

Boosting に基づく分割統治的戦略による高精度な識別器構築手法の提案

土屋 成光[†] 藤吉 弘亘[†]

[†] 中部大学

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

あらまし 顔や人等の物体検出では、多くの姿勢の異なる同一カテゴリの物体を検出する必要がある。しかし、姿勢の変化は画像上で大きな影響をもたらす、異なる姿勢の物体全てを同一に学習することは困難となる場合がある。この問題を解決するために本稿では、学習サンプルをサブカテゴリに分割し、それぞれに対して学習を行う分割統治的戦略に着目する。弱識別器応答の類似度に着目した学習サンプルのクラスタリングを行い、生成されたサブカテゴリ群に対しマルチクラスブースティングである Joint Boosting を改良したブースティングを用いることで検出性能を向上させる。評価実験の結果、2クラスブースティングに比べ INRIA Person Dataset を用いた評価では誤識別率 0.7% において 7%、UIUC Image Database for Car Detection を用いた評価では誤識別率 0.8% において 13% 検出率を向上させることができた。

キーワード 物体検出, ブースティング, ジョイントブースティング, 分割統治法

A Method for Constructing a High-Accuracy Classifier Using Divide and Conquer Strategy Based on Boosting

Masamitsu TSUCHIYA[†] and Hironobu FUJIYOSHI[†]

[†] Chubu University

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

Abstract Detecting objects like faces and people requires that objects of the same category but of many different poses be detected. However, a change in pose can have a great impact on the image, which makes it difficult to apply one approach to learning all instances of an object having different poses. To deal with this problem, we have examined a divide and conquer strategy that divides training samples into subcategories each of which becomes a target of training. The proposed technique improves detection performance by subjecting training samples to clustering focusing on the similarities of weak classifier responses and using advanced joint boosting to perform multi-class boosting on the generated subcategories. Evaluation experiments have shown that this technique can improve detection performance over 2-class boosting by 7% at a false positive rate of 0.7% when using the INRIA Person Dataset and by 13% at a false positive rate of 0.8% when using the UIUC Image Database for Car Detection.

Key words Object detection, Boosting, Joint Boosting, Divide and conquer strategy

1. はじめに

近年の物体検出は、画像局所特徴量と統計的学習手法の組み合わせにより実現され、統計的学習法による識別器には SVM や Boosting [1] などの利用が提案されている。特に、Boosting は特徴量をどのように捉えているかを解析し易いため、人、顔、車両等の物体検出に多く用いられている [2] [3]。検出対象となる物体のアピアランスは、照明、視点によって大きく異なり、例えば人や顔、車両などは向きや姿勢により、画像としては形状、テクスチャなど全く異なるものが得られる。このような様々な

変動を含む物体を検出する際、変化の大きい学習サンプルを一括に扱い識別器を構築するのは困難となる場合がある。そこで、本稿では学習サンプルの偏りをサブカテゴリと見なして分割し、それらに対して個別に問題を解く分割統治的アプローチに着目する。学習サンプルの分割は、問題を簡単にするだけでなく汎化性能の向上に寄与することが報告されている [6]。大町らは、弱識別器を構築する際に学習に使用するデータを逐次ランダムサンプリングすることで、汎化性能を向上させている。

我々は検出対象となる学習サンプルをサブカテゴリに分割し、分類されたサンプルに対して学習、識別器を構築することで分

割統治のアプローチを実現する．複数のカテゴリを持つ問題に対するマルチクラスの Boosting として，Joint Boosting が提案されている．Joint Boosting は，高精度な 2 クラス識別器である Gentle Boosting [4] をマルチクラスに拡張したものであり，一般物体認識の分野において統合的なマルチクラス識別器の学習法として用いられている [5]．この手法は，特徴量（弱識別関数）を各集合群やクラスで共有することにより統合的な学習を行うため，効率よくマルチクラス識別器を構築する．しかし，Joint Boosting はマルチクラスに対する学習であるためサブカテゴリを持つ 2 クラス分類には不要な境界を学習してしまうため，そのままでは適用できない．そこで，本稿では改良型 Joint Boosting を提案し，各サブカテゴリを独立させつつ，特徴を共有して学習を行う．さらに，分割統治アプローチではどのように学習サンプルを分割するかが重要である．そこで，Boost 学習で得られる弱識別器に基づく教師無しのクラスタリング手法を提案する．このようなサンプル分割により提案手法は，全てのサンプルに有効な識別器，サブカテゴリ集合に有効な識別器，各サブカテゴリに特化した識別器の逐次学習を実現する．これにより，多様なサブカテゴリを含む問題を高精度に解くことが可能となる．

