

人検出のための学習サンプルの自動生成とMILBoostを用いた学習法

A Learning Method Using MILBoost and Automatic Generation of Training Samples for Human Detection

草富 省吾† 山内 悠嗣† 藤吉 弘亘†

Shogo Kusatomi†, Yuji Yamauchi†, Hironobu Fujiyoshi†

† 中部大学

† Chubu University

E-mail: shogo@vision.cs.chubu.ac.jp, hf@cs.chubu.ac.jp

Abstract

人検出に用いられる統計的学習法は、大量の学習サンプルを必要とするため、サンプルの収集コストが高い。また、学習サンプルを収集した環境と人検出システムが稼働する環境が異なる場合には、検出性能が低下することがある。そこで、本稿では3次元人体モデルから学習サンプルの自動生成と改良型MILBoostを用いた生成型学習法を提案する。本研究では、3次元人体モデルを用いて特定シーンに特化した学習用ポジティブサンプルを自動的に生成する。学習用ネガティブサンプルは、映像からランダムに自動的に切り出して収集するが、誤ラベルが付与されたサンプルを収集することがある。誤ラベルが付与された学習サンプルを用いて統計的学習手法により識別器を学習すると、識別能力が低下するという問題がある。そこで、本研究では誤ラベルのサンプルが混在しても悪影響を受けない生成型学習をMILBoostを用いて実現する。評価実験の結果、3次元人体モデルから生成した学習サンプルを用いて学習した識別器は、人手で切り出した学習サンプルを用いて学習した識別器よりも高い検出性能であることを確認した。また、提案手法は学習用ネガティブサンプル中に人画像が混在した状態においても、識別性能の低下を抑制することができた。

1 はじめに

画像中から自動的に人を検出する技術は、セキュリティやマーケティングなどの多種多様な分野で実現が期待され、人検出の高精度化に関する研究が数多く提案されている[1]~[10]。近年提案された人検出法は、人の形状に着目した特徴量[4],[5],[6]や、人の動きに着目した特徴量[1]~[3],[7]、色情報を利用した特徴量[8],[9]、人の識別に対して有効な特徴量をどのように捉えるか

を検討した手法が多い。これらの特徴量は、人検出を困難とする人の姿勢や体型、衣服の違いなどの“人の個体差に関する要因”を吸収しつつ、人らしさを捉えることで検出性能の向上に貢献した。しかし、学習用データベースを収集した環境と人検出システムが稼働するシーンが異なる場合、人検出性能が低下するという問題がある。この問題を解決するためには、システムが稼働する環境からデータを採取して、識別器を再学習する必要がある。しかし、シーン毎に人検出器を学習するためのデータセットを作成することは大きな労働力と多大な時間を必要とし、実際には難しい問題である。

これらの問題を解決するアプローチとして、少数の学習サンプルからスケール変化や回転、ノイズの付加などの実環境で測定される変動を含むように変形させた学習サンプルを生成し、それらのサンプルを用いて識別器を学習する生成型学習法[13]が提案されている。文献[11]では、車載カメラから見える路面上の標識に対して、光学ぼけや動きぼけなどを考慮したサンプルを生成し、学習に利用した。文献[12]では、道路標識に対して、位置ずれや回転などの形状の変化、背景などのテクスチャの変化、反射や影などの色の変化を考慮した生成モデルを用いて学習サンプルを生成した。しかし、これらの手法が認識対象とするのは比較的簡単な2次元パターンであり、人のような非剛体で複雑な形状を持つ物体に対しては、同様のアプローチで学習サンプルを生成するのは困難である。

そこで、3次元人体モデルから学習サンプルの自動生成と改良型MILBoostを用いた生成型学習法を提案する。本研究では、3次元人体モデルを用いて特定シーンに特化した学習用ポジティブサンプルを自動的に生成する。学習用ネガティブサンプルは、映像からランダムに自動的に切り出して収集するが、誤ラベルが付与されたサンプルを収集することがある。誤ラベルが付与された学習サンプルを用いて統計的学習手法により

