

## Online Real Boostingによる物体追跡のための特徴選択

山下 隆義<sup>†</sup> 藤吉 弘亘<sup>††</sup>

<sup>†</sup> オムロン株式会社 〒 525-0035 滋賀県草津市西草津 2-2-1

<sup>††</sup> 中部大学 〒 487-8501 愛知県春日井市松本町 1200

E-mail: <sup>†</sup>takayosi@omm.ncl.omron.co.jp, <sup>††</sup>hf@cs.chubu.ac.jp

**あらまし** 近年、物体検出や物体追跡において、AdaBoost や Real AdaBoost などのブースティングが注目されており、オンライン学習へ応用されている。AdaBoost による Online Boosting は追跡対象に適した弱識別器を繰り返し処理により選択する。そのため、オンライン学習の処理コストが大きく、現時刻のサンプルへの過学習が生じやすい。一方、Real AdaBoost による Online Real Boosting は弱識別器をグループ分割し、各グループから最適な弱識別器を選択する。これにより、処理コストを削減することともに、過学習を抑制している。しかしながら、これまで、どのようにグループ分割を行い、特徴選択するのが良いか論じられていない。そこで、本稿では、複数の弱識別器のグループ分割方法を提案し、それによる追跡精度への影響について調査する。その結果、弱識別器を特徴の種類ごとにグループ分割した場合に、追跡精度が最も向上することが分かった。

**キーワード** Online Real Boosting, 物体追跡, 特徴選択, グループ分割, ランダム

## Feature Selection for Object Tracking based on Online Real Boosting

Takayoshi YAMASHITA<sup>†</sup> and Hironobu FUJIYOSHI<sup>††</sup>

<sup>†</sup> OMRON Corporation Nishikusatsu 2-2-1, Kusatsu-city, SHIGA, 525-0035 Japan

<sup>††</sup> Chubu University 1800, Matsumoto-cho, Kasugai-city, AICHI 487-8501, Japan

E-mail: <sup>†</sup>takayosi@omm.ncl.omron.co.jp, <sup>††</sup>hf@cs.chubu.ac.jp

**Abstract** Recently, Boosting algorithms like AdaBoost and Real AdaBoost are used in online learning. The weak classifiers for online boosting are selected in an iterative manner in Adaboost based Online Boosting. And due to this, the computing cost increases for online training and it might also over-fit to the current sample. On the other hand, Online Real Boosting based on Real Adaboost groups the weak classifier, and selects an optimal weak classifier from each group. Besides reducing the computational cost, it prevents overfitting. The grouping process for feature selection is yet to be discussed. In this paper, we discuss the various grouping process and its effect on the tracking performance. As a result, it is observed that feature type based grouping of the weak classifiers results in the best performance.

**Key words** Online Real Boosting, object tracking, feature selection, grouping, random

### 1. まえがき

近年、物体検出や物体追跡において、統計的な機械学習手法である AdaBoost や Real AdaBoost などのブースティング手法 [2] が注目を集めている。ブースティングは、多数の識別器により識別するアンサンブル学習手法の一つであり、オフライン学習時に検出対象および非検出対象の画像をサンプルとして与え、あらかじめ用意した局所特徴量から識別に適したものを弱識別器として選択する。ひとつひとつの弱識別器は識別能力が低いですが、多数の弱識別器を重み付き線形結合することで汎化性の高い識別結果を得ることができる。物体追跡の場合は、オ

フラインで選択された弱識別器の重みを更新する方法 [3] や特徴選択を行う方法 [7] [9] [11] などにより、追跡対象に最適な識別器をオンラインで再学習している。オンライン学習は、追跡対象に最適な識別器を各時刻で学習できる一方、追跡対象の形状への過適合や、隠れが生じた場合の遮蔽物への過適合が発生しやすい。過適合により誤追跡が生じるため、追跡対象の変化に対して、汎化性の高い弱識別器をオンラインで選択することが望まれている。また、オンラインでブースティングの繰り返し処理を行い、特徴を選択するため、学習コストがかかる。そのため、オンライン学習のコストを削減することも重要となっている。

山下らはオフライン学習に Real AdaBoost を用い、学習した追跡対象および非追跡対象の確率密度関数をオンライン学習に導入する Online Real Boosting を提案している [12]. 確率密度関数を導入することで、遮蔽状態時に遮蔽物への過適合を抑制することができ、追跡対象以外への乗り移りを防いでいる。また、オフラインで選択された弱識別器をグループに分割し、限られた弱識別器の中から選択することで、計算コストを削減している。グループ分割を導入することは、計算コストの削減だけでなく、過適合を抑制し、汎化性を向上させることにも貢献している。過適合を抑制するためには、どのようにグループ分割するかが重要となる。この手法では、ランダム選択によるグループ分割を行っているか、その効果やどのようにランダム選択を行えば良いかは、十分に述べられていない。

