

## 形状と色の類似特徴を用いた 共起確率特徴量による人検出

後藤 雄飛<sup>†1</sup> 山内 悠嗣<sup>†1</sup> 藤吉 弘亘<sup>†1</sup>

従来の人検出法では、HOG 特徴量に代表されるように人の形状を捉える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、人検出に有効な特徴表現をすることができる。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、提案手法では HOG 特徴量と CSS 特徴量を共起表現により同時に捉えることで高精度な人検出を実現する。形状特徴である HOG 特徴量と色の類似特徴である CSS 特徴量を用いて共起確率特徴量を生成することにより、性質の異なる特徴量の様々な関係性を捉えることが可能となる。評価実験より、従来の HOG 特徴量と CSS 特徴量を併用する手法と比較し、識別精度の向上を確認した。

### Human Detection by Co-occurrence Probability Feature with Shape and Color Self-Similarity Features

YUHI GOTO,<sup>†1</sup> YUJI YAMAUCHI<sup>†1</sup>  
and HIRONOBU FUJIYOSHI<sup>†1</sup>

Conventional human form recognition methods mostly use shape-based features, of which the HOG feature is typical. In recent years, the Color Self-Similarity (CSS) has been proposed as a feature that uses color information. The CSS feature has been confirmed to be an effective feature representation that involves calculating color similarity and determining the degree to which it seems a single object is represented. Improvement in detection performance by using the CSS feature together with shape-based features such as HOG features has also been reported. Therefore, the proposed method achieves highly accurate human form detection by using HOG features and CSS features simultaneously. Using the HOG shape feature and the CSS color similarity feature to generate a co-occurrence probability feature makes it possible to understand

the relations among features that are based on different properties. Evaluation experiments confirmed that this approach improved the recognition rate relative to the previous method of using HOG features and CSS features together.

#### 1. はじめに

人検出は、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人検出器により実現している。高精度な人検出を実現するためには、(1) 人の特徴を効果的に表現する局所特徴量の設計、(2) 局所特徴量間の関連性や共起性の表現の二つのアプローチが重要である。

(1) 人の特徴を効果的に表現する局所特徴量の設計アプローチとして、Histograms of Oriented Gradients (HOG) 特徴量<sup>1)</sup>、Edge Orientation Histograms (EOH) 特徴量<sup>2)</sup>、Edgelet 特徴量<sup>3)</sup>などの物体の形状を捉える局所特徴量が提案されている。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勾配に基づいており、色情報は利用されていない。カラー画像は、グレースケールの画像の3倍の情報量を持つが、髪や衣類にみられるように個人差が大きいため、人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<sup>4)</sup>が提案され、色情報が人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、人検出に有効な特徴を表現する。さらに、CSS 特徴量は、勾配の情報に基づく HOG 特徴量と併用することで、高精度な人検出が可能であることが報告されている。

(2) 局所特徴量間の関連性や共起性の表現のアプローチとして、Joint Haar-like 特徴量<sup>5)</sup>、Joint 特徴量<sup>6)</sup>、共起確率特徴量<sup>7)</sup>などが提案されている。これらは、複数の特徴量を同時に捉えることで、特徴量間の共起を表現する。これにより、複数の局所特徴量により物体の構造を捉えることが可能となり、検出精度の向上に貢献した。Joint Haar-like 特徴量は、AdaBoost<sup>9)</sup>の弱識別器が複数の Haar-like 特徴量<sup>8)</sup>を同時に観測することにより、共起性

<sup>†1</sup> 中部大学  
Chubu University

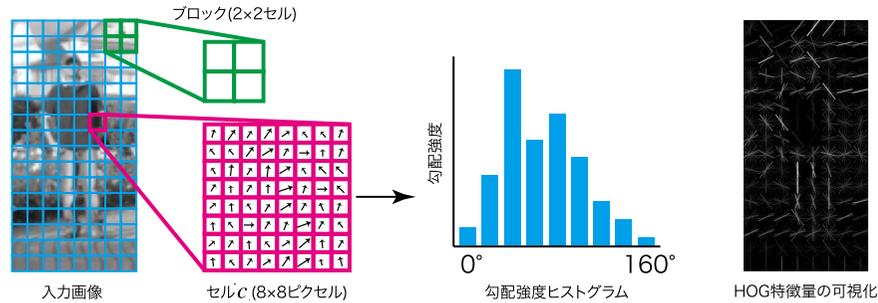


図 1 Histograms of Oriented Gradients  
Fig. 1 Histograms of Oriented Gradients.