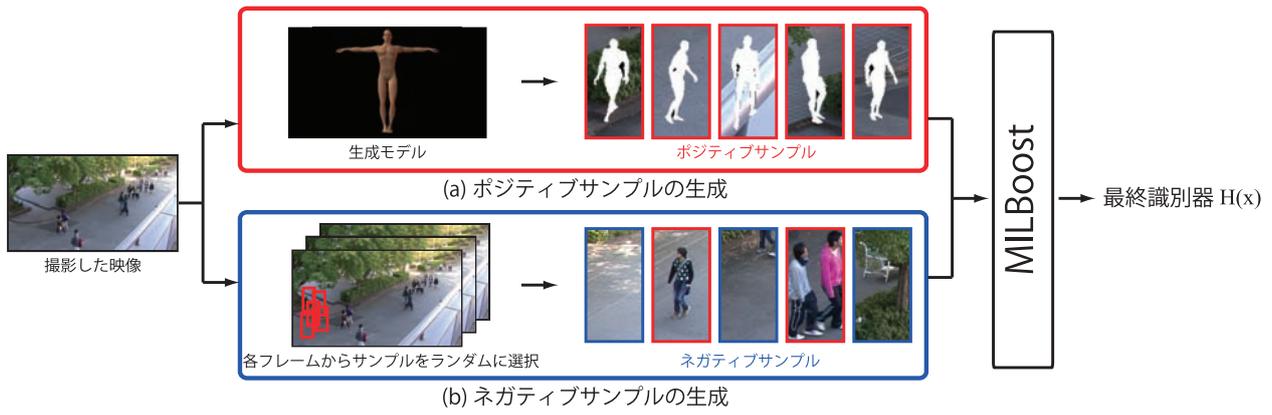


図1 提案手法による生成型学習の流れ

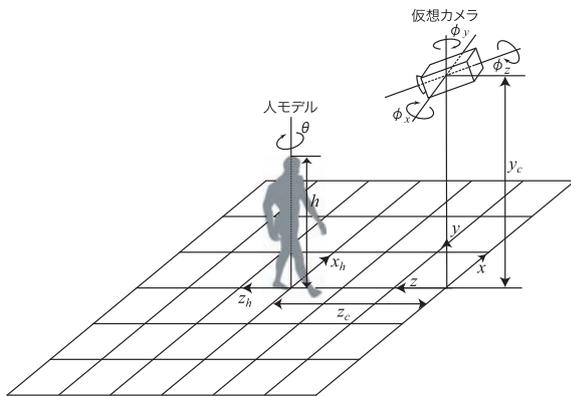


図2 3次元人体モデル

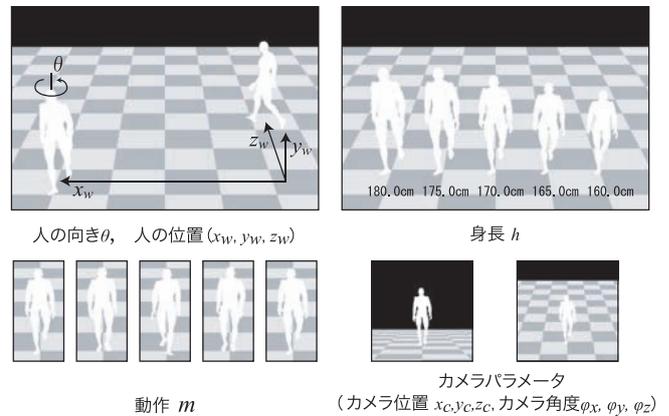


図3 パラメータに対応した人体モデル

識別器を学習すると、識別能力が低下するという問題がある。そこで、本研究では誤ラベルのサンプルが混在しても悪影響を受けない生成型学習を MILBoost を用いて実現する。

本稿では、2章で人体モデルを用いて特定シーンに特化した学習サンプルを生成する方法について述べる。3章では、誤サンプルが存在する学習用サンプルを用いた MILBoost による学習について述べる。4章で提案手法の有効性を示すために3つの評価実験を行う。

2 生成モデルを用いた学習用人画像の生成

提案手法による識別器を学習するまでの流れを図1に示す。提案手法は、特定シーンに特化した学習サンプルを自動生成するために、ポジティブサンプルは3次元の人体モデルを用いてシルエット画像を生成する(図1(a))。ネガティブサンプルは映像中から切り出す(図1(b))。そして、生成したサンプルを改良型 MILBoost に入力することで識別器を学習する。

学習用ポジティブサンプルの生成には、図2に示すような人体モデルを用いることで、様々な視点からの

自然で自由な姿勢の人体シルエット画像を生成することが可能となる。

2.1 3次元人体モデル

提案手法で使用する人体モデルには、形状モデルやモデルの各パーツの階層構造、動作データなどが含まれている。人体の形状モデルは、19のパーツが存在し、これらのパーツは階層的な構造で表現される。そのため、例えば右肩を動かした場合、右腕や右手が連動して動く。本研究では、19のパーツに歩行動作のパラメータを与えることで、歩行姿勢として人体モデルを表現する。また、下記のパラメータを与えることで図3に示すように任意の視点から撮影した人体モデルの姿勢を得ることができる。

