

論文

非隣接型矩形特徴を用いた物体検出

日高章理^{†,††} 栗田多喜夫^{††,†}

Non-Neighboring Rectangular Features for Object Detection

Akinori HIDAKA^{†,††} and Takio KURITA^{††,†}

あらまし P. Violaらは高速かつ高精度な物体検出手法として、矩形特徴と Adaboost を用いた検出器を提案した。Adaboost 学習法では学習時間が矩形特徴の総数 C に依存する。そのため Violaらは矩形特徴の取り方に制約を加えることで C を減らし、それにより学習時間を抑えていた。本研究では、第一にランダム候補選択および粒子群最適化法を用いた効率的な学習アルゴリズムを提案する。これらにより従来手法の学習時間を $1/25 \sim 1/50$ 程度に削減することが可能になる。第二に、従来の矩形特徴の総数 C に対しておよそ $O(C^2)$ の総数を持つ非隣接型矩形特徴を提案する。提案特徴を粒子群最適化法で特徴選択することにより、従来よりも高精度な検出器をより短時間で構築することが可能になる。

Abstract Recently, Viola proposed a object detector based on rectangular features (RFs) and Adaboost [10]. The training time of Adaboost depends on C which is the number of RFs. Therefore, Viola limited C by restricting how to extract RFs and suppressed the training time. In this paper, at first we propose the fast training algorithm based on Random Candidate Selection (RCS) and Particle Swarm Optimization (PSO) that the training time does not depend on C . RCS and PSO are 25 to 50 times faster than Viola's training method. Next, we propose Non-Neighboring RF (NNRF) which is an extension of RF and has the variety of $O(C^2)$. We show PSO can select the powerful NNRFs and construct a highly accurate detector in a shorter training time than Viola's work.

キーワード 物体検出, Adaboost, 特徴選択, 粒子群最適化法

Keywords Object Detection, Rectangle Feature, Adaboost, Feature Selection, Particle Swarm Optimization

1. ま え が き

P. Viola と M. Jones が提案した物体検出法 [10] は高速かつ高精度な処理性能を併せ持つ手法として有名である。彼らの検出器は矩形特徴と呼ばれる局所画像特徴の集合で構成される (図 1)。矩形特徴は局所特徴であり、画像のどの部分から抽出するかに応じて多数 (数万~数十万) のバリエーションを持つ (例: 図 2 左)。効率的な検出を行うためには、矩形特徴の母集団の中から検出力が高いものを選び出す (特徴選択する) 必要がある。

彼らは Adaboost という学習法を利用して矩形特徴



図 1 従来の矩形特徴における小矩形の配置タイプ。



図 2 矩形特徴 (左) と非隣接型矩形特徴 (右) の例。

の特徴選択を行った。Adaboost は元々アンサンブル学習法として提案された手法で、複数の単純な識別器 (ベース識別器) を線形結合させ、一つのより強力な識別器 (強識別器) を構築するための学習法である。Viola と Jones は矩形特徴一つ一つをベース識別器として扱うことで Adaboost によって局所特徴選択を行う方法 (Adaboost.VJ と呼ぶ) を提案した。

Adaboost.VJ では単純に全探索法によって特徴選

[†] 筑波大学大学院 システム情報工学研究科
Department of Systems and Information Engineering, University of Tsukuba

^{††} 産業技術総合研究所 脳神経情報研究部門
Neuroscience Research Institute, National Institute of Advanced Industrial Science and Technology (AIST)

- N 組のサンプルとラベルのペア $\{I_i, y_i\}_{i=1}^N$ を用意
 - サンプルの重みを初期化:
if $y_i = 1$ then $w_i = \frac{1}{2p}$, otherwise $w_i = \frac{1}{2q}$
(p, q : 顔画像, 背景画像の枚数)
 - For $t = 1, \dots, T$
 - 重みを規格化: $w_{t,i} \leftarrow \frac{w_{t,i}}{\sum_{i=1}^N w_{t,i}}$
 - ベース識別器 $\{b_c\}_{c=1}^C$ を最適化:
 $\{b_t, e_t\} = \text{Opt}(\{b_c\}_{c=1}^C, \{I_i, w_i, y_i\}_{i=1}^N)$
 - $\alpha_t = \log((1 - e_t)/e_t)$
 - サンプル重みの更新:
 $w_i \leftarrow w_i \cdot \exp[\alpha_m \cdot \delta(y_i - b_t(I_i))]$
($\delta(x) = 1$ (if $x = 0$), 0 (otherwise))
 - 強識別器の識別関数
- $$H(I) = \begin{cases} 1 & \text{if } \sum_{t=1}^T \alpha_t b_t(I) \geq \Theta \\ 0 & \text{otherwise} \end{cases}$$

図 3 Adaboost の標準アルゴリズム. Θ は手動決定する閾値. 提案手法のための Opt 関数は図 4 と図 5.