を表現している。Joint 特徴量<sup>6)</sup>は、異なる二つの領域の HOG 特徴量を Real AdaBoost<sup>10)</sup>により組み合わせることで、単一の特徴量では表現が困難な対称性や連続的なエッジの関連性を表現している。共起確率特徴量は、弱識別器の出力が連続値である Real AdaBoost を利用し、弱識別器の出力を複数の演算子によって結合する。これにより、二つの特徴量間の共起性を柔軟に捉えることが可能である。

そこで、本稿では人の特徴を効果的に表現する局所特徴量間の共起性を表現することで、人検出性能の高精度化を目的とする。提案手法では、形状を捉える HOG 特徴量と色の類似性を捉える CSS 特徴量を用いて、共起確率特徴量を生成する。性質の異なる HOG 特徴量と CSS 特徴量を共起表現し、多様な特徴量間の関係性を表現することで、人検出の高精度化が期待できる。

## 2. 形状特徴と色の類似特徴

人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人検出器を利用するアプローチが一般的である。本章では、提案手法で用いる局所特徴量として、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

物体の形状を捉える局所特徴量として、提案手法では Dalal らが提案した Histograms of Oriented Gradients(HOG) 特徴量<sup>1)</sup>を用いる。HOG 特徴量は図 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。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  $\theta$  を式 (1) ~ 式 (3) より算出する。

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

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

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

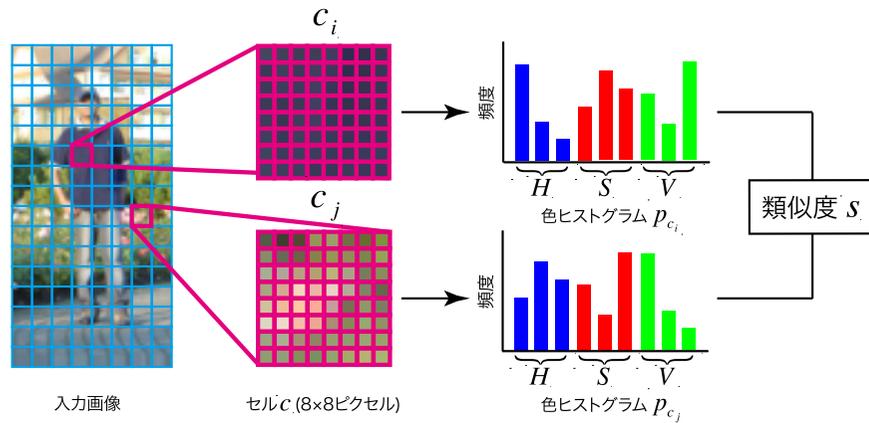
次に、算出した勾配強度  $m$  と勾配方向  $\theta$  より、セルにおける勾配方向ヒストグラムを作成する。勾配方向は  $0^\circ$  から  $360^\circ$  の値で算出されるが、 $180^\circ$  より大きくなる方向は反転させて  $0^\circ$  から  $180^\circ$  に変換する。これにより、検出対象と背景領域の輝度の大小関係に依存しない勾配方向を得ることができる。算出した勾配方向を  $20^\circ$  ずつの 9 方向に量子化し、各方向に勾配強度  $m$  を累積することで勾配方向ヒストグラムを作成する。このように、セル毎にヒストグラム化することにより、セル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、各セルで作成した勾配方向ヒストグラムを、複数のセルで構成されるブロック領域ごとに式 (4) より正規化する。

$$v = \frac{v}{\sqrt{\sum_{i=1}^k v_i^2 + \epsilon^2}} \quad (\epsilon = 1) \quad (4)$$

ここで、 $v$  は勾配方向における累積した勾配強度、 $k$  はブロック内の勾配方向の数、 $\epsilon$  は分母が 0 になることを防ぐための定数である。HOG 特徴量の特徴ベクトルは、 $64 \times 128$  ピクセルの入力画像、 $8 \times 8$  ピクセルのセル、 $2 \times 2$  セルのブロックの場合、ブロック領域の正規化処理により 420 個のセルから勾配方向ヒストグラムが算出されるため、 $420 \times 9 = 3,780$  次元となる。

### 2.2 色の類似特徴：CSS 特徴量

物体の色の類似性を捉える局所特徴量として、提案手法では Walk らが提案した Color Self-Similarity(CSS) 特徴量<sup>4)</sup>を用いる。CSS 特徴量は図 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物らしさを捉える特徴