本稿では，2 章にて従来法の 2 クラス問題に対する Boosting である Gentle Boosting，それをマルチクラス問題への共有的学習へと拡張した Joint Boosting について述べる．また，3 章にて分割統治的な学習アプローチのフレームワークを述べ，要素技術である，サブクラス問題に対して拡張した改良型 Joint Boosting，サンプルデータの弱識別器応答によるクラスタリングについて述べる．更に，4 章では評価実験を行い提案手法の有効性を示す．5 章は全体の結びである．

2. 従来法

従来法として，2 クラス問題に対する高精度な Boosting 手法である Gentle Boosting と，それをマルチクラス問題における共有学習に展開した Joint Boosting について述べる．

2.1 Gentle Boosting

Gentle Boosting は 2 クラス問題に対する AdaBoost [1] の発展系であり，Boosting による強識別器は以下となる．

$$H(v) = \sum_{m=1}^M h_m(v) \quad (1)$$

ここで， v は入力ベクトル， M は弱識別器 h_m の総数である．弱識別器 h_m は次式により計算される．

$$h_m(v) = a\delta(v^f > \theta) + b \quad (2)$$

v^f は入力における特徴 f の値， θ はしきい値， δ はデルタ関数を表す． a, b はパラメタであり， b は最終的な判別に寄与しない． a, b は最小二乗法により算出する．ここで， a, b のパラメタはそれぞれ以下である．

$$b = \frac{\sum_i w_i z_i \delta(v_i^f \leq \theta)}{\sum_i w_i \delta(v_i^f \leq \theta)} \quad (3)$$

$$a + b = \frac{\sum_i w_i z_i \delta(v_i^f > \theta)}{\sum_i w_i \delta(v_i^f > \theta)} \quad (4)$$

また， z は v が正例か負例かを示すラベルであり， $\{1, -1\}$ をとる．式について指数評価関数 J を最も低くする弱識別器 h を逐次選択する．

$$J = E \left[e^{-zH(v)} \right] \quad (5)$$

その際，各サンプル i の重みが $w_i = e^{-z_i H(v_i)}$ として更新される．

2.2 Joint Boosting

Joint Boosting は，マルチクラス識別のための Boosting 手法であり共通する特徴（弱識別器）を共有しながら学習を行う．ここで，Boosting 手法の原型は Gentle Boosting とし，強識別器は次式となる．

$$H(v, c) = \sum_{m=1}^M h_m(v, c) \quad (6)$$

このとき，弱識別器 h_m は以下となる．

$$h_m(v, c) = a\delta(v^f > \theta) + b \quad (7)$$

c はクラスラベルである．Joint Boosting は図 1 に示す様に弱識別器を共有する．図 1 は 3 クラスについてのマルチクラス識別器を表現しており， $G^{S(n)}(v) = \sum_{m=1}^{M_n} h_m^n(v)$ は対象とするクラス集合 $S(n)$ の識別に対して用いられる弱識別器の集合を示す． $G^{1,2,3}$ は検出対象 1~3 全てと背景を， $G^{1,3}$ は検出対象 1 と 3 全てと背景を分離するのに有効な弱識別器群である．この図における強識別器はそれぞれ以下となる．

$$\begin{aligned} H(v, 1) &= G^{123}(v) + G^{12}(v) + G^{13}(v) + G^1(v) \\ H(v, 2) &= G^{123}(v) + G^{12}(v) + G^{23}(v) + G^2(v) \\ H(v, 3) &= G^{123}(v) + G^{13}(v) + G^{23}(v) + G^3(v) \end{aligned} \quad (8)$$