- 引数 $\{b_c\}_{c=1}^C, \{I_i, w_i, y_i\}_{i=1}^N$ を受け取る
- K 個の矩形特徴 $\{b_k\}_{k=1}^K$ を $\{b_c\}_{c=1}^C$ からランダム選択
- For $k = 1, \dots, K$
 - 重み付サンプル $\{I_i, w_i, y_i\}_{i=1}^N$ で b_k を訓練
 - エラー $err_k = \frac{\sum_{i=1}^N w_i \cdot \delta(y_i - b_k(I_i))}{\sum_{i=1}^N w_i}$ を計算
- 最もエラー err^* の低い矩形特徴 b^* を選択
- $\{b^*, err^*\}$ を返す

図 4 Adaboost.RCS のための最適化関数.

択を行うため、学習時間が矩形特徴の数 C に依存する。従って従来は特徴抽出する領域を互いに隣接した同サイズの小矩形に限定して C を抑えていた (図 1)。

Viola らの手法には二つの問題がある。第一に従来は C を数万～数十万程度に抑えているが、それでも学習時間が数日あるいは週のオーダーに達し、実用上不便な点である。第二に特徴の取り方を制約したこと、より検出力の高い多くの矩形特徴のバリエーションを利用できない点である。特徴の種類を増やすと検出器の精度が向上することが知られているため [9], 本来このような制約を設けることは望ましくない。

本研究では特徴数の増加と学習時間の短縮という二つの相反する問題を同時に解決するため、まず従来の全探索法に代えてランダム候補選択および粒子群最適化を用いた特徴選択法を提案する。これにより、実験では従来法の学習時間を $1/25$ から $1/50$ 程度に短縮した [2] [3]。

次に従来の矩形特徴が持っていた小矩形の同サイズ性および隣接性という制約を廃した非隣接型矩形特徴を提案する。これを粒子群最適化法で特徴選択することにより、Viola らの矩形特徴を用いた検出器より高精度なものをより短時間で構築可能になる [4]。

- 引数 $\{b_c\}_{c=1}^C, \{I_i, w_i, y_i\}_{i=1}^N$ を受け取る
- $c_s = c_g = 2, w_{min} = 0.2, w = w_{max} = 1.2$ とする
- 状態ベクトル $x_\tau^p \in R^d$ と $v_\tau^p \in R^d$ をランダム初期化
- For $\tau = 1, \dots, T_{it}$
 - For $p = 1, \dots, P$
 - * $r_s, r_g \in [0, 1]$ をランダムに設定
 - * 重み付サンプル $\{I_i, w_i, y_i\}_{i=1}^N$ で $b(x_\tau^p; I)$ を訓練
 - * エラー $e_\tau^p = \frac{\sum_{i=1}^N w_i \cdot \delta(y_i - b(x_\tau^p; I_i))}{\sum_{i=1}^N w_i}$ を計算
 - * 一番低い e_τ^p が得られたら h_τ^p または h_g を更新
 - * v_τ^p と x_τ^p を式 (3) で更新
 - 慣性項を更新: $w \leftarrow w_{max} - \frac{\tau}{T_{it}}(w_{max} - w_{min})$
- $\{h_g, e_{h_g}\}$ を出力

図 5 Adaboost.PSO のための最適化関数. 各位置ベクトル x_τ^p は矩形特徴または非隣接型矩形特徴のパラメータで、それぞれ 5 次元 (式 1) または 8 次元 (式 4.)。 h_τ^p と h_g はそれぞれ各粒子 p または全粒子がこれまでに発見した最適解の位置。 e_{h_g} は位置 h_g による訓練サンプルの重み付き誤識別率。