量である．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  $M(x \times y)$  ピクセルのセル  $c$  の色ヒストグラム  $p_c$  を作成する．式 (5) に示すように色ヒストグラム  $p_c$  は，セル毎に HSV 表色系  $R \in \{H: \text{色相}, S: \text{彩度}, V: \text{明度}\}$  で表される各ピクセルの色  $I(m, H)$ ,  $I(m, S)$ ,  $I(m, V)$  を累積することで作成する．

$$p_c = \sum_{m=1}^M \sum_{r \in R} \sum_{n=1}^N \delta[f(I(m, r), n)] \quad (5)$$

ここで， $N$  は色の量子化数， $M$  はセル  $c$  に含まれるピクセル数， $f(I(m, r))$  は HSV 表色系で表される各ピクセルの色  $I(m, r)$  を量子化した値を表している． $\delta[\cdot]$  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．セル  $c$  より選択した二つのセル  $c_i, c_j$  から作成した色ヒストグラムの類似度  $s(c_i, c_j)$  を用いて，式 (6) に示すユークリッドノルムにより算出する．

$$s(c_i, c_j) = \sqrt{\sum_{q=1}^{N \times 3} (p_{c_i}(q) - p_{c_j}(q))^2} \quad (6)$$



図 3 CSS 特徴量の可視化  
Fig. 3 Visualization examples of CSS feature.

ここで， $q$  は色ヒストグラムの特徴ベクトルの番号を表す．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<sup>4)</sup>と同様に，予備実験の結果ユークリッドノルムが最も有効に働いたため，類似度の算出法として採用する．CSS 特徴量の特徴ベクトルは， $64 \times 128$  ピクセルの入力画像， $8 \times 8$  ピクセルのセルの場合，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 (赤色矩形) 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 特徴量が高いほど白色，低いほど黒色で表現している．図 3 より，CSS 特徴量はポジティブサンプル (検出対象) 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，ネガティブサンプル (非検出対象) には，類似度にばらつきが生じていることがわかる．図 3 のポジティブサンプルの平均類似度画像からもわかるように，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．

### 3. 提案手法

本章では，HOG 特徴量と CSS 特徴量の共起表現法として用いる共起確率特徴量 (Co-occurrence Probability Feature)<sup>7)</sup> について述べる．提案手法で用いる共起確率特徴量は，Boosting アルゴリズムである Real AdaBoost<sup>10)</sup> を用いて，弱識別器から得られる出力値を演算子により結合する特徴量である．提案手法では，HOG 特徴量と CSS 特徴量を利用し

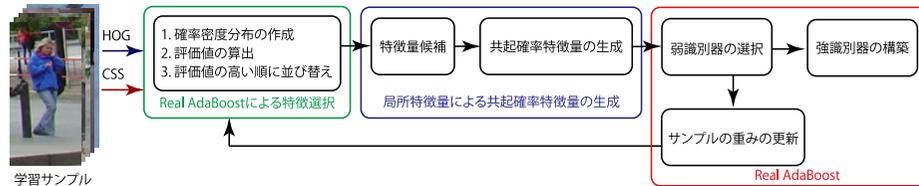


図 4 共起確率特徴量を用いた学習の流れ  
Fig. 4 Flow of learning that uses Co-occurrence Probability Feature.

て共起確率特徴量を生成する．形状を捉える HOG 特徴量と色の類似性を捉える CSS 特徴量を用いて共起を表現することにより，性質の異なる特徴量を様々な捉え方で表現可能となる．そのため，従来の単一の特徴量を用いた場合と比較して検出精度の向上が期待できる．

### 3.1 HOG 特徴量と CSS 特徴量を用いた共起確率特徴量の生成と学習

提案手法では，HOG 特徴量と CSS 特徴量を利用し，Real AdaBoost を用いて共起確率特徴量を生成する．図 4 に共起確率特徴量を用いた学習の流れを示す．まず，確率密度関数を作成し，各特徴量の識別性能を表す評価値を算出する．次に，評価値の高い順に並び替え，特徴量候補を作成する．作成された特徴量候補に含まれる特徴量のみを用いて，共起確率特徴量を生成し，Real AdaBoost の学習アルゴリズムにより人検出器を学習する．以下に詳細を述べる．

#### 3.1.1 Real AdaBoost による特徴選択

共起確率特徴量は HOG 特徴量 (3,780 次元) と CSS 特徴量 (8,128 次元) を，二つの演算子により結合する．生成される共起確率特徴量数は  $11,908 C_2 \times 2 = 141,788,556$  次元となる．しかし，全ての特徴量を用いて学習をする場合，膨大な学習時間が必要となり現実的ではない．そこで，文献<sup>7)</sup>と同様に効率的に学習をするために，11,908 次元の特徴量から，Real AdaBoost の学習アルゴリズムを用いて特徴選択を行い，予め識別に有効な特徴量のみで構成される特徴量候補を作る．この特徴量候補に含まれる特徴量のみを組み合わせることで，識別精度を維持しつつ学習時間を削減することができる．