そこで、本稿では、オンライン学習を利用した物体追跡において、汎化性能の向上と計算コストの削減にむけて、Online Real Boosting に適したグループ分割による特徴選択方法を提案する。そのために、まず、従来の Online Real Boosting のグループ分割の効果を検証する。グループ分割の有無による処理速度を比較し、グループ分割の有効性を確認する。そして、複数のグループ分割方法を提案し、その具体的な方法と性能について比較実験を行い、有効な分割方法を示す。

## 2. ブースティングによるオンライン学習

### 2.1 Online Boosting

Oza らにより提案された Online Boosting は、あらかじめ学習した弱識別器に重みをオンラインで更新する [3]. これにより、現時刻での検出対象に適した弱識別器には大きな重みを付与することができ、検出に適さない弱識別器の重みは小さくすることができる。一方、Grabner らは、検出対象に適した弱識別器をオンラインで選択する方法を提案している [7]. あらかじめ用意した弱識別器セット  $H_{strong} = \{h_1, h_2, \dots, h_M\}$  から、AdaBoost により識別エラー  $e_n$  が最も小さくなる弱識別器  $m = \arg \min_n e_n$  を  $n$  番目のセレクトアとして選択する。そして、特徴選択を  $N$  回繰り返して行い、式 (1) のような  $N$  個の弱識別器を線形結合した新たな強識別器を学習する。

$$H(x) = \sum_{n=1}^N \alpha_n h_n(x) \quad (1)$$

ここで、 $\alpha_n$  は弱識別器の重みであり、弱識別器の識別エラーが低いほど大きな値、識別エラーが高いほど小さな値となる。この値は、AdaBoost の学習プロセスにおいて決められる。

### 2.2 Online Real Boosting

山下らはオフライン学習に Real AdaBoost を用い、学習した追跡対象および非追跡対象の確率密度関数をオンライン学習に導入する Online Real Boosting を提案している [12]. Online Real Boosting の処理手順を図 1 に示す。Online Real Boosting は、オンライン学習のための準備、弱識別器の選択、弱識別器の更新の 3 つのステップからなる。ここでは、各処理について詳しく述べる。

#### 0. オフラインで強識別器を学習

強識別器  $H_{offline}(x)$  (弱識別器  $M$  個)

弱識別器  $h_{offline,m}(x)$  ( $m = 1, \dots, M$ )

#### 1. 新しいサンプルデータ $(x_1, y_1), \dots, (x_L, y_L)$ ,

$y_i = \pm 1$ ,  $L$  はサンプル数

#### 2. 弱識別器 $M$ 個をセレクトア数と同じ $N$ 個に分割

#### 3. セレクトアの評価値 $\lambda_n$ の初期化 $\lambda_n = 1/N$

弱識別器の識別エラー  $\epsilon$  の初期化  $\epsilon = 0$

#### 4. For $n=1, 2, \dots, N$ //セレクトア数

##### 4.1. For $m=1, 2, \dots, M/N$ //弱識別器数

##### 4.1.1. 弱識別器の識別関数を更新

If  $h_{n,m}(x) \in bin_j$

$$W_{n,m,j}^y = W_{n,m,j}^y + \lambda_n \quad (2)$$

##### 4.1.2. 弱識別器を更新

If  $h_{n,m}(x) \in bin_j$

$$h_{n,m}(x) = \frac{1}{2} \ln \frac{G(W_{n,m,j}^+) + \beta}{G(W_{n,m,j}^-) + \beta} \quad (3)$$

$G$  はガウシアン平滑化による正規化関数

##### 4.1.3. 弱識別器選択のための評価関数

$$Z_{n,m} = 2 \sum_{j=1}^T \sqrt{W_{n,m,j}^+ W_{n,m,j}^-} \quad (4)$$

$T$  はヒストグラムの要素数

#### 4.2. 最も $Z$ が小さい弱識別器を選択

$$m^* = \arg \min_m Z_{n,m} \quad (5)$$

$$h_n = h_{n,m^*}$$

#### 4.3. 弱識別器 $h_m(x)$ の識別エラー $\epsilon_n$ を算出

If  $y \cdot h_n(x) \geq 0$

$$\epsilon_n^{+1} = \epsilon_n^{+1} + \lambda_n \cdot |h_n| \quad (6)$$

Else

$$\epsilon_n^{-1} = \epsilon_n^{-1} + \lambda_n \cdot |h_n| \quad (7)$$

$$\epsilon_n = \frac{\epsilon_n^{+1}}{\epsilon_n^{+1} + \epsilon_n^{-1}} \quad (8)$$

