

1. はじめに

人検出に用いる統計的学習法は、大量の学習サンプルを必要とするため、データの収集コストが高くなるという問題がある。この問題に対して、繚織らは人体の生成モデルを用いて、実環境に応じた人の学習サンプルを生成することにより収集コストを削減する手法を提案した [1]。しかし、背景の学習サンプルについては、人が存在しない領域を手で切り出す必要があるため、依然収集コストが高いままである。

そこで、本研究では自動的に収集した背景の学習サンプルと MILBoost[2] を用いて高精度な人検出器を学習する手法を提案する。

2. 提案手法

提案手法では、実環境に応じた学習サンプルを自動的に生成する。人の学習サンプルは、撮影時のカメラパラメータを人体生成モデルに入力することで生成する。背景の学習サンプルは、入力映像からランダムに切り出す。生成した学習サンプルと MILBoost により検出器を学習する。

2.1 実環境に応じた学習サンプルの生成

本研究では、人手を介さずに自動的に学習サンプルを生成する。学習サンプル生成の流れを図 1 に示す。まず、実環境にカメラを設置し、キャリブレーションによりカメラの高さや俯角などのカメラパラメータを得る。次に、カメラパラメータを用いて人体生成モデルにより、環境に対応した人の学習サンプルを自動的に生成する。背景の学習サンプルは、映像中からランダムに切り出す。しかし、切り出した画像中には、人のサンプルに相当するサンプルが混在するという問題があり、学習の際に誤ったラベルに基づいて識別器を学習することになるため、性能の低下に繋がる原因となる。




図 1: 学習サンプル生成の流れ

2.2 MILBoost[2] による検出器の学習

人の学習サンプルが混在してしまう問題に対して、本研究では MILBoost を用いることにより解決する。MILBoost は Boosting に Multiple Instance Learning(MIL) を導入した学習法である。MIL は、複数のサンプルで構成された Bag に対してラベル付けを行い学習する。ポジティブクラスの Bag にネガティブサンプルが混在するような場合でも、悪影響を受けないように学習したからである。

Bag の作成方法 ポジティブクラスの Bag は、サンプル一つを Bag として作成する。図 2 にネガティブクラスの Bag の作成方法を示す。ネガティブクラスの Bag の作成は、映像中の人は一定の場所に留まらないという特性を利用する。まず、入力映像中からランダムにフレームを選択する。次に、選ばれたフレームでランダムに選択した領域を中心として、ランダムに位置を変更してサンプルを生成する。生成されたサンプルの集合をネガティブクラスの Bag とする。

MILBoost の適用方法 本研究では、ネガティブクラスの Bag に、ポジティブクラスのサンプルが含まれる場合においても、悪影響を及ぼさないように検出器を MILBoost を応用して学習する。適用する MILBoost の学習の流れは




図 2: ネガティブクラスの Bag の作成

Real AdaBoost と同様であるが、サンプルの重み w_{ij} の算出方法が異なる。以下に学習の流れを示す。

Step1 ポジティブクラスの Bag はサンプル一つとする

Step2 ネガティブクラスの Bag は切り出されたサンプルの集合とする

Step3 t 個目の弱識別器 $h_t(x)$ を学習

Step4 式 (1) により j 番目のサンプルのクラス尤度 p_{ij} を算出

$$p_{ij} = \frac{1}{1 + \exp(-H_t(x_{ij}))}, p_i = \prod_{j \in i} p_{ij} \quad (1)$$

Step5 式 (1) により i 番目の Bag のクラス尤度 p_i を算出

Step6 式 (2) により学習サンプルの重み w_{ij} を更新

$$w_{ij} = \begin{cases} \frac{p_{ij}(1-p_i)}{p_i} & \text{if } y_i = 1 \\ -p_{ij} & \text{otherwise} \end{cases} \quad (2)$$

Step3 ~ Step6 を繰り返すことにより、最終識別器 $H(x)$ を得る。

3. 評価実験

評価実験により、提案手法の有効性を示す。

3.1 実験概要

実験は、提案手法と従来法である Real AdaBoost を比較する。学習用データセットには INRIA Person Dataset を用いる。学習サンプルのポジティブには 1200 枚、ネガティブには 4000 枚を用いる。ネガティブサンプルはポジティブサンプルを 5% から 30% までの割合で混在させる。評価には、INRIA Person Dataset の評価データセットを用いる。評価サンプルのポジティブには 1126 枚、ネガティブには 4532 枚を用いる。実験は Equal Error rate により比較する。

3.2 実験結果

図 3(a) に実験結果を示す。実験結果から、混在するサンプルの割合が増加すると、従来法の誤識別率は増加傾向にあることがわかる。一方、提案手法は含有率 15% の場合では、従来法よりも識別率を 3.6% 向上させることができた。提案手法はネガティブサンプル中にポジティブサンプルが混在する問題に対して、有効であることがわかる。

図 3(b) は、ネガティブクラスの同一 Bag に含まれているネガティブ、ポジティブサンプルの強識別器の応答値とサンプル重みを比較したものである。ポジティブクラスのサンプルに対してネガティブクラスのラベルが与えられているにも関わらず、小さくなるはずの弱識別器の値が大きい。これは、Bag と学習サンプルのラベルが一致していないサンプルは、MIL のアルゴリズムにより小さな重みが与えられ悪影響を及ぼさない学習が可能となるからである。




図 3: 実験結果

4. おわりに

本研究では、学習サンプルの収集コストを削減するために、学習サンプルの自動生成と MILBoost を用いた学習法を提案した。今後は、オンライン学習を取り入れて、時々刻々と変化する環境への対応について検討する。

参考文献

- [1] 繚織 直也, 山内 悠嗣, 藤吉 弘亘, “人体シルエットの生成型追加学習による人検出の高精度化”, 電子情報通信学会パターン認識・メディア理解研究会 (PRMU), pp. 99-104, 2010.
- [2] Paul Viola, John C. Platt and Cha Zhang, “Multiple instance boosting for object detection”, In NIPS 18, 1419-1426, 2006.