特徴量候補を作成するには．まず，HOG 特徴量，CSS 特徴量の計 11,908 次元の特徴量から，式 (7)，(8) よりポジティブクラス (+: 検出対象) とネガティブクラス (-: 非検出対象) の確率密度関数  $W_+$ ， $W_-$  を学習サンプルの重み  $D_t$  に基づいて作成する．

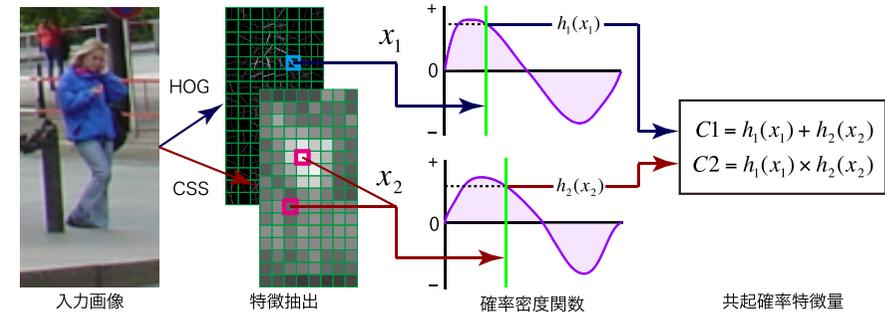


図 5 HOG 特徴量と CSS 特徴量を用いた共起確率特徴量の生成  
Fig. 5 Generation of Co-occurrence Probability Feature with HOG feature and CSS feature.

$$W_+^j = \sum_{i: j \in J \wedge y_i = +1} D_t(i) \quad (7)$$

$$W_-^j = \sum_{i: j \in J \wedge y_i = -1} D_t(i) \quad (8)$$

ここで， $t$  は学習回数， $i$  は学習サンプルの番号， $j$  は確率密度関数  $W_{\pm}$  の量子化番号， $y_i$  はクラスのラベル  $y \in \{1, -1\}$  を表している．本研究では，確率密度関数  $W_{\pm}$  の量子化数は 64 とした．次に確率密度関数  $W_{\pm}$  を用いて，式 (9) より特徴量の識別性能を表す評価値  $z$  を算出する．

$$z = 1 - 2 \sum_j \sqrt{W_+^j W_-^j} \quad (9)$$

評価値  $z$  が高いほど，ポジティブクラスとネガティブクラスの分布が分離していることを意味している．全ての特徴次元から得られる，確率密度関数  $W_{\pm}$  の評価値  $z$  を降順に並び替え，評価値  $z$  の高い順に任意の個数の特徴量を特徴量候補とする．そして，作成された特徴量候補に含まれる特徴量のみを用いて共起確率特徴量を生成する．本研究では，文献<sup>7)</sup> 同様に特徴量候補数を 200 個とした．そのため，生成される共起確率特徴量は  $200 C_2 \times 2 = 39,800$  個となる．

#### 3.1.2 局所特徴量の組み合わせによる共起確率特徴量の生成

共起確率特徴量は，Real AdaBoost の複数の弱識別器から得られる出力値を演算子によって結合した特徴量である．そのため，複数の特徴量を演算子により多様な捉え方で観測す

ることが可能となり，単一の特徴量のみでは識別が困難なパターンに対しても高精度な検出が可能となる．まず，共起確率特徴量を生成するために，弱識別器の出力値  $h(x)$  を式 (10) より算出する．

$$h(x) = \frac{1}{2} \ln \frac{W_+ + \epsilon}{W_- + \epsilon} \quad (\epsilon = 0.0000001) \quad (10)$$

次に，図 5 に示すように，特徴量候補の中から選択した二つの特徴量  $x_1, x_2$  の出力値を  $h_1(x_1), h_2(x_2)$  としたとき，式 (11)，式 (12) の和と積の演算子により結合した共起確率特徴量  $C_1, C_2$  を生成する．

$$C_1 = h_1(x_1) + h_2(x_2) \quad (11)$$

$$C_2 = h_1(x_1) \times h_2(x_2) \quad (12)$$

共起確率特徴量  $C_1$  は，弱識別器の出力値を和で結合するため，二つの特徴量を総合的に捉える特徴量となる． $C_1$  は弱い共起表現をするため，片方の特徴量が遮蔽物による隠れやノイズ等の影響を受けた場合においても，もう一方の特徴量がクラスをよく表現していれば，対象のクラスに反映した特徴量となる．共起確率特徴量  $C_2$  は，弱識別器の出力値を積で結合するため，二つの特徴量の出力値が共に高いときは表現能力の高い特徴量となり，それ以外は小さい特徴量となる． $C_2$  は強い共起表現をするため，二つの特徴量の両方が共に対象物体らしさを表現する時に有効な特徴量となる．本研究では，HOG 特徴量と CSS 特徴量を特徴量候補とするため，特徴量の組み合わせは HOG 特徴量同士，CSS 特徴量同士，HOG 特徴量と CSS 特徴量の組み合わせによる三種類の共起確率特徴量が考えられる．