2. 矩形特徴とブースティングによる検出器

2.1 矩形特徴

P. Viola らは物体検出のために矩形特徴 (RF, Rectangular Feature) と呼ばれる局所画像特徴を提案した [10]。矩形特徴は画像中の複数の矩形領域間の平均輝度の差を特徴量とする。矩形特徴は 2 ～ 4 個の互いに隣接した同サイズの小矩形から構成される (図 1, 図 2 左)。そのため矩形特徴は次の 5 つの自由度を持つ。

$$(x_s, y_s, x_e, y_e, z) \quad (1)$$

ここで (x_s, y_s) と (x_e, y_e) は基準となる小矩形の対角線上の 2 頂点の座標、 $z \in \{1, 2, 3, 4\}$ は小矩形の配置タイプ (図 1) である。例として 19×19 ピクセルの画像中には約 53,000 種類の矩形特徴が存在する。

式 (2) に矩形特徴の識別関数を示す。

$$b(I) = \begin{cases} 1 & \text{if } pf(I) > p\theta \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

ここで I は入力画像、 $f(I)$ は I から計算された矩形特徴の特徴量、そして $p \in \{1, -1\}$ と $\theta \in R$ は学習によって決定されるパラメータである (文献 [10] 参照)。

2.2 Adaboost による矩形特徴選択

Adaboost [1] はアンサンブル学習法の一つであり、複数のベース識別器を集めて一つのより強力な識別器を作るための学習法である。各ベース識別器は個々に入力データのクラスを識別し、強識別器はそれらの識別結果で多数決を行うことで最終的な識別結果を決定する。Adaboost のアルゴリズムを図 3 に示す。




図6 異なるパラメータによる Adaboost.RCS(左) および Adaboost.PSO(右) の識別実験結果。横軸は Adaboost のステップ数、縦軸はテストセットへの識別率 (%) を表す。左図 (RCS): 黒/赤/緑/青の線はそれぞれ 1,000/100/10/1 個の候補を用いた際の結果。右図 (PSO): 黒/赤/緑/青の線はそれぞれ粒子数と反復数が 100-20/50-20/30-20/10-10 の PSO を用いた結果。

Violaらは Adaboost で顔検出器を作る際に、ベース識別器として矩形特徴を用いた [10]。Violaらによる Adaboost(Adaboost.VJ と呼ぶ) では、各ステップごとに下記の二段階の最適化が行われる。

- (1) 各矩形特徴を個別に最適化
- (2) 最も識別性能が良かった特徴を選択

学習に N 枚のサンプルを用いる場合、Adaboost.VJ の計算量は $O(N \log NTC)$ になる。ここで $O(N \log N)$ は矩形特徴一つの最適化の計算量オーダーである。また T は Adaboost の反復数であり、学習で選択されたベース識別器 (= 矩形特徴) の数に等しい。 C は学習に利用される矩形特徴の総数である。Adaboost.VJ では各反復毎に全探索法によって矩形特徴選択が行われるため、合計で TC 回の特徴最適化が行われる。

3. 効率的な局所特徴選択法

本節では、本研究で提案するランダム候補選択または粒子群最適化法を用いた効率的な特徴選択アルゴリズムについて述べる。

3.1 ランダム候補選択による矩形特徴選択

2.2 節で述べたように、Adaboost.VJ では各ステップ毎に C 回の最適化が行われる。矩形特徴の数 C を減らせば単純に学習時間を節約することができるが、アンサンブル学習においてはベース識別器の多様性 (diversity) が全体の識別性能に影響を与えることが知られているため [7]、単に矩形特徴の種類を間引いて C を減らすことは望ましくないと考えられる。

そこで、ここではランダム候補選択 (RCS, Ran-

dom Candidate Selection) による矩形特徴選択法 (Adaboost.RCS と呼ぶ) を提案する。Adaboost.RCS は極めて単純な方法で、Adaboost.VJ において各ステップごとに毎回 K 個 ($K < C$) の矩形特徴の部分集合をアトランダムに選び出し、それらのみを候補として特徴選択を行う方法である。これにより C 個の特徴全てが均等に学習に利用される機会を持つため、識別器の多様性が確率的な意味で保たれると期待される。Adaboost.RCS のアルゴリズムを図 3, 図 4 に示す。