学習は，あるクラス集合に対する弱識別器 $G^{S(n)}(v) = \sum_{m=1}^{M_n} h_m^n(v)$ を毎ラウンド選択することで進む．その際，最良の弱識別器を選択するために以下の評価関数 J_{wse} という重み付き二次誤差を用いる．

$$J_{wse} = \sum_{c=1}^C \sum_{i=1}^N w_i^c (z_i^c - h_m(v_i, c))^2 \quad (9)$$

C は全クラスの集合， c は各クラスラベルを表す．また， z^c は v がクラス c に含まれるかどうかを示すラベルであり， $\{1, -1\}$ をとる．つまりこの式は識別境界から各サンプルへのマージンを指数評価し，その平均値を算出するものである．この評価値を最小にするよう弱識別器を選択することで，汎化性能の高い識別器の構築が期待できる．また，弱識別器をマルチクラス識別用に拡張する．Boosting に基づく分割統治的戦略による高

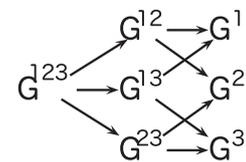


図 1 弱識別器の共有

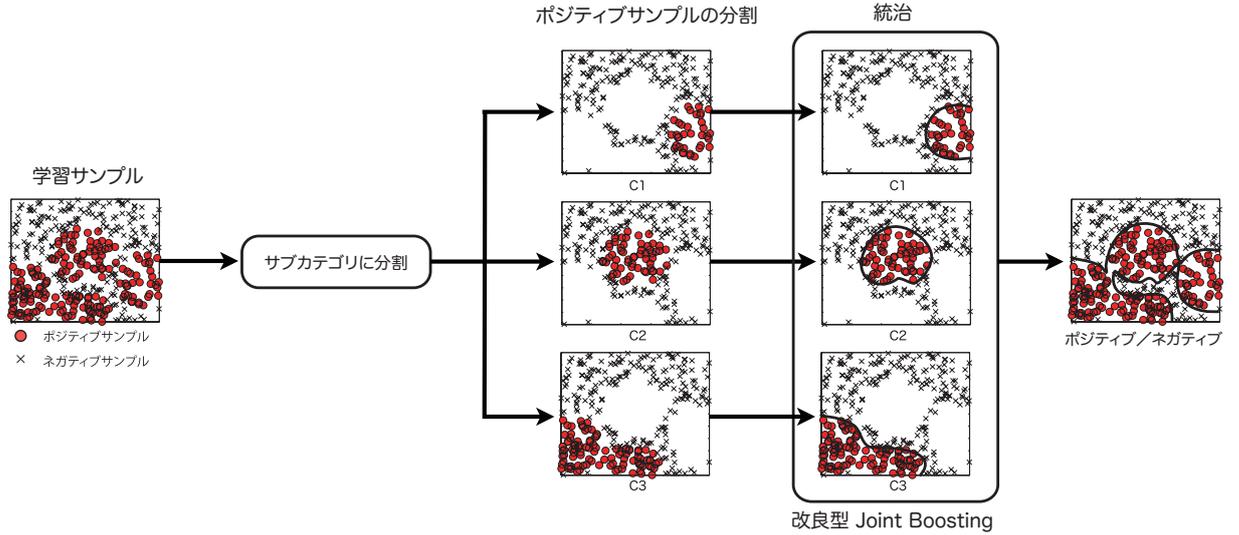


図 2 分割統治的戦略による高精度な識別器

精度な識別器構築手法の提案

$$h_m(v, c) = \begin{cases} a\delta(v^f > \theta) + b & \text{if } c \in S(n) \\ k^c & \text{if } c \notin S(n) \end{cases} \quad (10)$$

ここで, a, b, k^c のパラメータはそれぞれ以下となる.

$$b = \frac{\sum_{c \in S(n)} \sum_i w_i^c z_i^c \delta(v_i^f \leq \theta)}{\sum_{c \in S(n)} \sum_i w_i^c \delta(v_i^f \leq \theta)} \quad (11)$$

$$a + b = \frac{\sum_{c \in S(n)} \sum_i w_i^c z_i^c \delta(v_i^f > \theta)}{\sum_{c \in S(n)} \sum_i w_i^c \delta(v_i^f > \theta)} \quad (12)$$

$$k^c = \frac{\sum_i w_i^c z_i}{\sum_i w_i^c} \quad c \notin S(n) \quad (13)$$

弱識別器 h_m が対象としないクラスについて識別器は k_c を応答として返し, 識別関数は介在しない.

