方向ヒストグラム $V'_c(c')$ が作成される。最後に，式 (15) を




図 10 HOG 特徴量と CS-HOG 特徴量の比較

用いて注目セル c' ごとに，HOG 特徴量と同様にして勾配方向ヒストグラム $V'_c(c')$ を，複数のセルで構成されるブロック ($K \times K$ セル) 領域ごとに正規化する．

$$v'_c(n, c') = \frac{v'_c(n, c')}{\sqrt{\sum_{k=1}^b v'_c(k, c')^2 + \epsilon}} \quad (\epsilon = 1) \quad (15)$$

ここで， b はブロック内の勾配方向の数 ($K \times K \times N^{cshog}$) を表している．正規化後の勾配方向ヒストグラム $V'_c(c')$ は， $V'_c(c') = \{v'_c(1, c'), v'_c(2, c'), \dots, v'_c(b, c')\}$ となる．CS-HOG 特徴量は，この処理 (式 (11) ～ 式 (15)) により，全ての注目セル c' から作成した類似度画像から勾配方向ヒストグラム $V'_c(c')$ を取得し，各量子化番号の値を特徴量とする．CS-HOG 特徴量は， 64×128 ピクセルの入力画像に対して， $M = 8$ ， $K = 2$ ， $N^{cshog} = 18$ のとき，128 パターンの注目セル c' より作成した類似度画像と 105 個のブロック領域により正規化処理が行われる．そのため， $128 \times 2 \times 2 \times 18 \times 105 = 967,680$ 次元となり，HOG 特徴量と比較して膨大な特徴次元が取得できる．

HOG 特徴量と CS-HOG 特徴量の比較

HOG 特徴量と CS-HOG 特徴量の特徴表現の特性について比較する．HOG 特徴量と CS-HOG 特徴量を可視化して比較したものを図 10 に示す．図 10 の 2 つの検出対象からわかるように，HOG 特徴量は物体領域と背景領域の輝度の明暗関係による勾配の反転を防ぐため，勾配方向を $0^\circ \sim 180^\circ$ に制限している．勾配方向ヒストグラム (図中のヒストグラム) から確認できる



図 11 INRIA Person Dataset の例

ように，勾配方向を制限させることで検出対象で統一した特徴を捉えることができています．一方，CS-HOG 特徴量は同一物体らしさを色の類似度を利用して表現しているため，勾配方向を制限する必要がなく全ての勾配方向を表現できる．そのため，HOG 特徴量と比較して特徴表現が多様となり，物体形状を柔軟に捉えることができると考えられる．図 10 の非検出対象は，検出対象に類似した形状を人為的に背景に加えた画像を示している．この場合，HOG 特徴量は局所領域の形状のみを観測するため，ヒストグラムからもわかるように，検出対象と似た形状を捉えてしまうことで誤検出となる恐れがある．しかし，CS-HOG 特徴量は注目セルとして選択した局所領域を利用して，同一物体らしさから物体領域を捉えることでこのような影響を抑制できる効果がある．このように，CS-HOG 特徴量は色の類似性に基づいて形状特徴を求めることで，多様な特徴表現をして柔軟に物体形状を捉えることができることから，高精度な物体検出が期待できる．

4 評価実験

CS-HOG 特徴量による特徴表現の有効性を確認するために人検出による評価実験を行う．

4.1 データセット

評価実験には，予め物体の領域を切り出したデータセットを用いる．データセットには，人検出のベンチマークとして広く利用されている INRIA Person Dataset[1] を使用する．図 11 に INRIA Person Dataset の検出対象 (ポジティブサンプル)，非検出対象 (ネガティブサンプル) の例を示す．学習サンプルにはポジティブサンプル 2,416 枚，ネガティブサンプル 13,161 枚を使用する．評価サンプルはポジティブサンプル 1,126 枚を使用し，ネガティブサンプルは背景画像 453 枚から網羅的にラスタスキャンさせて切り出した画像を使用する．学習




図 12 DET カーブ

サンプル，評価サンプルは 64×128 ピクセルの大きさに正規化して使用する。

4.2 実験概要

CS-HOG 特徴量の有効性を示すために，以下の局所特徴量を用いて識別精度を比較する。

- HOG 特徴量 (HOG)
- CSS 特徴量 (CSS)
- HOG 特徴量と CSS 特徴量の併用 (HOG+CSS)
- CS-HOG 特徴量：RGB 表色系 (CS-HOG : RGB)
- CS-HOG 特徴量：HSV 表色系 (CS-HOG : HSV)