### 3.1.3 共起確率特徴量を用いた学習

生成した共起確率特徴量を用いて Real AdaBoost により識別器を学習する．3.1.1 で説明した特徴量候補は，更新される学習サンプルの重みに従い，Real AdaBoost における弱識別器の選択の際に作成する．これにより，前の弱識別器の選択の際に，誤識別した学習サンプルを正しく識別するような特徴量候補が毎回作成される．

強識別器の学習は，まず，作成された特徴量候補から評価値の上位 200 個を用いて，共起確率特徴量を作成する．次に，作成した共起確率特徴量から確率密度関数  $W_{\pm}$  を作成し，評価値  $z$  を算出する．その中から最も評価値  $z$  の高い弱識別器候補を弱識別器  $h_t(x)$  として採用する．この処理を指定した学習回数  $T$  まで繰り返し，式 (13) に示す強識別器  $H(x)$  を構築する．

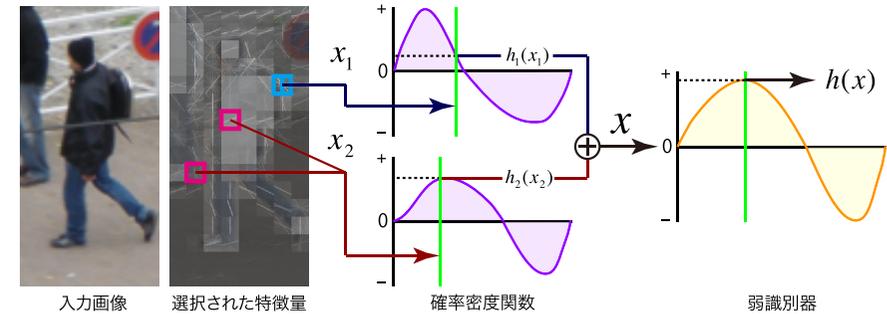


図 6 HOG 特徴量と CSS 特徴量を用いた共起確率特徴量による識別  
 Fig. 6 Classifier by Co-occurrence Probability Feature with HOG feature and CSS feature.

$$H(x) = \text{sign} \left[ \sum_{t=1}^T h_t(x) - \lambda \right] \quad (13)$$

ここで， $T$  は学習回数， $\lambda$  は閾値を表す．

### 3.2 HOG 特徴量と CSS 特徴量を用いた共起確率特徴量による識別

学習した強識別器  $H(x)$  を用いて未知入力画像を識別する際の流れについて述べる．識別は図 6 に示すように，まず，未知入力画像から共起確率特徴量を生成するための二つの特徴量  $x_1, x_2$  を抽出する．次に， $x_1, x_2$  から出力値  $h_1(x_1), h_2(x_2)$  を算出し，選択された演算子により結合して共起確率特徴量  $x$  を生成する．最後に，生成された共起確率特徴量  $x$  から出力値  $H(x)$  を算出する．この処理を  $T$  個の弱識別器に対して計算し，式 (13) に示すように弱識別器  $h(x)$  の線形和を閾値  $\lambda$  により判定することで，検出対象と非検出対象を識別する．

## 4. 評価実験

提案手法の有効性を確認するために評価実験を行う．

### 4.1 データセット

評価実験には予め人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



図 7 INRIA Person Dataset の一部  
Fig. 7 Examples of INRIA Person Dataset.