3. Boosting に基づく分割統治的戦略による高精度な識別器

提案手法では, 改良型 Joint Boosting 識別器を弱識別器応答のクラスタリングを交えて構築する. その手順は基本的に以下の 2 ステップに分かれる.

- サンプル分割
- 共有学習

提案手法では, まず最初に全てのデータに対して 2 クラス分類の独立学習を行う. これは, 通常の Gentle Boosting と同一の学習である. 次に, Gentle Boosting で選ばれた弱識別器の分離性能が低下し, これ以上の性能向上の見込みが低くなると, それまで得られた弱識別器の応答を用いてサンプルを分割する (図 2(a)). その後, 分割されたサンプルとそれらの集合をノードとして改良型 Joint Boosting による共有学習を行う (図 2(b)). この時点で得られている 2 クラス識別機は全体の識別に対してある程度の有効性を持つため, 全サンプルを対象とするノード (例, 図 1 中の G^{123}) として全サブカテゴリに利用し, 学習を継続する. この様な過程で, 全体を大まかに識別する識別器, 詳細な集合に対して識別を行う識別器をそれぞれ構

築していく. こうして得られた各サブカテゴリへの識別器を統合することで, 最終的な識別器が構築される.

3.1 改良型 Joint Boosting

サブカテゴリにクラスタリングされたデータに対し, 各サブカテゴリに対して識別器を構築する. ここで, 各サブカテゴリ間で共通して有効な特徴を共有して学習を行う. 手法としては, Joint Boosting をベースとしてサブカテゴリを含む 2 クラス問題向けに変更を加える.

3.1.1 Joint Boosting アルゴリズムの分割統治戦略への適用

Joint Boosting は各学習ラウンドにおいて全ての対象クラスの組み合わせを探索し, 最良の識別器を取得することにより, 全クラスで合計した特徴数 (弱識別器数) を削減することが可能である. しかし, 提案する分割統治戦略を採る場合それら共有学習には多くの無駄が存在する. 我々は, 全サブカテゴリを対象としたものが通常の Gentle Boosting と同様であることに着目し, 段階的にサンプルを分割しながら学習を行うことで Joint Boosting と類似した識別器の構造を実現する.

サブカテゴリ問題へ適用させるため, 各サブカテゴリにおける弱識別器評価を考える. Joint Boosting では, 他のサブカテゴリを自己と捉えてもエラーと判定するため, サブカテゴリ問題にはあまり寄与しない識別関数を学習してしまう. そこで, 各サブカテゴリ毎に存在するサブカテゴリラベル $z = \{1, -1\}$ を, サブカテゴリに属するポジティブサンプル, 属しないポジティブサンプル, ネガティブサンプルとして $z^* = \{1, 0, -1\}$ に拡張する. 次に, エラー評価を各ノードについて独立に求める. ここでは, 他のノードに属するデータを自己と捉えてもエラーと判定せず, 同様にそれらを他クラスと捉えても正解と判定しない.

次に, 各ノードにおいて下記の評価関数を用いて弱識別器評価を行う.

$$J_{wsc} = \sum_{c=1}^C \sum_{i=1}^N z_i^c w_i^c (z_i^c - h_m(v_i, c))^2 \quad (14)$$