#### 4.4. 弱識別器の重みを設定

$$\alpha_n = \frac{1}{2} \log \frac{1 - \epsilon_n}{\epsilon_n} \quad (9)$$

#### 4.5 セレクトアの評価値を更新

If  $y \cdot h_n(x) \geq 0$

$$\lambda_n = \frac{\lambda_n}{2(1 - \epsilon_n)} \quad (10)$$

Else

$$\lambda_n = \frac{\lambda_n}{2\epsilon_n} \quad (11)$$

#### 5. 強識別器

$$H(x) = \text{sign}(\text{conf}(x)) \quad (12)$$

$$\text{conf}(x) = \sum_{n=1}^n \alpha_n h_n(x) \quad (13)$$

図 1 Online Real Boosting の処理手順

Fig.1 Process of Online Real Boosting.

### 2.2.1 オンライン学習のための準備

あらかじめ、顔検出や人体検出などと同様に対象物体の強識別器  $H_{offline}(x)$  をオフライン学習する。そして、弱識別器をセクタ数と同じ  $N$  個のグループに分割し、各グループから弱識別器を選択する。学習サンプルは追跡対象の領域を正解サンプル、その周囲の背景を非正解サンプルとし、合計  $L$  個のサンプルを用いる。非正解サンプルの背景領域は追跡対象の一部を含むような領域を設定することで、追跡位置のずれを軽減することができる。図1の2において、各セクタの識別能力を示す評価値  $\lambda_n$  を初期化する。

### 2.2.2 弱識別器の選択

図1の4においてセクタごとに最適な弱識別器を1つ選択する。図1の4.1.1では、各弱識別器の確率分布  $W_{n,m}^y(j)$  にセクタの評価値  $\lambda_n$  を重みとして加算して更新する。確率分布  $W_{n,m}^y(j)$  はオフライン学習時に得られた追跡対象および背景画像の確率分布であり、正解サンプルは  $W_{n,m}^{+1}(j)$ 、非正解サンプルは  $W_{n,m}^{-1}(j)$  を更新する。確率分布  $W_{n,m}^y(j)$  はヒストグラムで実現されており、ヒストグラムの要素位置  $bin_j$  は特徴量の値から算出する。全サンプルデータによる確率分布の更新後、各弱識別器を更新する。弱識別器は確率分布  $W_{n,m}^y(j)$  と同様にヒストグラムで実現されている。サンプルデータにより更新される確率分布の要素が1つであると、要素間での確率分布の変動が大きくなる。そのため、1つのサンプルデータが属する要素は、その前後の要素位置の確率分布を用いて弱識別器を更新するガウシアン平滑化関数を用いる。ここで、 $\beta$  は0による除算を防ぐための係数である。

弱識別器の選択は図1の4.1.3でバチャタリア係数に基づく評価関数を用い、4.2で弱識別器候補から  $Z_{n,m}$  が最小となる弱識別器をセクタとして選択する。

### 2.2.3 弱識別器の更新

選択した弱識別器の識別能力を評価するために、図1の4.3でオンライン学習に用いたサンプルデータにより、エラー率を算出する。正しく識別できた場合、 $y \cdot h_n(x)$  は正の値となり、正解累積値  $\epsilon_n^{+1}$  に加算する。また、負の場合は、誤識別として非正解累積値  $\epsilon_n^{-1}$  に加算する。これらより得られた識別エラー  $\epsilon_n$  により、弱識別器の有効性を示すための値として  $\alpha_n$  を求める。Real AdaBoost は各弱識別器が識別の信頼度を出力するが、本提案手法では、セクタで選択される弱識別器の有効性を示す  $\alpha_n$  を別に算出している。

セクタの評価値  $\lambda_n$  は図1の4.5で識別エラー  $\epsilon_n$  の値をもとに更新する。評価値  $\lambda_n$  はセクタ  $n$  の識別能力を示す値である。  $\lambda_n$  が大きい場合、セクタ  $n$  は追跡対象に対して有効な弱識別器を選択しているといえる。一方、  $\lambda_n$  が小さい場合、有効でない弱識別器が選ばれていると考えることができる。本提案手法では、Grabner らと同様に最も  $\lambda_n$  の値が小さいセクタの弱識別器を更新している。

## 2.3 Online Real Boosting による追跡

Online Real Boosting で学習する特徴量は、輝度に着目した Haar-like 特徴量 [4] と Haar-like 特徴量の絶対値から求める abs Haar-like 特徴量、エッジに着目した Edgelet 特徴量 [6]、

表1 処理コストの内訳

Table 1 Detail of processing time.

