

分枝限定法を用いた顔認識の効率化

内海 ゆづ子^{†1} 松本 雄大^{†1} 岩井 儀雄^{†1}

これまで、顔認識に関して様々な手法が提案され、認識率を改善するために研究が行われてきた。そのため、計算コストに焦点をおいた手法はほとんど提案されてこなかった。そこで、我々は、計算コストを削減するため、分枝限定法を用いた効率的な顔認識手法を提案する。分枝限定法では、限定操作を認識木のより早い段階で行うほど効率が向上する。そこで、本論文では、AdaBoostにより生成された個人ごとの識別器の重みを利用して弱識別器の計算順序を変更することにより、より早い段階で限定操作を行って顔認識処理の効率化を図る。実験により、提案手法が探索ノードをオリジナルのデータベースを用いたもので平均 72.1%削減することができ、大幅な計算コストの削減に成功した。

Effective Face Recognition by Branch and Bound Method

YUZUKO UTSUMI,^{†1} YUTA MATSUMOTO^{†1}
and YOSHIO IWAI^{†1}

Researchers have proposed many face recognition methods with the aim of improving the accuracy rate of face recognition in several decades. Few face recognition methods, however, focus on computational cost. To reduce the computational cost of face recognition, we propose an effective face recognition method using branch and bound method. The efficiency of the branch and bound method can be improved by performing bounding operation at shallow nodes. We, therefore, change the calculation order of the weak learners learned by AdaBoost M1 algorithm for early bounding. Experimental results show that our proposed method reduces the calculated classifiers in the recognition tree by 72.1% and achieves an overall reduction in the computational cost.

^{†1} 大阪大学大学院基礎工学研究科
Graduate School of Engineering Science, Osaka University

1. はじめに

近年、コンピュータ、センサ、アクチュエータの小型化、低価格化が進み、これらを用いたロボットやセンサネットワークといったシステムが社会に導入されるようになってきた。これらのシステムは、人々に情報を提供する^{1)–3)}、人の作業を手伝う^{4)–6)}などの活動の支援や、人同士のコミュニケーション支援^{7)–11)}など、人に対する支援を行うことを目的として導入されている。よって、これらのシステムにおいて人とのインタラクションは不可欠な要素となる。

人とシステムとのインタラクションを行う際に、システムが人物を認識することができれば、各人物に適した支援が可能となる¹²⁾。人物の認識の1つに、顔認識がある。顔認識は、画像センサで撮影された顔画像を用いて行うため、センサに接触せずに認識が可能である。また、人も人を認識する際は顔を見て行うため、自然な人物認識であるといえる。

顔認識はこれまで、様々な方法が提案されてきた。部分空間を用いた方法として、主成分分析 (PCA) を用いたもの^{13)–16)}、線形判別分析 (LDA) を用いたもの^{17)–19)}、独立成分分析 (ICA) を用いたもの^{20),21)} があげられる。また、このほかに、ニューラルネットワークを用いた手法^{22)–25)} や、隠れマルコフモデル (HMM) を用いた手法^{26)–28)}、SVM を用いた手法^{29)–32)} があげられる。これらの手法は認識精度を改善するために考案された手法であり、計算コストの面を考慮せず研究が行われてきた。そのため、ニューラルネットワークや HMM といった手法は認識を行うまでに非常に計算時間がかかる。また、認識が高速に行える部分空間法や SVM を用いた手法は、主に、2 クラス判別問題を解く手法であり、顔認識を行う場合、すべての人物の顔判別を行わなければならない。よって、データベースに存在する人数が増えるにつれて、計算時間が増加する。顔認識の実用性を考慮すると、認識までにかかる時間はできるだけ短い方が良い。また、実際に顔認識システムが搭載されるロボットなどの計算機の性能には限界があり、計算量が少ない方が望ましい。2 クラス判別問題の計算を高速に行う手法として、分枝限定法を用いた手法が提案されている³³⁾。この手法は、物体認識を画像中に目標の物体が存在している、いないの 2 クラス判別問題として扱い、画像中で長方形の窓を移動させながら窓内に物体があるかないかの判別をすることにより物体の位置推定を行う。この手法では、SVM を用いて物体の認識を行う。SVM で学習した識別器が最大値をとる領域を物体領域とし、この最大値を画像から高速に探索するために、分枝限定法を用いている。SVM の識別器の出力は学習で得られたサポートベクタと画像から得られた特徴量の内積の重み付き線形和によって計算がされる。よって、分枝限定