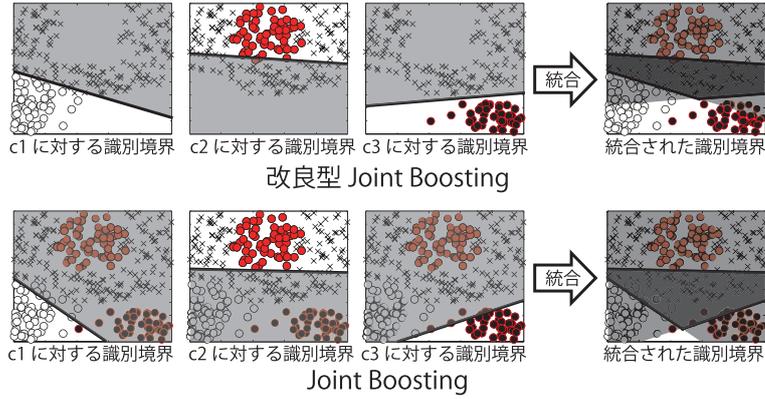


図 3 Joint Boosting と改良型 Joint Boosting による境界の差

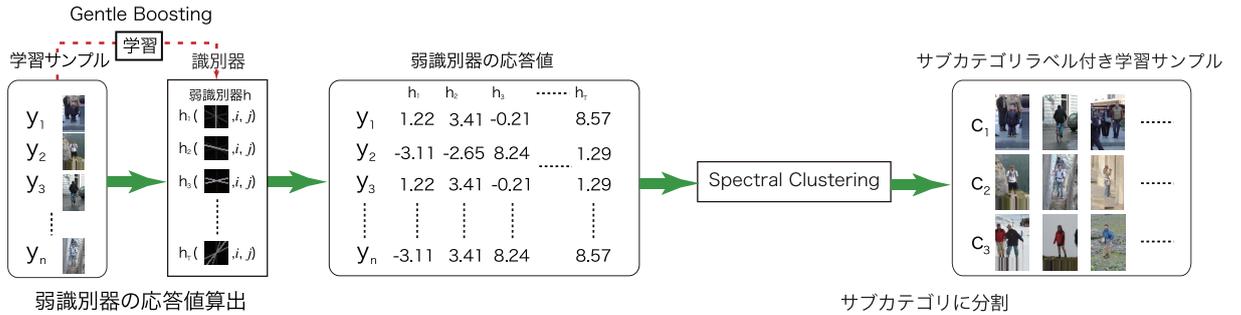


図 4 弱識別器応答値を用いた Spectral Clustering による学習サンプルのクラスタリング

上式より、対象ノード内に属しないデータは計算に関与しない。ここで、 a, b, k^c のパラメータはそれぞれ Joint Boosting と同様の形で以下の式で計算される。

$$b = \frac{\sum_{c \in S(n)} \sum_i w_i^c z_i^c \delta(v_i^f \leq \theta)}{\sum_{c \in S(n)} \sum_i z_i^2 w_i^c \delta(v_i^f \leq \theta)} \quad (15)$$

$$a + b = \frac{\sum_{c \in S(n)} \sum_i w_i^c z_i^c \delta(v_i^f > \theta)}{\sum_{c \in S(n)} \sum_i z_i^2 w_i^c \delta(v_i^f > \theta)} \quad (16)$$

$$k^c = \frac{\sum_i w_i^c z_i}{\sum_i z_i^2 w_i^c} \quad c \notin S(n) \quad (17)$$

これらの操作は、ポジティブサンプルを各サブカテゴリで独立して保持することと同義である。これにより、各サブカテゴリ間の分離に着目した学習が行われなくなる。

3.1.2 通常の Joint Boosting との相違点

通常の Joint Boosting では、あるノードについて識別器を評価する際に他のサブカテゴリを負例として用いる。このアルゴリズムにより引かれる境界は、各サブカテゴリ間を分離するよう重点的に学習される。しかし、サブカテゴリを含む 2 クラス問題において各サブカテゴリは本質的に同じ属性であるため、これらを分離する境界を学習するのは無駄となる。そこで、提案する改良型 Joint Boosting では、あるノードについて計算するときそのノードに含まれないサブカテゴリについて考慮しないことで無駄な境界を学習せず、効率よくサブカテゴリ群とネガティブサンプル間の境界を学習可能である。図 3 に示すように、サブクラス間での誤解を考慮しない事で改良型 Joint Boosting はより多くのポジティブ/ネガティブの分離が可能である。

3.2 弱識別器応答値を用いた Spectral Clustering による学習サンプルのクラスタリング

学習サンプルのクラスタリングには通常、データの持つ特徴量を用いた k-means クラスタリングなどが用いられている。しかし、特徴空間における分布が複雑である場合その空間における遠近は識別器においてどのように捉えられるかは不明である。村井らは、Boosting を用いた人領域のセグメンテーションにおいて、類似度の評価に Real AdaBoost による弱識別器の応答値を用いることで、識別器にマッチした類似度を算出している [7]。そこで、提案手法では図 4 に示すように、まず学習サンプルに対して Gentle Boosting で学習を行い、弱識別器群を得る。次に、弱識別器の応答値を属性としてサンプルのクラスタリングを行う。これにより、特徴空間での関係性だけでなく、学習を経た識別器の分類情報を用いることができ、より識別に適したクラスタリングとなることが期待できる。