| 弱識別器数 | Online Real Boosting |      | Online Boosting |      |
|-------|----------------------|------|-----------------|------|
|       | 学習処理                 | 追跡処理 | 学習処理            | 追跡処理 |
| 40    | 9.2ms                | 11ms | 103ms           | 16ms |
| 60    | 9.3ms                | 10ms | 129ms           | 17ms |
| 80    | 9.1ms                | 12ms | 178ms           | 20ms |
| 100   | 9.7ms                | 16ms | 220ms           | 20ms |

EOH 特徴量 [5] を用いる。Haar-like 特徴量は追跡対象の見えを捉えることができ、EOH は輪郭を捉えることができる。また、照明変化が生じる際には EOH 特徴量、形状変化が生じる際は Haar-like 特徴量が選択されることが期待される。

Online Real Boosting によりオンライン学習された強識別器を用いて、パーティクルフィルタ [1] により追跡を行う。パーティクルフィルタのサンプリング点に対して、強識別器をもとに尤度を計算する。また、状態ベクトルは、追跡位置  $(x, y)$  およびスケール  $s$ 、システムモデルはランダムウォークとする。各サンプリング点は、前フレームでの中心座標を中心に追跡物体の幅の2倍、大きさは  $\pm 0.1$  倍の範囲に対して二次元正規分布に従ってランダムに散布する。サンプリング点の重みは、強識別器の尤度をもとに更新する。

## 2.4 Online Real Boosting の計算コスト

オンライン学習手法は、オンラインでの識別器の学習と追跡処理の2つの処理から構成される。Online Boosting および Online Real Boosting の各処理における計算コストを表1に示す。オフラインで学習した300個の弱識別器数を候補として、その中からオンラインで選択した弱識別器数ごとの処理時間を示している。Online Boosting は、オフラインで学習した弱識別器候補の中から最適な弱識別器の選択を繰り返し処理で行うため、弱識別器数が増えると処理速度が増加する。一方、Online Real Boosting は、弱識別器候補をオンラインで選択する数にランダムにグループに分割して、その中から選択する。各グループから選択される弱識別器数は1個である。オンラインでの弱識別器数が増えた場合、分割されたグループに含まれる弱識別器数が減るため、全体として学習処理の時間に変動はない。追跡処理は、弱識別器数が増えると Online Boosting および Online Real Boosting とともに微小に増加する。また、Online Boosting は、学習処理の時間が追跡処理にかかる時間に比べると大きな割合を占めている。一方、Online Real Boosting は、学習処理と追跡処理は大きな差はなく、学習処理の時間がわずかに少なくなっている。これより、オンライン学習において、学習時間を短縮するためには、弱識別器を選択する繰り返し処理を削減することが、重要であり、Online Real Boosting は、効率的なオンライン学習ができていると言える。

## 3. グループ分割の方法

Online Real Boosting は、オフラインで学習した弱識別器候補をグループに分割することで、処理コストを大幅に低減させている。追跡性能を向上させるためには、弱識別器候補をどの

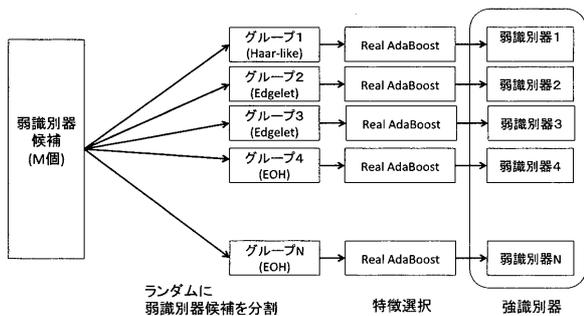


図2 ランダムなグループ分割による Online Real Boosting のフレームワーク

Fig.2 Framework of Online Real Boosting with random group division.

ように分割するかが重要である。そこで、我々は、Online Real Boosting に適したグループ分割方法を提案して比較する。グループの分割方法として、以下のような方法がある。

- 分割なし (Online Boosting)
- ランダムに分割 (Online Real Boosting)
- 領域ごとに分割 (提案手法 1)
- 特徴量の種類ごとに分割 (提案手法 2)

従来の Online Real Boosting のようなランダムに分割する従来の Online Boosting は、弱識別器をランダムに分割して、Real AdaBoost により特徴選択している。そこで、従来手法を含む以下の3つの分割方法について比較する。