- カメラパラメータ
カメラ位置 x_c, y_c, z_c , カメラ角度 ϕ_x, ϕ_y, ϕ_z
- 人体形状パラメータ
身長 h , 人の向き θ , 人の位置 x_h, y_h, z_h
- テクスチャ
背景のテクスチャ T_{bg} , 人体のテクスチャ T_{in}

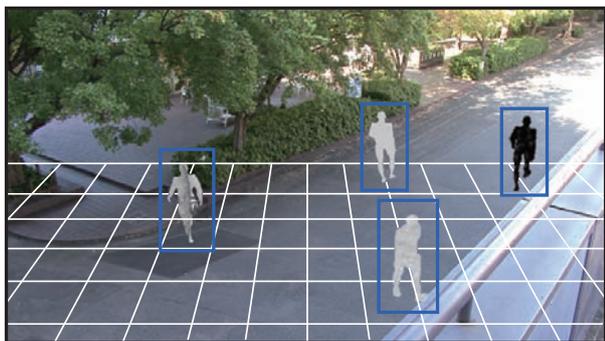


図4 実環境を考慮したシルエット画像の生成の例 (カメラ位置 $(x_c, y_c, z_c) = (0\text{m}, 6.2\text{m}, 0\text{m})$, カメラ角度 $(\phi_x, \phi_y, \phi_z) = (21^\circ; 0^\circ; 0^\circ)$)

2.2 ポジティブサンプルの生成

特定シーンに特化した人体シルエット画像を得るために、実環境に設置したカメラのパラメータを3次元人体モデルに入力する。本研究では、固定カメラを想定し、事前に得たカメラパラメータをモデルに与える。上記のパラメータの中で、人の向きと位置は事前に決定できないパラメータであるため、一様ランダムとする。人の身長は、文部科学省の統計調査より平均身長171.9cmとする。人体のテクスチャは、衣服などを考慮することも考えられるが、多種多様な種類の衣服を用意する事が難しい。人体のテクスチャを張り付けないことも考えられるが、このようなサンプルを用いて学習した場合、人の内部はテクスチャがないものとして学習される。そこで、本研究では事前に用意した自然画像のテクスチャをランダムで張り付ける。また、設置したカメラから得られる画像を、背景のテクスチャとして用いる。図4はカメラの高さ $y_c = 6.2\text{m}$, カメラ角度 $\phi_x = 21^\circ$ とした際の特定シーンにおける人体シルエット画像を生成した例である。生成した人体シルエットを中心に切り出した画像を学習用ポジティブサンプルとして用いる。

2.2.1 ネガティブサンプルの生成

学習用ネガティブサンプルは、図1(b)に示すように動画の各フレームからランダムに切り出して生成する。本来、人物が存在しないフレームを用いるが、歩行者の交通量が多い場所では、背景のみの画像を収集するのが難しい。そのため、切り出す領域をランダムに決定する際に誤って人の画像をネガティブサンプルとして収集するという問題が発生する。

本研究では、この問題を解決するために、誤ラベルが付与されたサンプルの混在を考慮した MILBoost により識別器の学習を行う。

3 学習サンプルの混在を考慮した MILBoost による学習

本章では背景サンプル中に人の画像が混在してしまう問題を解決するために、改良型 MILBoost による識別器の学習法について述べる。

3.1 MILBoost[14]

物体検出に利用される統計的学習手法は、各サンプルに対して与えられたラベルに基づき学習する。これに対して Multiple Instance Learning (MIL) では、複数のサンプルから構成される Bag に対してラベルを付与する。Bag 中のサンプルに一つでもポジティブが含まれていればポジティブ Bag となり、それ以外はネガティブ Bag とラベル付けされる。MIL では、Bag に与えられたラベルに基づき識別器を学習する。そのため、ラベルが付与されていない未知のサンプルを含むデータに対しても学習が可能なアプローチとなる。本研究では MIL を Boosting に導入した MILBoost[14] を学習に用いる。