3.2.1 Spectral Clustering

提案手法で用いる弱識別器の応答値は、サンプルが充分でない場合に $\sum_i w_i$ が極小化し、計算上極大化することがあるため、k-means によるクラスタリングではこれらのような応答値を扱う際に危険である。他にも、k-means に基づくクラスタリングは、以下の 2 つの前提を持つ。1 つは、各クラスタのデータ分布は超球形であること、2 つ目は、各クラスタの半径は同じ長さであるということである。これらの性質は実データにおいて問題となり得る。そこで、各サンプルの相関行列から次元圧縮を行い、圧縮された空間上でクラスタリングを行う Spectral Clustering [8] を用いてクラスタリングを行う。Spectral Clustering とはサンプル間の相関行列 (類似度行列)

を作成し、相関行列を固有値問題に帰結し解くことで次元圧縮効果を得る。まず、クラスタリング対象となるサンプルから相関行列を求める。相関行列 A は、

$$A_{ij} = distance(i, j) \quad (18)$$

で表わされる。 i と j はクラスタリング対象となるサンプルである。距離関数 $distance$ としては $L2$ ノルムや内積空間への写像などが用いられる。この相関行列を、固有値問題に帰結して解く。まず、求められた A を用いて、 $L = D^{-1/2}AD^{-1/2}$ を求める。ここで、 D は $D_{ii} = \sum_{j=1}^N A_{ij}$ で求められる対角行列である。

次に、 $E = [e_1, \dots, e_K]$ を計算する。 e_k は L の最大固有ベクトルを K 個のシードとする。そして、 k -means クラスタリングで E を基にクラスタリングを行う。提案手法では、任意のクラスタ数に分割する際はここで k -means クラスタリングを、ノンパラメトリックに分割する際はクラスタ数を設定しなくてよい medoid-shift クラスタリング [9] を用いてクラスタリングする。

4. 実験

提案手法の有効性を示すための実験として、以下の2種類を行う。1つは、Gentle Boosting との識別性能の比較である。この実験を通じて、提案手法による分割統治的アプローチが問題の識別に有益であることを示す。2つ目は、サンプル分割を行う際の分割手法についての比較である。本実験を通じて、弱識別器の応答値を用いてクラスタリングを行うことが提案する分割統治的識別のために有効であることを示す。

4.1 Dataset

実験に使用する各データセットについて説明する。

a) INRIA Person Dataset [10]

人検出問題として、INRIA から提供されているデータベースを用いる。学習用画像 2,416 枚と学習用背景画像 1,218 枚、評価用画像 1,135 枚と評価用背景画像 453 枚が用意されている。

b) UIUC Image Database for Car Detection [11]

車両検出問題として、UIUC の車両データベースを用いる。道路画像より切り出された車両画像 550 枚と同じく切り出された背景画像 550 枚を学習用に、評価用には道路画像 170 枚を持つデータセットである。

4.2 特徴量

本稿では、特徴量として Histograms of Oriented Gradients (HOG) [12] を用いる。HOG 特徴量は、局所領域における輝度の勾配方向をヒストグラム化した特徴量であり、ある一定領域に対する特徴量の記述を行う。そのため、大まかな物体形状を表現することが可能であり、人検出や車検出等の物体検出に有効であることが報告されている [2] [3]。

4.3 評価基準

横軸に誤検出率、縦軸に検出率を表したグラフによって評価を行う。識別器のしきい値を変化させることによって、汎化性能を考慮した誤検出率に対する識別率の実用的な比較を行うこ