CS-HOG 特徴量は，色の類似度に RGB 表色系を利用したものと HSV 表色系を利用したものをを用いる。HOG 特徴量と CSS 特徴量の併用は，二つの特徴次元を同時に使用して識別器を学習したものを示している。各特徴量のパラメータは，セルサイズ $M = 8$ ピクセル，ブロックサイズ $K = 2$ セル，量子化数は $N^{hog} = 9$ ， $N^{css} = 3$ ， $N^{cshog} = 18$ とした。CS-HOG 特徴量と比較手法は Real AdaBoost[5] を利用して識別器を学習する。また，Real AdaBoost により学習する弱識別器は 500 個で統一して評価実験を行う。評価には Detection Error Trade-off (DET) カーブを用いる。DET カーブは横軸に誤検出率，縦軸に未検出率を表しており，原点に近いほど高精度であることを表す。

4.3 実験結果

実験結果の DET カーブを図 12 に示す。DET カーブより，誤検出率 0.05% のとき CS-HOG : RGB は HOG, CSS と比較して約 5.7 ~ 8.1% 識別精度が向上してい




図 13 識別器の出力値

る。CS-HOG : HSV は HOG, CSS と比較して約 22.5 ~ 27.2% 識別精度が向上しており，CS-HOG : RGB と比較して約 16.8% 識別精度が向上している。これにより，CS-HOG 特徴量は HSV 表色系を利用して類似度計算をすることで，有効な特徴表現を可能にしたことが確認できる。また，CS-HOG : HSV は HOG+CSS と比較したとき，約 4.2% 識別精度が向上している。このことから，単一の特徴量で色の類似性と形状特徴を効果的に表現できたと考えられる。

CS-HOG 特徴量と HOG 特徴量，CSS 特徴量で識別器の出力値にどのような変化があるかを確認する。図 13 に評価サンプルにおける識別器の出力値の分布を示す。図 13 は，横軸に CS-HOG 特徴量の識別器の出力値，縦軸に HOG 特徴量及び CSS 特徴量の識別器の出力値を




図 14 人検出例

示し，対角線上にサンプルが分布すると同一の出力値であることを表す。識別器の出力値の分布からわかるように，CS-HOG 特徴量は HOG 特徴量及び CSS 特徴量と比較して，ポジティブサンプルの約 86.7 ～ 88.1% が出力値が高い値となっている。また，ネガティブサンプルの約 67.2 ～ 86.7% が出力値が低い値となっている。これにより，CS-HOG 特徴量は HOG 特徴量，CSS 特徴量と比較して，各サンプルがより正解クラスらしい出力となることが確認できた。よって，図 14 に示す人検出例からもわかるように，CS-HOG 特徴量は色の類似度に基づいて形状を観測し，物体の特徴を効果的に捉えることで高精度な物体検出を実現した。

5 おわりに

本研究では色の類似性に基づいて形状を観測する CS-HOG 特徴量を提案した。CS-HOG 特徴量は，カラー画像の色の類似性に基づいて形状を算出することで，HOG 特徴量に比べて柔軟に物体形状を捉えることを可能にした。人検出における評価実験により，CS-HOG 特徴量は従来の局所特徴量と比較して，物体の特徴を効果的に表現し高精度な検出を実現した。今後は，自動車などの人以外の検出対象への CS-HOG 特徴量の有効性を調査する予定である。

参考文献

- [1] N. Dalal, and B. Triggs, “Histograms of Oriented Gradients for Human Detection”, Computer Vision and Pattern Recognition, vol.1, pp.886-893, 2005.
- [2] K. Levi, and Y. Weiss, “Learning Object Detection from a Small Number of Examples: the Importance of Good Features”, Computer Vision and Pattern Recognition, vol.2, pp.53-60, 2004.
- [3] B. Wu, and R. Nevatia, “Detection of Multiple, Partially Occluded Humans in a Single Image by Bayesian Combination of Edgelet Part Detectors”, International Conference on Computer Vision, vol.1, pp.90-97, 2005.
- [4] S. Walk, and N. Majer, “New Features and Insights for Pedestrian Detection”, Computer Vision and Pattern Recognition, pp.1030-1037, 2010.
- [5] R. E. Schapire, and Y. Singer, “Improved Boosting Algorithms Using Confidence-rated Predictions”, Machine Learning, vol.37, no.3, pp.297-336, 1999.