MILBoost は MIL の学習モデルを Boosting に導入した学習アルゴリズムであり、Viola らは MILBoost により効率的に顔検出器を学習する方法を提案した。この手法は、顔周辺を適当にサンプリングすることでポジティブ Bag としポジティブサンプルの収集を簡略化した。そして、Boosting により学習する際に各 Bag と各サンプルに対するクラス尤度を求め、サンプルに対する重みの更新時に、クラス尤度を用いて誤って付与されたラベルのサンプルの重みを小さくする。これにより、誤って付与されたラベルの影響を抑制することが可能となる。

3.2 MILBoost の改良

提案手法では、従来の MILBoost を本研究の問題設定に適用する。ここでは、まず Bag の作成方法について述べ、次に本研究の問題設定に適用した改良型 MILBoost の学習アルゴリズムについて述べる。

3.2.1 Bag の作成方法

本研究の問題設定では、背景サンプルの一つ一つに正しいラベルを必ずしも与えることができない。そのため、文献 [14] の Bag の構成を変更する。図5にネガティブ Bag の作成方法を示す。提案手法のポジティブ Bag は、各ポジティブサンプル一つを一つの Bag として扱い、ネガティブ Bag は、多数のネガティブサンプルに加え、幾つかのポジティブサンプルを含む可能性がある。ネガティブ Bag は、2つのアイデアに基づき作成する。1つ目のアイデアは、映像中の人は長時間に亘り一定の場所に留まらないという特性が見られるため、映像中のある座標をランダムに決定し、時間軸方

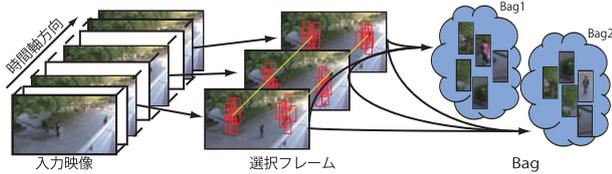


図5 ネガティブクラスの Bag の作成方法

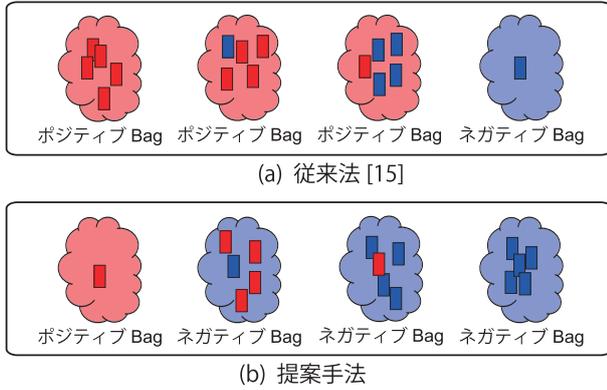


図6 提案手法による Bag の構成 (赤色はポジティブを表し, 青色はネガティブを表す)

向にランダムで選択したフレームの背景画像を切り出す. 2つ目のアイデアは, 1つ目のアイデアにより切り出した全ての背景画像の周辺は人が密集している可能性は低いと考え, 切り出した背景画像の周辺をランダムに背景画像として切り出す. この2つのアイデアを組み合わせ, 切り出した複数の画像をネガティブ Bag とする.

3.2.2 学習

MILBoost の学習過程は学習サンプルに対する重みの更新以外は Real AdaBoost[15] と共通である. 図 6(b) に示した Bag の構成に基づく MILBoost の学習アルゴリズムを Algorithm 1 に示す.

まず, 学習の事前準備として J 個の学習サンプルが所属する I 個の Bag を用意する. そして, これらの Bag に対してラベルを与える. 次に, i 番目の Bag に所属する j 番目のサンプルの重み w_{ij} を式 (1) により初期化する.

次に, MILBoost により強識別器を学習する. まず, 特徴量 x_{ij} を入力とした確率密度関数 W_+ , W_- を式 (2)(3) により作成する. 本研究では, 特徴量として Histogram of Oriented Gradients(HOG) 特徴量 [6] を用いる. 確率密度関数 W_{\pm} は, 1次元のヒストグラムにより表現され, 学習サンプルの重み $w_t(i, j)$ を累積することで作成する. ここで t は学習回数, k は1次元ヒストグラム

Algorithm 1 提案手法の MILBoost

入力

J 個の学習サンプルが所属する I 個の Bag に対して正解ラベル $y \in \{1, 0\}$ を与える.