Adaboost.RCS の計算量は $O(N \log NTK)$ になる。

3.2 粒子群最適化法による矩形特徴選択

粒子群最適化法 (PSO, Particle Swarm Optimization) は群知性モデルの一種であり、アリなどの群れが集団で餌を探すときの振る舞いをモデル化した手法である [6]。これは遺伝的アルゴリズム [5] のような多粒子系の最適化手法の一種でもある。粒子群最適化法では数十～数千の粒子が互いに通信しながら探索範囲内の最適解を探す。各粒子 p は位置 x_p^t と速度 v_p^t という二つの状態ベクトルを持つ。これらは次式の単純な更新則により時間変化していく。

$$\begin{aligned} v_{t+1}^p &= wv_t^p + c_s r_s (h_s^p - x_t^p) + c_g r_g (h_g - x_t^p) \\ x_{t+1}^p &= x_t^p + v_t^p \end{aligned} \quad (3)$$

ここで w は慣性項、 c_s と c_g は手動設定する重み、 r_s と r_g は 0 から 1 の乱数。また h_s^p と h_g はそれぞれ各粒子 p または全粒子がこれまでに発見した最適解の位置。 P 個の粒子が時刻 T_{it} まで最適解を探索するため、一回の粒子群最適化法の計算量は $O(PT_{it})$ になる。




図7 同程度の計算量による Adaboost.VJ・RCS・PSO の比較結果. 横軸は Adaboost のステップ数, 縦軸はテストセットへの識別率 (黒/緑の線はそれぞれ PSO50-20 と RCS-1000 の結果. 青線は 1068 個に減らされた矩形特徴による Adaboost.VJ の結果.

式 (1) にあるように, 矩形特徴は 5 次元のパラメータを持つ. これらのパラメータを各粒子の位置ベクトル x_t^p と見なすことで, 粒子群最適化の作法により 矩形特徴の選択を行うことができるようになる. すなわち Adaboost.VJ では各反復ごとに全探索法によって特徴選択を行っているが, 提案手法ではそれに代わって粒子群最適化法により特徴選択を行う (これを Adaboost.PSO と呼ぶ). Adaboost.PSO のアルゴリズムを図 3 および図 5 に示す.

ブースティングの各反復ごとに一回の粒子群最適化法が行われるため, Adaboost.PSO 全体の計算量は $O(N \log N T P T_{it})$ になる.

Adaboost.PSO の計算量は特徴の総数 C に直接的には依存しないため, 従来よりも多くの特徴を学習に利用できるようになると期待される. 次節では本研究で提案する拡張型の矩形特徴について述べる.

4. 非隣接型矩形特徴

図 1 にある通り, 従来の矩形特徴には小矩形のサイズが同じであり, また必ず互いに隣接しているという制約が加えられていた. これにより特徴の総数 C を抑え, 学習時間をコントロールしていた. しかし特徴のバリエーションを増やして特徴選択を行うことで強識別器の識別精度が向上することが知られており [9], より高精度な検出器を作るためには従来よりも豊富な候補のもとで特徴選択を行うべきである.

そこで本研究では従来の矩形特徴から小矩形の同サイズ性および隣接性の制約を外した非隣接型矩形特徴 (NNRF, Non-Neighboring RF) を提案する (図

2). 一つの非隣接型矩形特徴は画像中の任意の二つの小矩形領域 r^1 と r^2 から構成されると限定すると, この特徴は次の 8 次元のパラメータを持つようになる.

$$(x_s^1, y_s^1, x_e^1, y_e^1, x_s^2, y_s^2, x_e^2, y_e^2) \quad (4)$$

ここで $(x_s^1, y_s^1), (x_e^1, y_e^1)$ と $(x_s^2, y_s^2), (x_e^2, y_e^2)$ はそれぞれ r^1 と r^2 の対角線上の 2 頂点. 例として 19×19 ピクセルの画像には約 36,000 個の小矩形があるので, 提案特徴は約 $36,000^2 = 13$ 億個という膨大な量のバリエーションを持つ. 提案特徴の特徴量には従来と同じく小矩形領域間の平均輝度の差を用いる.

5. 実験

本研究では 2,901 枚の顔画像と 28,121 枚の背景画像を含む MIT CBCL face database [8] を用いて実験を行った. このうち 2,000 枚の顔と 4,000 枚の背景を学習用セット, 残りをテスト用セットとする. このような学習セットとテストセットのペアをランダムに 3 組生成し, 平均の識別率を以降表示する. 画像は 19×19 ピクセルで, このとき約 53,000 個の矩形特徴と約 13 億個の非隣接型矩形特徴を学習に利用できる.