検出のベンチマークとして広く利用されている INRIA Person Dataset<sup>\*1</sup>を使用する。図 7 に INRIA Person Dataset の一部を示す。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。評価サンプルにはポジティブサンプル 1,176 枚、ネガティブサンプル 9,060 枚を使用し、学習サンプル、評価サンプル共に  $64 \times 128$  ピクセルの大きさに正規化して使用する。

#### 4.2 実験概要

提案手法を評価するために、以下の特徴量を用いた手法と比較する。

- HOG 特徴量 (HOG)
- CSS 特徴量 (CSS)
- HOG 特徴量と CSS 特徴量の併用 (HOG+CSS)

HOG 特徴量と CSS 特徴量の併用は、二つの特徴量を用いて特徴量候補を生成し、その中から一つの特徴量を弱識別器に使用する。各特徴量のパラメータを、HOG 特徴量のセルサイズは  $8 \times 8$  ピクセル、ブロックサイズは  $2 \times 2$  セル、勾配方向数は 9 方向。CSS 特徴量のセルサイズは  $8 \times 8$  ピクセル、色ヒストグラムの量子化数は 9 (各色の量子化数 3) とした。提案手法と比較手法は Real AdaBoost を用いて識別器を学習する。評価に用いる弱識

\*1 INRIA Person Dataset  
<http://pascal.inrialpes.fr/data/human/>

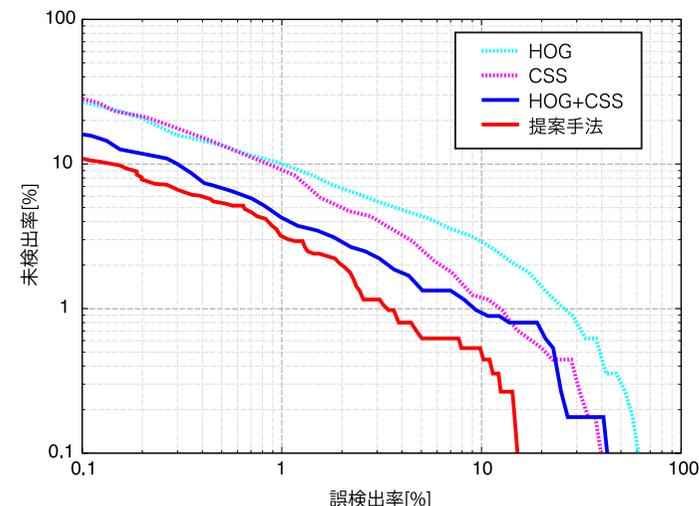


図 8 評価実験による DET カーブ  
Fig. 8 DET curves of evaluation experiment.

別器数は 500 個で統一する。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 8 に示す。提案手法は全ての手法の中で最も高い検出性能が得ていることがわかる。誤検出率 1% において、HOG+CSS と HOG, CSS の単一の特徴量と比較すると、HOG+CSS は約 5~6% 検出精度が向上している。これは、単一の特徴量に比べて二つの異なる性質の特徴量を併用して使用することによる効果であるといえる。次に HOG+CSS と提案手法を比較する。HOG+CSS と比較して、提案手法は約 1.5% 検出精度を向上させることができた。提案手法は、共起表現により二つの特徴量の関係性を効果的に捉えることができたため、検出性能が向上したといえる。

#### 4.4 人検出例

図 9 に人検出の例を示す。図 9 中の矩形は検出結果を表しており、青色は人を正確に検出した結果、赤色は誤検出の結果を示している。また、黄色の破線で表している楕円は未検出を示している。検出結果より、HOG 特徴量を用いた識別器では人を検出できているが、背

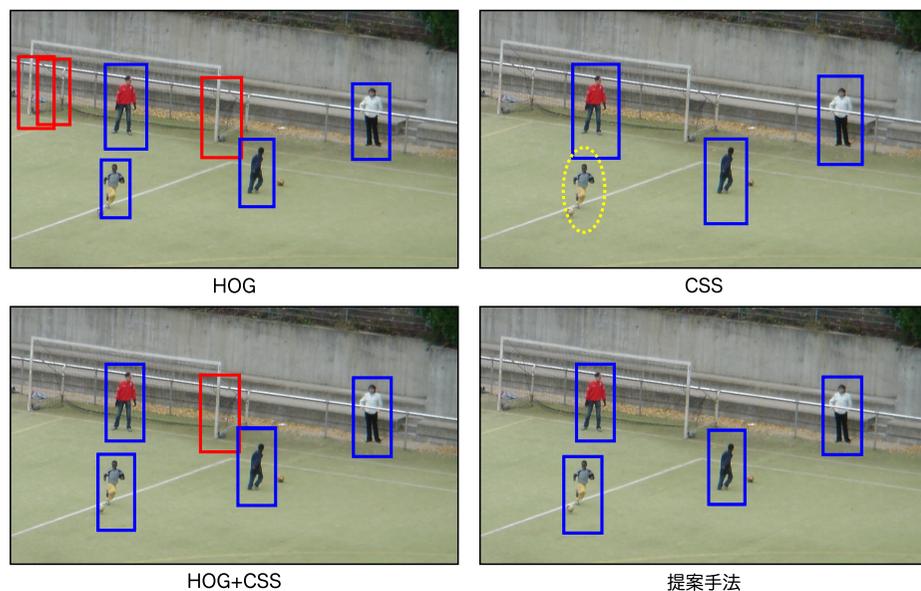


図 9 人検出の例  
Fig. 9 Examples of human detection.