初期化

学習サンプルに対する重み $w_t(i, j)$ を初期化

$$w_1(i, j) = \frac{\text{クラスの Bag 数}}{\text{全ての Bag 数}} \quad (1)$$

学習

for $t = 1, 2$ to T T 回の学習回数 do

for $l = 1, 2$ to L L 個の弱識別器候補 do

弱識別器候補 $h_t(x)$ の確率密度関数 W_{\pm} の作成

$$W_+^k = \sum_{i, j: k \in K \wedge y_i = 1} w_t(i, j) \quad (2)$$

$$W_-^k = \sum_{i, j: k \in K \wedge y_i = 0} w_t(i, j) \quad (3)$$

弱識別器 $h(x)$

$$h(x) = \frac{1}{2} \ln \frac{W_+^k + \varepsilon}{W_-^k + \varepsilon} (\varepsilon = 10^{-7}) \quad (4)$$

評価値 Z_l の算出

$$Z_l = 2 \sum_{k=1}^K \sqrt{W_+^k W_-^k} \quad (5)$$

end for

最も Z_l が小さい弱識別器候補 $h_t(x)$ を選択

$$h_t(x) = \arg \min_{l \in \mathcal{L}} Z_l \quad (6)$$

end for

学習サンプルの重み $w_t(i, j)$ の更新

$$w_{ij} = \begin{cases} -p_{ij} & \text{if } y_i = 1 \\ \frac{p_{ij} \times (-p_i)}{1-p_i} & \text{if } y_i = 0 \end{cases} \quad (7)$$

$$p_i = \prod_{j \in \text{Bag}_i} p_{ij} \quad (8)$$

$$p_{ij} = \frac{1}{1 + \exp(-H_t(x))} \quad (9)$$

出力

最終識別器 $H(x)$

$$H(x) = \text{sign} \left(\sum_{t=1}^T h_t(x) \right) \quad (10)$$

の BIN の番号を表す,

確率密度関数 W_{\pm} を作成後, 式 (5) より弱識別器 $h(x)$ の評価値 Z を求める. 評価値 Z は弱識別器の識別性能を表し, 小さいほどポジティブサンプルとネガティブサンプルを分離する能力があることを表している. これを全ての弱識別器候補について求め, 式 (6) に示すよ

表 1 学習用データセットの内訳

	Pos.	Neg.
データ 1	INRIA(2,416 枚)	実環境 (12,180 枚)
データ 2	実環境 (2,416 枚)	実環境 (12,180 枚)
データ 3	生成 (2,416 枚)	INRIA(12,180 枚)
データ 4	生成 (2,416 枚)	実環境 (12,180 枚)

うに最も識別性能が高い弱識別器候補を t 個目の弱識別器 $h_t(x)$ とする。

弱識別器を選択後, 誤識別した学習サンプルを次のラウンドにおいて正しく識別するために, 学習サンプルの重みを更新する. MILBoost では, サンプルに対するクラスラベルが付与されていないため, 学習サンプルの重み w_{ij} は Bag のラベルに基づき更新される. ポジティブ Bag に含まれるサンプルには, サンプルのクラス尤度 p_{ij} により重みを更新する. クラス尤度は, 高い値であるほど人画像, 低い値であるほど背景画像の可能性が高いことを表している. ネガティブ Bag に含まれているサンプルは, サンプルのクラス尤度 p_{ij} と Bag のクラス尤度 p_i により重みを更新する. 重み w_{ij} は, Bag のクラス尤度 p_i の値が低く, サンプルのクラス尤度 p_{ij} の値が高い場合では高くなる. 逆に, p_i の値と, p_{ij} の値が低い場合は重み w_{ij} は低い値になる. 以上の処理を T 回繰り返すことで, 最終識別器 $H(x)$ を得る.

3.2.3 識別

識別時は, 従来法である Real AdaBoost と同様に計算する. 式 (10) に示すように複数の弱識別器の線形和をしきい値により大きいときは人, そうでないときは背景として識別結果を出力する.

4 評価実験

提案手法の有効性を示すために 3 つの評価実験を行う. 1 つ目の実験では, 特定シーンに特化した学習サンプルを生成することの有効性を示す. 次に, 2 つ目の実験では, ネガティブの誤サンプルに対応した MILBoost による検出器の学習法の有効性を評価実験により示す. 最後に, 3 つ目の実験では実環境における性能を評価する.

4.1 実験 1: 自動生成の評価

4.1.1 実験概要

特定シーンに特化した学習サンプルの自動生成による有効性を評価する. 下記のデータベース毎に比較する.

- データ 1: INRIA Pos. + 実環境 Neg.
- データ 2: 実環境 Pos. + 実環境 Neg.