### 3.1 ランダムなグループ分割による特徴選択

Online Real Boosting は、図2のようにランダムにグループ分割した後、その中から最適な特徴を選択している。単純にランダムに選択しているのではなく、特徴選択の処理を行っているため、追跡に有効な特徴が選択されている。これは、近年注目されている Randomized Trees [8] の処理に類似している。Randomized Trees は、学習サンプルをランダムなサブセットに分割したり、ランダムな特徴候補から有効な特徴を選択している。このような、ランダム選択が過適合を抑制して汎化性能を向上させることが知られている。また、複数の弱識別器から構成される点も、決定木をアンサンブルにして識別する点と類似している。このような点から、ランダムなグループ分割を導入した特徴選択は、汎化性能が高くなることが考えられる。

### 3.2 領域ごとの分割による特徴選択 (提案手法 1)

ランダムに分割した場合、追跡に有効な弱識別器が特定のグループに集中することや追跡に適さない特徴が特定のグループに集中することなど、追跡性能に影響を及ぼすような分割になることが考えられる。そこで、特徴が含まれる領域ごとにグループを作成し、その中から最適な特徴を選択する方法を提案する。領域毎の分割による特徴選択方法を図3に示す。オフラインで選択された弱識別器候補  $M$  個を一定領域ごとに分割する。そして、各グループは、特徴選択する領域をランダムに決め、その領域に含まれる特徴の中からさらにランダムに候補を選択することで作成する。このように領域を考慮して分割したグループから Real AdaBoost により特徴選択を行う。

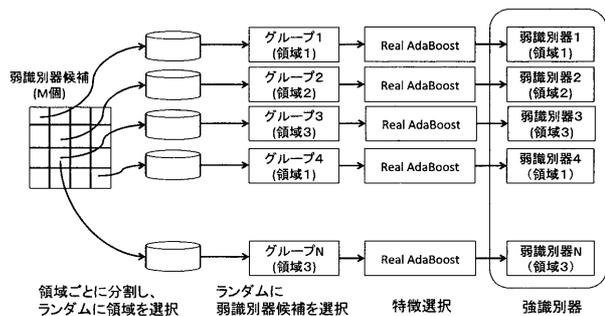


図3 領域ごとのグループ分割による Online Real Boosting のフレームワーク

Fig.3 Framework of Online Real Boosting with region based group division.

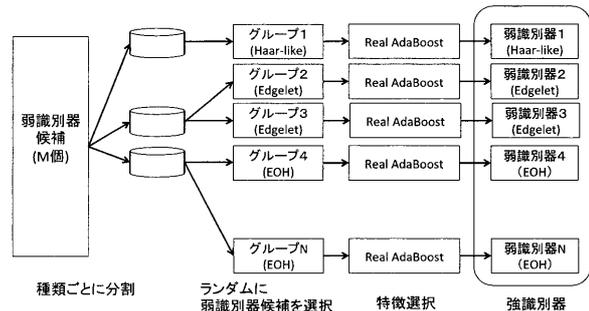


図4 特徴量種類ごとのグループ分割による Online Real Boosting のフレームワーク

Fig.4 Framework of Online Real Boosting with feature type based group division.

### 3.3 特徴量種類ごとの分割による特徴選択 (提案手法 2)

本稿では、Haar-like 特徴量、abs Haar-like 特徴量、Edgelet 特徴量、EOH 特徴量の4つの特徴量の種類を用いる。これらの特徴量の中で、追跡対象の形状や姿勢変化に応じて、追跡対象に適した特徴量の種類が異なることが考えられる。追跡対象の変化に追従するためには、追跡に有効な複数の種類の特徴量が特定のグループに集中するのではなく、グループ間に分散している方がよい。そのためには、特徴量の種類ごとに分割することがよいと考えられる。そこで、図4に示すように、オフラインで選択された弱識別器候補を特徴量の種類ごとに分割し、ランダムに各グループに分割する。そして、各グループから Real AdaBoost により特徴選択を行う。

## 4. 評価実験

特徴量の分割方法による性能について、従来手法と提案手法の比較実験を行う。比較実験には、Ross らの評価データ [10] を用いる。評価データは 320x240 ピクセル、30fps で撮影された約 800 フレームの映像で、被写体が室内の暗いところから明るいところへ歩くようなシーンである。また、被写体は顔の向きや表情、メガネの脱着などの見えの変化を伴っている。比較手法は、分割処理を行わない Online Boosting、ランダムに分割する Online Real Boosting、領域ごとに分割する提案手法 1、特徴の種類ごとに分割する提案手法 2 の4つである。各フレー

表 2 分割方法による追跡誤差 [pixel]

Table 2 Tracking error comparison.