5.1 Adaboost.RCS

最初に Adaboost.RCS のランダム候補数 K に関する実験を行った. 7 通りの $K(1, 10, 100, 500, 1,000, 1,500, 2,000)$ で学習を行い, 識別性能を比較した. 図 6 左は $K = 1, 10, 100, 1,000$ の結果である. K が大きいほど性能が上がっているが, $K = 100$ と $K = 1,000$ では結果の差はさほど大きくない. さらに K が 500, 1,000, 1,500, 2,000 の場合では, ほとんど性能に有意な差は見られなかった (図は省略). そのため以降は $K = 1,000$ で実験を行う.

5.2 Adaboost.PSO

次に, Adaboost.PSO のパラメータに関する実験を行った. ここで P 粒子と T_{it} 反復の PSO を $P-T_{it}$ と略記する. 7 通りのパラメータ ($10-10, 30-20, 50-20, 100-20, 200-10, 200-20, 200-30$) で学習を行い, 識別性能を比較した. 図 6 右は $10-10, 30-20, 50-20, 100-20$ の結果である. Adaboost.RCS と比べると計算量の違いによる性能の差はやや小さい. また $100-20$ 以上の計算量ではやはり全体的な性能に有意な差は見られなかった (図は省略).

5.3 同計算量での性能比較

ここでは従来手法と提案手法について同程度の計算量で学習を行った際の結果を比較する. 提案手法に




図 8 Adaboost.VJ・RCS・PSO・RCS と PSO のハイブリッド法の比較実験結果。横軸は Adaboost のステップ数、縦軸はテストセットへの識別率 (左図は 30 ステップ目まで、右図は 31 ステップ目から 600 ステップ目までの結果。青/緑/赤/黒のラインはそれぞれ Adaboost.VJ/RCS/PSO/PSO-RCS の結果。

	VJ	RCS-1000	PSO-100-20	PSO-300-30+RCS-1000
Accuracy ($T_{it} = 5$)	90.12%	88.48%	88.68%	89.88%
Accuracy ($T_{it} = 600$)	98.75%	98.78%	98.58%	98.77%
# of Optimized RFs	53,130 × 600	1,000 × 600	2,000 × 600	1,133.33 × 600
Computational Cost	100.0%	1.9%	3.8%	2.1%

表 1 テストデータへの識別率と学習の計算量。 T_{it} は Adaboost の反復数であり、強識別器を構成するベース識別器の数。

は RCS-1000 と PSO-50-20 を用いた。これらは Adaboost の各反復で 1000 回の特徴最適化を行う。従来法の計算量をこれに合わせるため、矩形特徴を画像上で規則的に間引いてその総数を 1,068 個に減らした。

図 7 に比較結果を示す。矩形特徴の種類を減らされた Adaboost.VJ の結果が悪く、やはり特徴選択は豊富な特徴候補のもとで行うべきであることが示された。

5.4 PSO と RCS のハイブリッド法

ここでは Adaboost.RCS と Adaboost.PSO のハイブリッド法を提案し、Adaboost.VJ との比較を行う。図 8 に示されるように、Adaboost.RCS の結果は Adaboost.VJ と比べて序盤で悪く、逆に Adaboost.PSO では後半で悪くなるという傾向が見られる。そこで Adaboost の序盤では PSO によって十分に最適化を行い、中盤以降は RCS によって高速に特徴選択するというハイブリッド法を提案する。結果は、図 8 および表 1 にあるように、序盤 (左図) でも中盤以降 (右図) でもハイブリッド法と Viola らの学習法はほぼ同程度の識別精度を持っていることが解る。

従来は約 53,000 個の矩形特徴全てから特徴選択を行っていたが、提案手法では高々 1,000~2,000 個程度のみを用いて同程度の識別精度を持つアンサンブルを構築でき、計算量の面で大きな利点があると言える。

5.5 PSO による非隣接型矩形特徴選択

次に、非隣接型矩形特徴を PSO で選択する実験について述べる。PSO には 100-10, 300-30, 1000-50, 2000-25 を使い、結果を図 9 左に示した。計算量が多いほど良い結果が得られ、試した中では PSO2000-25 が最高の結果を示した。

5.6 矩形特徴と非隣接型矩形特徴の比較

最後に従来の矩形特徴と提案する非隣接型矩形特徴の比較実験を行った。結果を図 9 右と表 2 に示す。表 2 の 2 段目は特に非隣接型矩形特徴の潜在力を表している。約 53,000 個の候補から選ばれた最も高性能な矩形特徴の識別精度は 86.06% だが、約 13 億個の候補から PSO によって探し出された (準) 最適な非隣接型矩形特徴は、89.12% の識別精度を持っている。