とが可能である。検出率と誤検出率は以下のように求める。

$$\text{検出率} = \frac{\text{検出した正解数}}{\text{検出対象数}} \quad (19)$$

$$\text{誤検出率} = \frac{\text{検出した不正解数}}{\text{非検出対象数}} \quad (20)$$

4.4 Gentle Boosting との比較実験

提案手法の有効性を示すため、2クラス分類器である Gentle Boosting、マルチクラス分類器である Joint Boosting との比較を行う。ただし、取り扱う問題は2クラス識別としてサブカテゴリ相互の誤りは誤検出としない。

4.4.1 INRIA Person Dataset

図5に、INRIA Person Dataset における比較結果を示す。全体に、提案手法が Gentle Boosting を上回っており、その差は最大で3%以上の向上を見せた。提案手法によるサンプルの分割が有効に働いたことがわかる。また、Joint Boosting では2クラス問題に対して対応できないことがわかる。

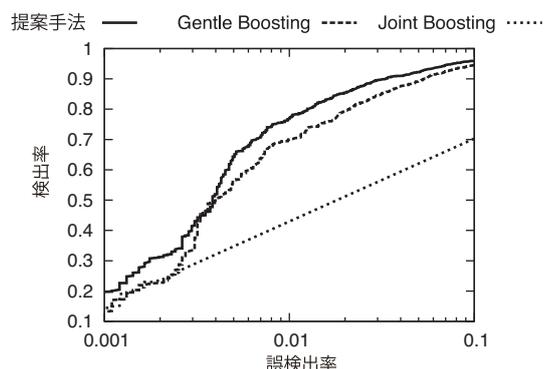


図5 INRIA Person Dataset での性能比較

4.4.2 UIUC Image Database for Car Detection

図6に、UIUC Image Database for Car Detection での車両検出における比較結果を示す。全体に、提案手法が Gentle Boosting を上回っており、その差は最大で10%以上の向上を見せた。これは、INRIA Person Dataset における結果よりも著しい上昇である。車両のように方向などによって大きくエッジの構成が異なる対象に対して、提案手法によるサンプルの分割が有効に働いたと考えられる。また、本実験においても Joint Boosting では2クラス問題に対してパフォーマンスは低い。

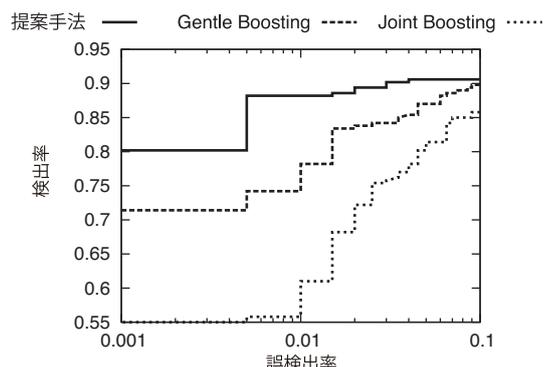


図6 UIUC Image Database for Car Detection での性能比較

4.5 サブカテゴリ生成手法についての比較

提案手法は改良型 Joint Boosting による実験の際、弱識別器の応答を用いることでより識別に有効な分離を実現する。それを確認するため、人手による3クラス(正面/背面, 左, 右)へのラベリング, 弱識別器で選択された特徴量によるクラスタリング, ランダムなラベリングとそれぞれ比較する。本実験では, INRIA Person Dataset を用いる。

4.5.1 比較のためのサブカテゴリ生成手法

各比較手法の詳細についてを以下に示す。

a) 人手によるラベリング

サンプルを分割する際の比較手法として, 人手によるラベリングを行う。人手によるラベリングは, 人の知識により分類されたサブカテゴリが得られるため, 有効なサブカテゴリ分類法である。しかし, 特に多量のサンプルに対しては時間やコストの面に問題があるため, 提案手法のような自動的な分類により同程度以上の成果が得られることが望ましい。

本実験では, INRIA Person Dataset 内の人画像に対して(正面/背面, 左, 右)へのラベリングを行った。

b) ランダムラベリング

サンプルに対するラベル付けをランダムで行う。クラス数のみ手動による方向別ラベリングと同じ3として指定した。

c) 特徴量によるクラスタリング

一般に, 画像データの自動クラスタリングは画像より得られた特徴量を用いて行う。そこで, 提案手法では選択された特徴量を用いるサンプル分離を, HOG 特徴量全ベクトルを用いてクラスタリングすることで行う。