法で用いる各ノードにおける上限値を正確に計算することができず、計算を途中で打ち切る刈り込みが最適に行われていなかった。

本論文では、顔認識に対して分枝限定法を適用し、高速に計算を行う手法を提案する。顔認識を各個人の識別器の2クラス判別問題と見なし、最大の出力値を示す識別器の人物を認識結果とする。そして、最大値の計算に分枝限定法を利用することで、効率良く計算する。各個人の識別器は、AdaBoost M1 アルゴリズムで学習したものを基にし、多クラスに適用可能なように改良して利用する。AdaBoost 識別器は、 ± 1 を出力する弱識別器の重み付き線形和で計算される。そのため、SVM などを用いた手法と比較して、部分問題の上限値を正確に推定することが可能であり、最も効率の良い最大値の探索が可能となる。画像特徴量には、Haar ウェーブレット特徴量を用いた。Haar ウェーブレット特徴量は、従来多くの顔認識で用いられてきた Gabor ウェーブレットと比較して計算コストが低く、同等の認識結果を示すことが分かっている^{34),39)}。

以降、2章では分枝限定法を顔認識に対してどのように適用したか説明する。3章では、効率的な認識木の構築について説明する。4章では、提案手法の有効性を確認するために行った実験と結果を示し、最後に5章で本論文をまとめる。

2. 分枝限定法を用いた顔認識の効率化

本章では、顔認識を離散最適化問題として定式化する。特徴量が得られたときの判別関数を計算する際に、分枝限定法を適用し、効率的に最適化計算を行う方法を説明する。

2.1 顔認識の定式化

顔認識は、与えられた入力画像に対して特徴抽出を行い、得られた特徴量と顔データベースの特徴量を比較して、最も判別関数の値が大きい人物を認識結果として出力することで行われる。これを、数式で表すと以下ようになる。

$$g_k = \operatorname{argmax}_{i=1, \dots, I} g_i(f) \Rightarrow f \in \omega_k \quad (1)$$

ただし、 g_i は人物 i の顔の識別器、 ω_i は人物 i の顔、 f は得られた特徴量を並べた特徴ベクトルである。

識別器の学習には、AdaBoost M1 アルゴリズムを利用する。AdaBoost M1 アルゴリズムによって得られる識別器は、弱識別器 h_d^i の重み付き線形和を用いて以下のように表すことができる。

$$\sum_{d=1}^D \alpha_d^i h_d^i(f_d) \quad (2)$$

ここで、 D は特徴ベクトルの次元数、 f_d は特徴ベクトルの d 番目の要素である。 α_d^i は弱識別器 h_d^i の対数訓練誤差比で、以下のように表される。

$$\alpha_d^i = \frac{1}{2} \ln \left(\frac{1 - \epsilon_d^i}{\epsilon_d^i} \right) \quad (3)$$

ただし、 ϵ_d^i は弱識別器 h_d^i の訓練誤差を表す。AdaBoost の学習を用いて特徴次元の削減を行う場合には、 α の値の大きいものから順に識別器が目標とする識別率を示すまで特徴量を選択して、識別器を構成する。本論文では、従来の AdaBoost 識別器の特徴量選択とは異なり、複数の識別器から共通の特徴量を選択し、識別器を構成する。そこで、特徴量選択の指標として、 α_d^i に代わり、 α_d^i を各識別器で正規化した γ_d^i を用いて特徴量を選択と認識を行う。本論文で用いる識別器は以下のように表すことができる。

$$g_i(f) = \sum_{d=1}^D \gamma_d^i h_d^i(f_d) \quad (4)$$

また、本論文で学習した弱識別器は以下のように表される。

$$h_d^i(f_d) = \begin{cases} 1 & \text{if } p_d^i f_d < p_d^i \theta_d^i \\ -1 & \text{otherwise} \end{cases} \quad (5)$$