景領域の垂直物等に誤検出が発生している。一方、CSS 特徴量を用いた識別器では誤検出はないが、下半身が背景と類似している人を未検出する。HOG 特徴量と CSS 特徴量を併用した識別器では、HOG、CSS と比較して誤検出、未検出が共に減少していることがわかる。これらの識別器と比較し、提案手法は誤検出、未検出がなく正確に人を検出することができた。

#### 4.5 考 察

提案手法と従来法で強識別器の出力値にどのような変化があるかを確認するため、評価サンプルの強識別器の出力値を比較する。図 10 に、提案手法と HOG+CSS の各サンプルにおける強識別器の出力値の分布を示す。横軸に提案手法の強識別器の出力値、縦軸に HOG+CSS の強識別器の出力値を示し、対角線上（緑線）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。図 10 より、提案手法はポジティブサンプルの 89% が青色の領域に分布し、ネガティブサンプルの 96% が赤色の領域に分布していることがわかる。これにより、提案手法は HOG+CSS と比較し、各サンプルがより正解クラスらしい出力値となる

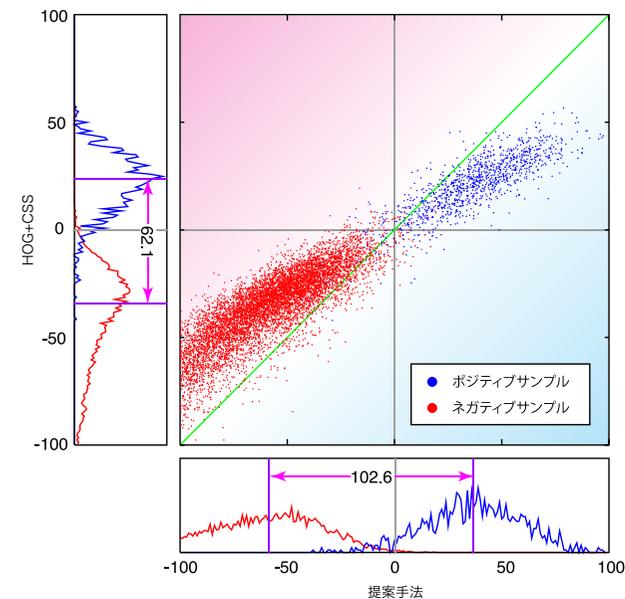
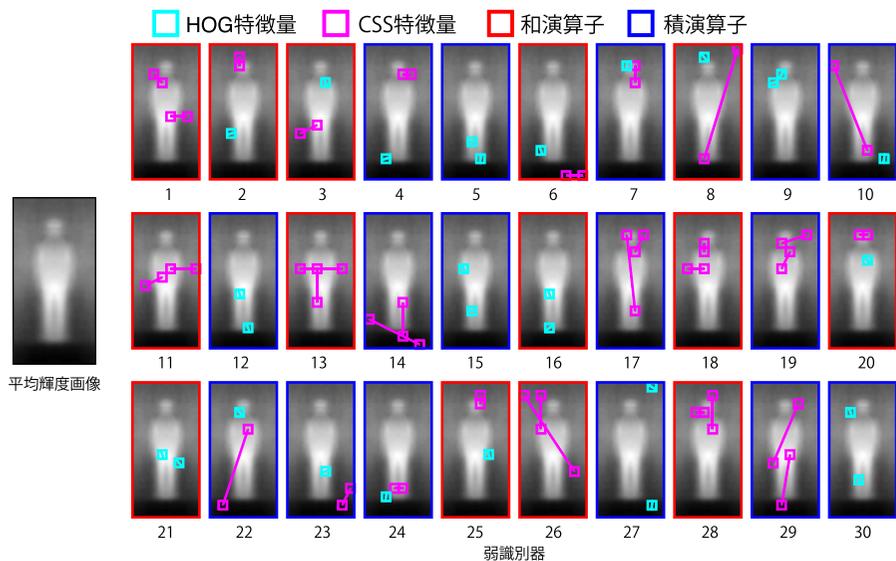


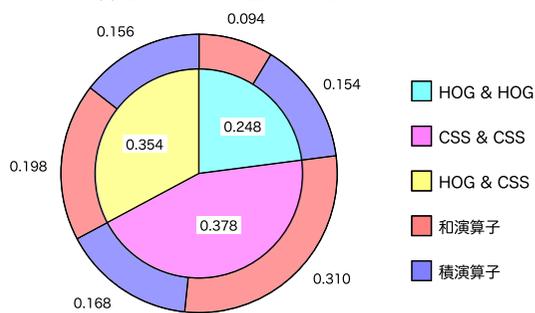
図 10 強識別器の出力値  
Fig. 10 Output of strong classifier.