| 分割方法                          | 弱識別器数 |       |       |       |
|-------------------------------|-------|-------|-------|-------|
|                               | 40    | 60    | 80    | 100   |
| 分割なし (Online Boosting)        | 18.86 | 48.27 | 34.08 | 52.56 |
| ランダム分割 (Online Real Boosting) | 13.15 | 24.25 | 24.60 | 24.93 |
| 領域ごと分割 (提案手法 1)               | 18.86 | 48.27 | 34.08 | 52.56 |
| 特徴の種類ごと分割 (提案手法 2)            | 11.13 | 19.36 | 18.00 | 24.81 |

ムに対して、被写体の頭部を覆うような領域を Ground Truth として定義し、その領域と追跡矩形の中心座標の誤差を追跡精度として比較する。また、各手法に対して、オンラインで選択する弱識別器の数を 40 から 100 まで 20 個ずつ変えた場合の性能についても比較する。初期位置は、すべての手法で同じ位置とする。各手法で選択する弱識別器は、オフラインであらかじめ学習しておく。オフラインで学習された弱識別器は、すべての手法で共通であり、300 個学習する。学習サイズは、24x24 ピクセルである。

#### 4.1 追跡精度の比較

各手法について、弱識別器の数による追跡精度を表 2 に示す。分割を行わない Online Boosting は、弱識別器の数が増えると追跡精度が低下している。これは、学習サンプルに対する過学習が起こっているためであると考えられる。提案手法を含む分割を行う場合も弱識別器数を一定の個数以上増やすと追跡精度が低下する傾向がある。しかしながら、分割を行わない場合と比較して、全体的に誤差は小さくなっており、分割することで過学習が抑制されていると言える。手法により最適な弱識別器数が異なるが、Online Boosting, Online Real Boosting, 提案手法 2 は弱識別器数を 40 個とした場合、提案手法 1 は 60 個とした場合が最も性能が良い。

一方、分割方法について比較すると、特徴の種類ごとに分割する提案手法 2 が最も追跡誤差が小さくなっている。これより、弱識別器を分割する際に、ランダムに分割するのではなく、特徴の種類ごとに分割した中から選択する方が有効な特徴が選択できることがわかる。

#### 4.2 フレームごとの追跡精度

追跡誤差の詳細な比較を行うために、各フレームにおける誤差を調査する。各手法について、フレームごとの追跡誤差を図 5, 図 6, 図 7, 図 8 に示す。図 5 より、Online Boosting は弱識別器を 40 個とした場合、450 フレームあたりから追跡誤差が大きくなっている。一方、Online Real Boosting は、図 6 に示すように、弱識別器数を多くすると Online Boosting と同様に 450 フレームあたりから追跡誤差が大きくなっている。弱識別器数を 40 個とした場合は、追跡誤差が急激に大きくなることはなく一定の誤差範囲に収まっており、追跡が最後まで成功している。提案手法 1 は、弱識別器を 60 個または 80 個にすると 450 フレームあたりで追跡誤差は小さくなっているが、弱識別器数を少なくした場合や一定以上多くした場合、他の手法と同様に追跡誤差が大きくなっている。提案手法 2 は、他の手法に比べて弱識別器数による追跡誤差の変動は小さくなっている。

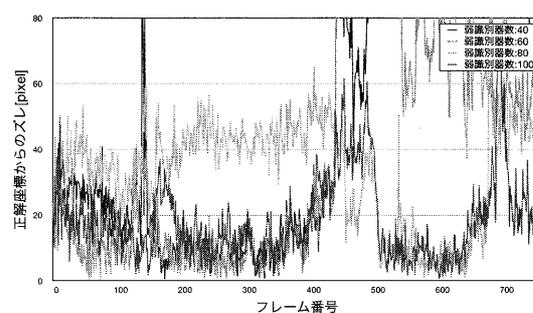


図 5 Online Boosting の追跡性能

Fig. 5 Performance of Online Boosting.

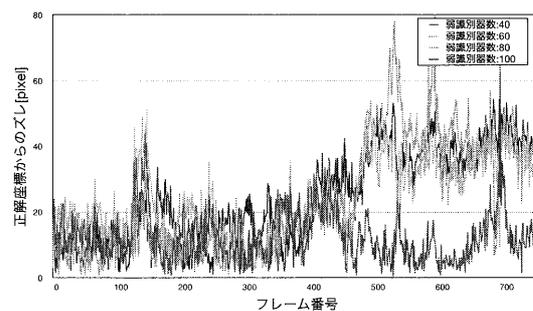


図 6 Online Real Boosting の追跡性能

Fig. 6 Performance of Online Real Boosting.