ただし、 θ_d^i は閾値、 p_d^i はプライオリティを表し、符号の向きを決定する。具体的な正規化の方法と特徴量選択の詳細は、3.1 節で述べる。

式 (1) から、顔認識は、識別関数 $g(f)$ を最大化する顔 ω_i を見つけることと同義であり、これは、 ω_i の $g_i(f)$ に対する離散最適化問題であると見なすことができる。そこで、分枝限定法を式 (1) に適用し、顔認識の効率化を図る。

2.2 分枝限定法

分枝限定法は 1960 年に A.H. Land と A.G. Doig により提案され³⁵⁾、広く用いられてきた。分枝限定法は、主に離散最適化問題や組合せ最適化問題での最適解を求めるために用いられる。分枝限定法では、2 つの手続きが存在する。1 つは与えられた最適化問題を部分問題に分割する手続きであり、分枝操作と呼ばれる。分枝操作は再帰的に行われ、各ノードが部分問題を示す探索木（認識木）が生成される。もう 1 つは、部分問題の最適化関数の値

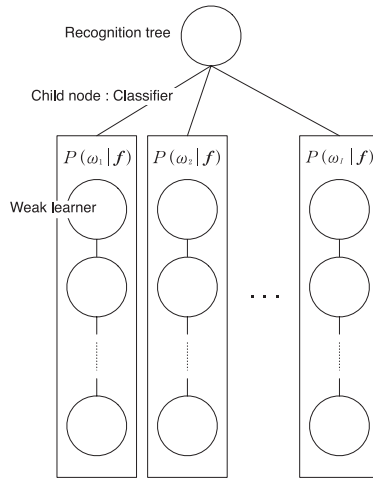


図 1 分枝操作を行って得られた認識木
Fig. 1 Recognition tree created by branching operation.

の上限と下限を用いて、探索の必要のないノードの計算を打ち切る限定操作である。分枝操作、限定操作のアルゴリズムは様々なものが考えられており、用いられるアルゴリズムによって問題における分枝限定法の有効性が変化する。また、あらゆる問題でうまく機能する分枝操作、限定操作は存在せず、最適化を効率良く行おうとした場合、問題ごとに2つの操作のアルゴリズムを変える必要がある。本論文では、新たな分枝操作、限定操作を提案し、顔認識の計算の高速化を目指す。

2.2.1 分枝操作

本論文では分枝操作として、顔認識をデータベース各個人での顔の認識に分割する。この分枝操作を行って得られた認識木の概要を図1に示す。認識木の1つのノードにつき、データベースのある人物 i の顔画像の特徴量 f に対する判別関数の出力値 $g_i(f)$ を計算することとなる。

2.2.2 限定操作

限定操作は、弱識別器ごとに学習された α_d^i を正規化した γ_d^i をもとに行う。限定操作は、顔の識別の計算を行う際に、識別器の上限値と暫定の最大値を比較して、暫定の最大値より小さい場合、識別器の計算を停止する。具体的には、まず、入力された特徴ベクトルから、あるノードの識別器の計算を行い、出力値を暫定最大値 G_{\max} とする。続いて、別のノード

Input: Feature vector $\mathbf{f} = (f_1 \cdots f_d \cdots f_D)^\top$

Initialization: $G_{\max} = 0, G_0^i = 0 (i = 1, \dots, I), \text{max-id} = 0$: non-registrant

for $i = 1, \dots, I$

for $d = 1, \dots, D$

1. Update weighted sum G_d^i and \overline{G}_d^i

$$G_d^i = G_{d-1}^i + \gamma_d^i h_d^i(f_d)$$

$$\overline{G}_d^i = \sum_{k=d+1}^D \gamma_k^i$$

2. Decision of bounding operation

if($G_d^i + \overline{G}_d^i < G_{\max}$): break

3. Update provisional maximum G_{\max}

if($G_{\max} < G_d^i$): $G_{\max} = G_d^i$

if($G_{\max} > T$): max-id = i

Output: max-id

図 2 限定操作の疑似コード

Fig. 2 Pseudo-code for bounding operation.