図 9 右と表 2 にあるように、PSO2000-25 を用いた場合は従来特徴のアンサンブルよりほぼ常に精度が高く、かつ学習の計算量は若干少ない。また、PSO300-30 を用いた場合は若干序盤の性能で劣るが、50 ステップ目以降はほぼ同程度の精度を達成しており、かつ学習の計算量は 1/6 である。

6. あとがき

本研究では第一に粒子群最適化法を用いた高速な矩




図 9 左図: 異なる PSO のパラメータによる非隣接型矩形特徴の識別実験結果. 右図: 矩形特徴と非隣接型矩形特徴の比較. 横軸は Adaboost のステップ数, 縦軸はテストセットへの識別率を表す.

	Viola-Jones' RF	NNRF (PSO300-30)	NNRF (PSO-2000-25)
識別率 ($T_{it} = 1$)	86.06%	84.32%	89.12%
識別率 ($T_{it} = 50$)	95.61%	95.79%	96.39%
識別率 ($T_{it} = 200$)	98.01%	97.95%	98.27%
矩形特徴の学習回数	53, 130 T_{it}	9, 000 T_{it}	50, 000 T_{it}

表 2 テストデータへの識別率と学習の計算量. T_{it} は Adaboost の反復数であり, 強識別器を構成するベース識別器の数.

形特徴選択法を提案した. 従来の学習法では Adaboost の各反復で約 53,000 個の矩形特徴全てを評価して特徴選択を行うが, 提案手法ではそのうち高々 1,000 個から 2,000 個程度のみを評価することで同程度の性能の検出器を構築できることを示した. これにより検出器の学習時間を 1/25 から 1/50 程度に短縮できた.

第二に矩形特徴の拡張である非隣接型矩形特徴を提案し, またそれを粒子群最適化法によって特徴選択する手法を提案した. 矩形特徴の 53,000 個に対し, 非隣接型矩形特徴は約 13 億個という膨大な数のバリエーションを持つ. 実験により, それらのバリエーションの中には従来より識別力の高い特徴が含まれること, および粒子群最適化法によってそれらの高性能な特徴を効率的に選択できることを示した.

謝辞 本研究の一部は科研費 (19500163) の助成を受けたものである.

文 献

- [1] Y. Freund, R. Schapire, "A decision-theoretic generalization of on-line learning and an application to boosting," *Journal of Computer and System Sciences*, vol. 55, 1, pp. 119-139, 1997
- [2] A. Hidaka, T. Kurita, "Fast Training Algorithm by Particle Swarm Optimization for Rectangular Feature Based Boosted Detector," In Proc. of FCV2008, pp.88-93, Jan. 2008.
- [3] A. Hidaka and T. Kurita, "Fast Training Algorithm by Particle Swarm Optimization and Random Candidate Selection for Rectangular Feature Based Boosted Detector," In Proc. of IJCNN2008 on WCCI2008, Jun. 2008.
- [4] A. Hidaka and T. Kurita, "Non-Neighboring Rectangular Feature Selection using Particle Swarm Optimization," In Proc. of ICPR2008, Dec. 2008, *Accepted*.
- [5] J. Holland, "Adaptation in Natural and Artificial Systems," University of Michigan Press, 1975.
- [6] J. Kennedy, and R. Eberhart, "Particle Swarm Optimization," In Proc. of IEEE int. conf. on neural networks Vol. IV, pp. 1942-1948. IEEE service center, Piscataway, NJ, 1995.
- [7] L. Kuncheva, "Measures of Diversity in Classifier Ensembles and Their Relationship with the Ensemble Accuracy," *Machine Learning*, vol. 51, 2, pp. 181-207, 2003
- [8] MIT Center For Biological and Computation Learning, "CBCL Face Database #1," <http://www.ai.mit.edu/projects/cbcl>.
- [9] R. Lienhart and J. Maydt, "An Extended Set of Haar-like Features for Rapid Object Detection," In Proc. of IEEE ICIP 2002.
- [10] P. Viola and M. Jones, "Robust real time object detection," In Proc. of IEEE ICCV Workshop on Statistical and Computational Theories of Vision, July 2001.