- データ 3: 生成 Pos. + INRIA Neg.
- データ 4: 生成 Pos. + 実環境 Neg.

INRIA Pos. と INRIA Neg. は, Web 上で一般公開されている INRIA Person Dataset[6] に含まれている人画像と背景画像である. このデータベースは, 多様な人の姿勢, 向き, 視点, 照明の変動や背景テクスチャを含んでおり, 非常に汎用性の高いデータベースである. 実環境 Pos. は, 実環境下で撮影した映像から人手により切り出した人画像である. 生成 Pos. は, 2 章にて述べた 3 次元人体モデルを用いて生成した人画像である. 実環境 Neg. は, 実環境下で撮影した映像から人手により切り出した背景画像である. 本実験に使用する実環境下の映像は, 人の通行量が多い屋外の通路を撮影したものである. カメラの高さ 6.2m, 俯角 21° としてカメラを設置し, 約 1 時間の映像を撮影した. 提案手法により生成するサンプルは, 人体モデルに上記のカメラの高さと俯角, 背景テクスチャを与えることで生成した. 表 1 に学習に使用する画像データベースの枚数と種類を示す. 図 7 に学習に使用した各データセットのサンプル例を示す. 評価用データベースには, 実環境下で撮影した動画画像からランダムで選択した 450 フレームを評価用データベースとして用いる.

実験結果の比較には Detection Error Tradeoff(DET) カーブを用いる. DET カーブは横軸に False Positive Per Window(FPPW), 縦軸に miss rate を表わし, 左下の原点に近いほど検出性能が高いことを示す.

4.1.2 実験結果

DET カーブを図 8 に示す. まず, ネガティブサンプルが同一のデータ 1, データ 2, データ 4 を比較すると, 検出性能が最も高いのは人体モデルから生成したサンプルを用いたデータ 4 であった. これは, 実環境下で撮影した映像に対応した人の見えを生成できたからといえる. 実環境下の映像から人手で切り出したサンプルを用いたデータ 2 は, 自動生成よりも低い結果となった. これは, 人画像を人手で大量に切り出す際には, 切り出し基準が曖昧になることがあり, これが識別器に悪影響を及ぼしたと考えられる. 汎用性のあるデータベースを用いたデータ 1 の結果が最も低い検出率となった. これは, 学習用データベースの INRIA Person Dataset は実験環境とカメラ位置が異なるため, サンプル中の人の見えも大きく異なるからといえる.

次に, データ 3 とデータ 4 を比較すると, 実環境下で撮影した映像の背景を用いたデータ 4 の方が良い結果が得られた. これは, データ 4 では実環境から生成した学習用ネガティブサンプルを用いているため, 実環境のシーンに特化した識別器となり検出性能が大きい



図7 学習用データセットの例

く向上したといえる。

以上により, 人体モデルから生成されたサンプルを用いることで, 実環境に特化した識別器を学習することができた。これにより, 汎用的なデータセットを用いた場合と比べて検出性能を向上させることができた。

4.2 実験2: 誤サンプルの影響の評価

4.2.1 実験概要

ネガティブの誤サンプルに対応した MILBoost による学習法の有効性を評価する。提案手法と Real AdaBoost を比較する。

- 従来法: Real AdaBoost
- 提案手法: 改良型 MILBoost

改良型 MILBoost の有効性を確認するために, 学習用のネガティブサンプルへ故意に人画像を混在させて識別器を学習する。その際の人画像の割合を 0%~30% まで変動させ, その際の識別結果を比較する。実験に使用するデータベースは, ポジティブサンプルには実環境下で撮影した映像から人手により切り出した人画像 2,400 枚のうち 1,200 枚を用いる。ネガティブサンプル

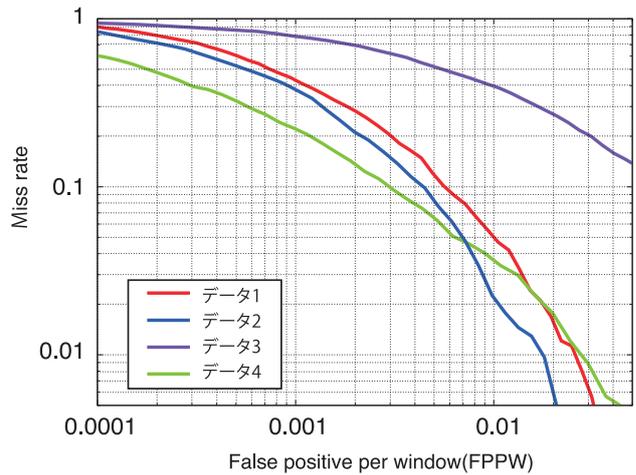


図8 学習サンプルの違いによる検出結果

表2 ネガティブサンプルの4,000枚の内訳

含有率	人画像	背景画像
0 %	0	4,000
5 %	200	3,800
10 %	400	3,600
15 %	600	3,400
20 %	800	3,200
25 %	1,000	3,000
30 %	1,200	2,800