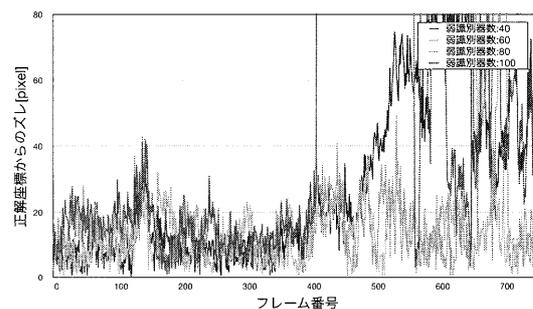


図 7 領域ごとのグループ分割による Online Real Boosting の追跡性能

Fig. 7 Performance of Online Real Boosting with region based group division.

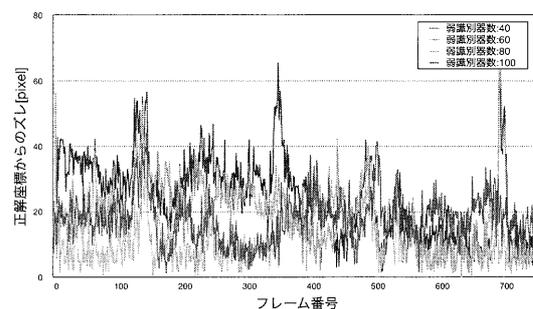


図 8 特徴量種類ごとのグループ分割による Online Real Boosting の追跡性能

Fig. 8 Performance of Online Real Boosting with feature type based group division.

また、他の手法の場合に追跡誤差が大きくなる 450 フレームあたりでも追跡誤差は小さく、安定して追跡ができています。

ここで、各手法の代表的なフレームにおける追跡結果を図 9



図9 各手法の追跡結果例. 左から 300 フレーム目, 400 フレーム目, 455 フレーム目, 500 フレーム目, 600 フレーム目, 695 フレーム目の目の結果.

Fig.9 Example images of tracking result.

に示す. 図9の1列目は300フレーム目, 2列目は400フレーム目の結果であり, 室内で暗い環境においては, 手法により追跡性能の大きな違いはない. 図9の3列目は455フレーム目の結果であり, 手法により結果が大きく異なっている. Online Boostingの追跡結果は, 追跡対象から下方向にずれている. そのため, 次の500フレーム目でも追跡結果が下方向にずれていることがわかる. 提案手法1は, 455フレーム目では追跡対象を見失い誤追跡しているため, その後の追跡が正しく行われていない. Online Real Boostingと提案手法2は, 455フレーム目で追跡対象を正しく捉えているため, その後の追跡においても追跡対象を正しく追跡することができる. また, 6列目の695フレーム付近では, Online Real Boostingおよび提案手法2ともに追跡対象を捉えることができているが, 提案手法2の方が追跡対象の正確に捉えることができている.

#### 4.3 選択された弱識別器の重み

Online BoostingおよびOnline Real Boostingは, 選択した弱識別器に対して重み $\alpha$ を算出している.  $\alpha$ は, 選択された弱識別器の識別能力を示す値であり, 大きいほど識別能力の高い弱識別器である. 各手法について, 選択された弱識別器の重みの分布を図10に示す. Online Boostingは, 学習サンプルの重みを逐次的に更新し, 識別能力の高い弱識別器を選択しているため, 選択された弱識別器の重みが全体的に高くなっており, 平均値が0.8である. 一方, グループ分割を導入した手法は, Online Boostingよりも識別能力の低い弱識別器が選択されて

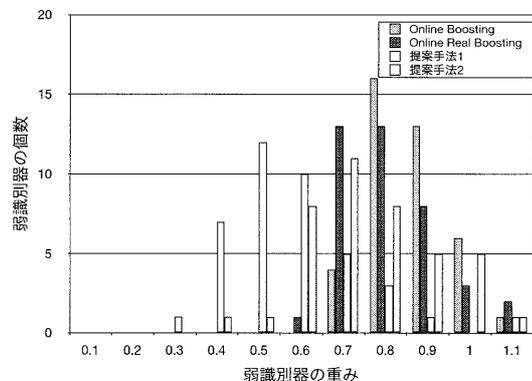


図10 選択された弱識別器の重みの分布.

Fig.10 Feature Count of weight of weak classifiers.