4.5.2 比較結果

INRIA Person Dataset を用いて, Equal-Precision-Recall Rate (EPR: 再現率と適合率を等しく設定)時の検出率について比較を行った結果を表4.5.2に示す。表4.5.2より, 提案手法が最も検出性能が高いことがわかる。また, 手動でラベリングしたものと特徴量によるクラスタリングはそれぞれ同程度であった。これは, 方向別などの人間の知識によるラベリングや単純な特徴量によるラベリングは必ずしも識別器に対して最適でないことを示している。

表1 サンプル分割手法の比較
(Detection equal-precision-recall rate)

サンプル分割手法	検出率 (%)
(a) 人手によるラベル	81.6
(b) ランダムラベリング	81.1
(c) 特徴量によるラベリング	81.5
提案手法	85.5

5. おわりに

人や顔, 車両などの向き, 姿勢により様々な変動を含む物体を検出するため, サンプルデータ群の偏りをサブカテゴリと見なして分割し, それらに対して個別に問題を解き, その結果を統合する分割統治アプローチによる識別器の構築法を提案した。

本論文の貢献は以下の2点である。1つは偏りを持つサン

プルを分割する教師無し的手法として弱識別器の応答によるクラスタリングと, 2つ目は改良型 Joint Boosting により2クラス識別問題に対して分割統治を実現した点である。人, 車両検出問題における評価実験の結果, 学習サンプルを分割しない従来の Gentle Boosting に比べ INRIA Person Dataset を用いた実験では約7% (誤識別率0.7%時), UIUC Image Database for Car Detection において約13% (誤識別率0.8%時)性能を向上させることができ, 提案手法の有効性を確認した。また, サンプル分割手法についても通常得られる特徴量や手動によるラベリングに比べ, 弱識別器の応答を用いる提案手法は3%以上高精度であった。

今後は, より効率的な学習への展開と, ブートストラップなどを組み合わせた総合的な識別フレームワークへの展開についての検討を行う予定である。

文 献

- [1] R. E. Schapire and Y. Singer, "Improved Boosting Algorithms Using Confidence-rated Predictions", Machine Learning, No. 37, pp. 297-336, 1999.
- [2] 藤吉弘巨, "局所特徴量の関連性に着目した Joint 特徴による物体検出", 情報処理学会 研究報告 CVIM 166, pp.43-54, Mar. 2009.
- [3] 高木雅成, 山内悠嗣, 三井相和, 藤吉弘巨. "Geometric Context を用いた特徴量間の共起による物体検出の高精度化", 第12回画像の認識・理解シンポジウム (MIRU2009), pp. 643-650, 2009.
- [4] J. Friedman, T. Hastie, and R. Tibshirani. "Additive logistic regression: a statistical view of boosting." Annals of statistics, 28(2):pp. 337-374, 2000.
- [5] A. Torralba, K. P. Murphy and W. T. Freeman "Sharing features: efficient boosting procedures for multiclass object detection." Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR). pp 762-769, 2004.
- [6] 堀内 真, 大町 真一郎, 阿曾 弘具, "AdaBoost アルゴリズムを用いた識別手法の統合", 電子情報通信学会論文誌, D, Vol. J91-D, No.4, pp.1168-1171, 2008.
- [7] 村井陽介, 藤吉弘巨, 伊藤誠也, 数井誠人. "弱識別器の応答に基づく類似シルエット画像選択による Chamfer Matching を用いた人領域のセグメンテーション", 第12回画像の認識・理解シンポジウム (MIRU2009), pp.1468-1475, 2009.
- [8] Andrew Y. Ng, Michael I. Jordan, Yair Weiss. "On Spectral Clustering: Analysis and an algorithm", NIPS, 2004.
- [9] Yaser Sheikh, Erum Khan, and Takeo Kanade. "Mode-seeking by Medoidshifts", ICCV, 2007.
- [10] INRIA, <http://ralyx.inria.fr/2006/index.html>
- [11] UIUC Image Database for Car Detection: <http://l2r.cs.uiuc.edu/cogcomp/Data/Car/>
- [12] N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection", IEEE Computer Vision and Pattern Recognition, vol.1, pp.886-893, 2005.