には実環境から収集した背景画像 4,000 枚を用いる。混在させる画像は, 人手によって撮影した映像から人手により切り出した人画像の中のポジティブサンプルに使用していない 1,200 枚を 0%~30% の割合で混在させる。ネガティブサンプルの内訳を表2に示す。評価に使用するデータベースは, 実験1で使用したデータベースと同じものを使用する。

実験結果の比較には Equal Error Rate(EER) を用いる。EER は, Miss rate と FPPW が等しい時の値である。

4.2.2 実験結果

実験結果を図9に示す。実験結果より, ネガティブサンプル中に人画像の含有率が高くなるに従って従来法では EER が高くなるが, 提案手法では EER の増大を抑制していることがわかる。人画像の含有率が 10% の場合を比較すると, 提案手法は従来法よりも EER が 5.8% 低い。以上より, 提案手法はネガティブサンプル中に人画像が含まれていても, 識別器の学習に及ぼす悪影響を低減することができた。

同一ネガティブ Bag に含まれる人画像と背景画像を強識別器の出力と, 学習サンプルの重みの遷移を図10に示す。横軸は学習回数, 左縦軸は強識別器の値, 右縦軸は重みの値を表す。図10より, ネガティブ Bag の

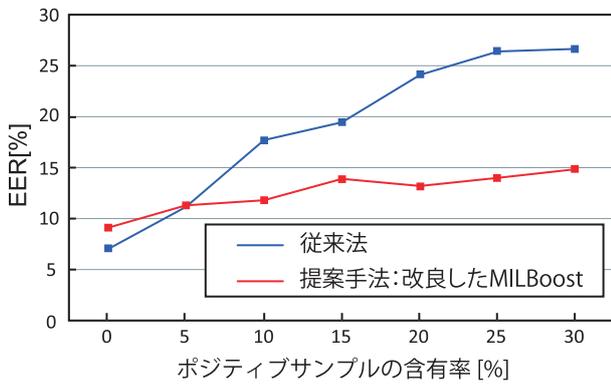


図 9 誤識別率の変化

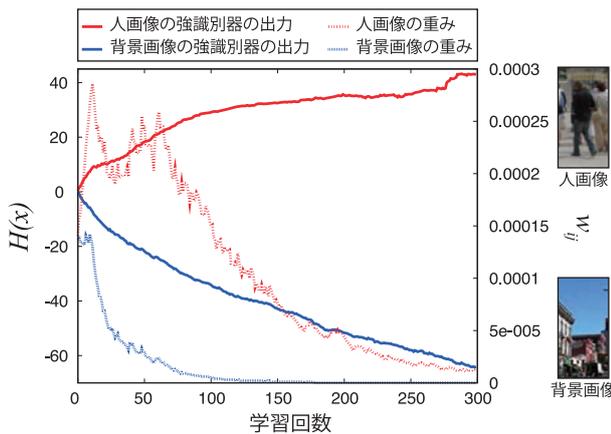


図 10 人画像と背景画像の識別器の出力と重みの遷移

人画像は、学習回数の増加に対して重みが低くなっていることがわかる。これにより、改良型 MILBoost の学習アルゴリズムは、誤ラベルを付与されたサンプルに対して悪影響を受けない学習を実現していることがわかる。

4.3 実験 3：実環境での評価

4.3.1 実験概要

実環境下における提案手法の有効性を示すために、下記の 2 つの手法を比較する。

- 従来法：Real AdaBoost + INRIA Person Dataset
- 提案手法：改良型 MILBoost + 実環境のサンプル

実験に使用する学習用データベースは、従来法では INRIA Person Dataset のポジティブサンプル 2,400 枚、ネガティブ 12,180 枚を用いる。提案手法ではポジティブサンプルには人体モデルから生成したサンプル 2,400 枚、ネガティブサンプルには撮影した映像から収集した画像 12,180 枚を用いる。評価用データベースには、実験 1, 2 で使用したデータベースと同じものを使用する。評価には False Positive Per Image (FPPI) により提案