いる. 提案手法1は, 弱識別器の重みが全体的に低くなり, 平均値が0.51と最も小さい. Online Real Boostingは弱識別器の重みが高いものから低いものまで幅広く含まれており, 平均値が0.75となっている. 提案手法2も同様に, 弱識別器の重みの分布は幅広く, 平均値は0.71である. これより, 弱識別器を選択する際に, 現時刻のサンプルを識別するのに適した弱識別器を多数選択するよりも識別能力の高い弱識別器から低い弱識別器まで幅広く選択する方が過学習を防ぎ, 追跡精度を向上させることにつながっている. その際, 提案手法1のように, 領域ごとに分割して選択すると, 識別能力の低い弱識別器が必要以上に選択され, 追跡精度が低下する. 一方, 特徴の種類ご

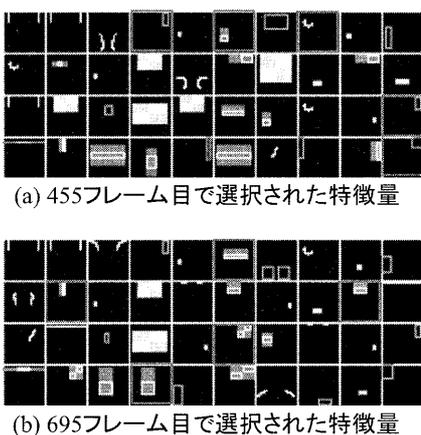


図 11 選択された弱識別器の特徴量形状.

Fig. 11 Selected feature type.

とに分割して選択すると、識別能力の低い弱識別器から高い識別器まで選択されるため、追跡精度が良い。このように、領域ごとに分割するよりも特徴の種類ごとに分割したほうが精度が高くなることが分かった。

#### 4.4 選択された弱識別器の特徴量

提案手法 2 において、455 フレーム目と 695 フレーム目で選択された弱識別器の形状を図 11 に示す。白と黒の矩形からなる形状が Haar-like 特徴量，白線の形状が Edgelet 特徴量，白線の矩形からなる形状が EOH 特徴量である。また，弱識別器の重みが大い上位 5 つの形状を赤線で囲っている。これより，455 フレーム目は横向きシーンであり，輪郭付近を捉える EOH 特徴量の重みが高くなっている。一方，695 フレーム目は，メガネの脱着を行うようなシーンであり，ここでは Haar-like 特徴量の重みが高くなっている。このように，追跡対象の状態に合わせて，最適な特徴の種類に対する重みが高くなっていることがわかる。

## 5. ま と め

本稿では，オンライン学習手法の一つである Online Real Boosting において，特徴選択の方法が追跡精度に与える影響について調査した。その結果，特徴選択時に弱識別器を特徴の種類ごとに分割して選択する方が逐次的に選択する場合やランダムに選択する場合と比べて，追跡精度が向上することがわかった。特徴ごとに分割することで，照明変化や顔向き変化が生じる際に，追跡に有効な特徴には大きな重み，追跡に適さない特徴には小さな重みが設定されている。これにより，検出器全体での重みが特定の状況に過学習することなく，次時刻での変化を許容可能な汎化性を保つことができている。

## 文 献

- [1] M. Isard and A. Blake, "Condensation - Conditional Density Propagation for Visual Tracking", *International Journal of Computer Vision*, Vol.29, No.1, pp.5-28, 1998.
- [2] R.E. Schapire, Y. Singer, "Improved Boosting Algorithms Using Confidence-rated Predictions", *Machine Learning*, No.37, pp.297-336, 1999.
- [3] N. Oza, S. Rusell, "Online bagging and boosting", In Proc.

- Artificial Intelligence and Statistics, pp.105-112,2001.
- [4] P. Viola, M. Jones, "Robust real-time face detection", *International Journal of Computer Vision*, Vol.57, No.2, pp.137-154, 2004.
- [5] K. Levi, Y. Weiss, "Learning Object Detection from a Small Number of Examples: The Importance of Good Features", In Proc. IEEE Conf. on Computer Vision and Pattern Recognition, pp.53-60, 2004.
- [6] B. Wu, R. Nevatia, "Detection of multiple, partially occluded humans in a single image by Bayesian combination of edgelet part detectors", In Proc. IEEE International Conference on Computer Vision, 2005.
- [7] H. Grabner, H. Bischof, "On-line Boosting and Vision", In Proc. IEEE Conf. on Computer Vision and Pattern Recognition, Vol.1, pp.260-267, 2006.
- [8] L. Breiman, "Random forests", *Machine Learning*, No.45, pp. 5-32, 2001.
- [9] X. Liu, T. Yu, "Gradient feature selection for online boosting", In Proc IEEE International Conference on Computer Vision, 2007.
- [10] D. Ross, J. Lim, R. -S., Lin, M. -H., Yang, "Incremental learning for visual tracking", *International Journal of Computer Vision*, Vol.77 Issue 1, 2008.
- [11] H. Grabner, C. Leistner, H. Bischof, "Semi-Supervised Online Boosting for Robust Tracking", In Proc. European Conf. of Computer Vision, pp.234-247, 2008.
- [12] 山下隆義, 勢世紅, 川出雅人, "Online Real Boosting による人物追跡", *情報処理学会論文誌 CVIM*, Vol.1, No.1, pp. 73-82, 2008.