ことを確認した。また、評価サンプルにおける強識別器の出力値の分布は、ポジティブとネガティブのクラス間の重なりが少なく、クラス間の距離が大きいほど人検出の精度が良い。図 10 より、HOG+CSS の各クラスの平均の距離は 62.1 なのに対し、提案手法は 102.6 と大きくなっていることがわかる。以上より、提案手法は HOG+CSS と比較し、共起表現によりクラス間の分離能力が向上した。クラス間の分離能力が向上したことにより、誤識別の発生が低減されるため、HOG+CSS と比較し識別精度が向上したといえる。

次に、学習により選択された特徴量と演算子について調査する。図 11(a) に、Real Adaboost により学習回数 30 回までに選択された弱識別器を示す。図 11(a) に示す各画像は、学習サンプルから算出した平均輝度画像に、選択された特徴量を可視化したものである。図 11(b) は学習によって選択された 500 個の特徴量とその演算子の割合を円グラフで示している。選択された特徴量は、学習の初期では和演算子の共起表現法が選択されている。これは、和演算子の弱い共起表現を用いて、対象物体の特徴をおおまかに捉えてクラスを大きく分離していると考えられる。そして、学習が進むにつれて、積演算子の共起表現法が選択



(a) 選択された特徴量の可視化



(b) 選択された特徴量の割合

図 11 選択された特徴量  
Fig. 11 Selected feature.

されている。積演算子の強い共起表現により、二つの特徴量が共に対象物体を強く表現し、和演算子では捉えきれなかったサンプルに対し有効に働いていると考えられる。また、選択された特徴量と演算子は図 11(b) から確認できるように、様々なパターンの共起確率特徴量が生成されている。このことから、提案手法は単一の特徴量と比べ、多様な特徴表現を可能

にし、検出精度を向上させることができたといえる。

## 5. おわりに

本稿では、形状と色の類似特徴を用いた共起確率特徴量による人検出を提案した。形状特徴である HOG 特徴量と色の類似特徴である CSS 特徴量を用いて共起確率特徴量を生成することにより、多様な特徴表現を可能にした。評価実験の結果、従来の単一の特徴量と比較して検出精度を向上させることができた。今後は、さらなる人検出の高精度化として、色情報を有効利用した特徴量について検討する予定である。

## 参考文献

- 1) N, Dalal. and B, Triggs.: Histograms of Oriented Gradients for Human Detection, IEEE Computer Vision and Pattern Recognition, pp. 886-893, (2005).
- 2) K, Levi. and Y, Weiss.: Learning Object Detection from a Small Number of Examples: the Importance of Good Features, IEEE 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, IEEE International Conference on Computer Vision, vol. 1, pp. 90-97, (2005).
- 4) S, Walk. and N, Majer.: New Features and Insights for Pedestrian Detection, IEEE Computer Society Conference on Computer Vision and Pattern Recognition (2010).
- 5) T, Mita. T, Kaneko. B, Stenger. and O, Hori.: Discriminative Feature Co-Occurrence Selection for Object Detection, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 30, no. 7, pp. 1257-1269, Jul, (2008).
- 6) 三井相和, 山内悠嗣, 藤吉弘巨: Joint 特徴量を用いた 2 段階 Boosting による物体検出, 電子情報通信学会論文誌, Vol. J92-D, No. 9, pp. 1591-1601, (2009).
- 7) 山内悠嗣, 山下隆義, 藤吉弘巨: Boosting に基づく特徴量の共起表現による人検出, 電子情報通信学会論文誌, vol. J92-D-II, no.8, pp.1125-1134, (2009).
- 8) P, Viola. and J, Jones.: Robust real-time face detection, International Journal of Computer Vision, 57(2), pp. 137-154, (2004).
- 9) Y, Freund. and R, E, Schapire.: Experiments with a new boosting algorithm, In Proceedings of the Thirteenth International Conference on Machine Learning, (1996).
- 10) R, E, Schapire. and Y, Singer.: Improved Boosting Algorithms Using Confidence-rated Predictions, Machine Learning, No. 37, pp. 297-336, (1999).