手法と従来法の比較する。

4.3.2 実験結果

実環境から学習用ポジティブサンプルとネガティブサンプルを生成した。ネガティブサンプルには約 20 % の人画像が含まれていた。表 3 に実験結果を示す。提案手法は従来法と比べ、FPPI を約 1.8 倍、Miss rate を約 1.2 倍に抑制することができた。図 11 に人検出例を示す。結果から、提案手法は従来法に比べ未検出や誤検出を抑制しつつ、検出性能を向上させることができた。

表 3 実環境における人検出結果

	FPPI[個]	miss rate[%]
従来法	2.5	79.4
提案手法	1.4	67.6

5 おわりに

本稿では、3次元人体モデルから学習サンプルの自動生成と改良型 MILBoost を用いた生成型学習法を提案した。特定シーンにおいて、3次元人体モデルから生成した学習サンプルを用いることにより、実環境に特化した識別器を学習することができた。さらに、改良型 MILBoost を用いることにより、誤ラベルを付与されたサンプルに対して悪影響を受けない学習を実現した。これらにより、人手による学習サンプルの収集の手間を無くしつつ、特定シーンにおいて検出性能が向上させることができた。今後は、オンライン学習への展開や、特定シーンにおける人物存在事前確率 [16] を用いて検出性能の高精度化を行う予定である。

参考文献

- [1] P. Viola, M. Jones, and D. Snow, "Detecting pedestrians using patterns of motion and appearance," International Journal of Computer Vision, pp.153-161, 2005.
- [2] A. Ess and B. Leibe and K. Schindler and L. van Gool. "Moving Obstacle Detection in Highly Dynamic Scenes," IEEE International Conference on Robotics and Automation, 2009.
- [3] C. Wojek, S. Walk, and B. Schiele, "Multi-cue onboard pedestrian detection," IEEE Computer Vision and Pattern Recognition, 2009.
- [4] T. Watannabe, S. Ito, and K. Yokoi, "Co-occurrence histograms of oriented gradients for



(a) 従来法



(b) 提案手法

図 11 人検出例 (緑枠は正解した検出ウィンドウ, 赤枠は誤検出したウィンドウを表す)

pedestrian detection,” Image and Video Technology, pp.37-47, 2009.

- [5] 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.
- [6] N. Dalal and B. Triggs: “Histograms of oriented gradients for human detection”, IEEE Computer Vision and Pattern Recognition, 1, pp. 886-893, 2005.
- [7] N. Dalal, B. Triggs, and C. Schmid, “Human detection using oriented histograms of flow and appearance,” European Conference on Computer Vision, 2006.
- [8] P. Ott, and M. Everingham, “Implicit color segmentation features for pedestrian and object detection,” IEEE International Conference on Computer Vision 2009.
- [9] T. Deselaers, and V. Ferrari, “Global and efficient self similarity for object classification and detection,” IEEE Computer Vision and Pattern Recognition, 2010.
- [10] B. Wu and R. Nevatia: “Detection of multiple, partially occluded humans in a single image by bayesian combination of edgelet part detections”, IEEE Computer Vision and Pattern Recognition, 1, pp. 90-97, (2005).
- [11] 野田雅文, 高橋友和, 井手一郎, 目加田慶人, 村瀬洋, “生成型学習を用いた車載カメラ映像中の路面標識認識の検討,” 電子情報通信学会総合大会, p.220, 2008.
- [12] 道満恵介, 出口大輔, 高橋友和, 目加田慶人, 井手一郎, 村瀬洋, “色変動を考慮した生成型学習による道路標識検出器の構築,” 画像の認識・理解シンポジウム (MIRU), 2009.
- [13] 村瀬洋, “画像認識のための生成型学習”, 情報処理学会論文誌, pp.35-42, 2005.
- [14] P. Viola, John C. Platt and Cha Zhang, “Multiple instance boosting for object detection”, In NIPS 18, pp.1419-1426, 2006.
- [15] R. E. Schapire, and Y. Singer, “Improved Boosting algorithms using confidence-rated predictions,” Machine Learning, pp.297-336, 1999.
- [16] 中河秀仁, 渡部済, 木戸出正繼, “人物の移動軌跡と画像の色情報を用いた人物存在事前確率の効率的な獲得”, 画像の認識・理解シンポジウム (MIRU), 2009.