i において、 d 番目までの弱識別器の γ_d^i による重み付き線形和 G_d^i と $d+1$ 番目以降の γ_d^i 値の和 \overline{G}_d^i をとる。

$$G_d^i = \sum_{k=1}^d \gamma_k^i h_k^i(f_k) \tag{6}$$

$$\overline{G}_d^i = \sum_{k=d+1}^D \gamma_k^i \tag{7}$$

弱識別器の最大値が1なので、 $G_d^i + \overline{G}_d^i$ は d 番目までの弱識別器の計算を行った際のこの識別器における上限値となる。そして、上限値 $G_d^i + \overline{G}_d^i$ と暫定最大値 G_{\max} との比較を行い、暫定最大値よりも上限値が小さい場合は限定操作を行い、それ以降の識別器の計算を停止する。識別器の計算が最後まで行われた際に、暫定最大値 G_{\max} と出力値 G_D^i の比較を行い、出力値が暫定最大値よりも大きければ、暫定最大値を更新する。最大値を更新した際、更新した最大値がデータベースの登録者かどうかを判別する閾値 T より大きい場合は、max-id の値を更新する。これらの操作をすべての識別器ノードで行い、最終的に得られた

最大値を出力する識別器の人物が認識結果となる．このアルゴリズムをまとめたものを図 2 に示す．

Viola ら³⁶⁾ は，顔検出を顔，非顔の 2 クラス分類問題とし，AdaBoost を用いて Haar ウェーブレット特徴量と類似した Haar-like 特徴量に基づいた弱識別器を学習し，弱識別器をカスケード構造の識別器として利用している．Viola らの手法は，我々の手法と非常に似ており，カスケード型の識別器を用いれば，計算のコストの削減は可能と考えられる．しかし，カスケード型の識別器は，あるノードの出力値をもとに計算の打ち切りの判断を行っており，得られる解は，式 (1) をつねに満たすとは限らない．一方で，我々の手法は，暫定最大値 G_{\max} と識別器の上限値 $G_d^i + \overline{G_d^i}$ の比較を行い，限定操作として，計算の打ち切りを行っている．よって，得られる解はつねに式 (1) を満たすことができる点が最大の違いである．

3. 効率的な認識木の構築法

分枝限定法を効率的に使用するためには，認識木のより浅い段階で限定操作を行う必要がある．そこで， γ_d^i を利用して，弱識別器の計算順序を変更することでより効率的な認識が可能な認識木の構築法について述べる．具体的には，1) AdaBoost の弱識別器の対数訓練誤差比 α_d^i を正規化した γ_d^i の値をもとに，顔認識に用いる特徴量の選択を行い，さらに 2) 弱識別器の計算順序を変更することで，分枝限定法が本論文の顔認識問題に対して最も高い有効性を示すようにする．

3.1 γ_d^i による特徴量選択

AdaBoost M1 アルゴリズムにより学習を行い，1 つの画像から大量に得られる画像特徴量の中から，認識に有効な特徴量を選択する．有効な特徴量を選択する理由は，冗長な特徴量を排除し，顔認識処理の効率化を図るためである．しかしながら，本論文では，各個人で識別器の学習を行っているため，各個人の識別器によって α_d^i が異なり，すべての識別器に共通する特徴量の選択指標が存在しないため，何らかの正規化がされた γ_d^i が必要である． γ_d^i が決定されれば，以下のように同じ特徴量を用いている弱識別器の γ_d^i 値の和 Γ_d を特徴量の選択指標とすることができる．

$$\Gamma_d = \sum_{i=1}^I \gamma_d^i \quad (8)$$

Γ_d は，値が大きいほど分類により大きく貢献していることがいえるため， Γ_d が大きい特

Step 1: Select Haar rectangular filters.

$$\text{Criterion: } \Gamma_d = \sum_{i=1}^I \gamma_d^i, \quad \gamma_d^i = \frac{\alpha_d^i}{\sum_{d=1}^D \alpha_d^i}$$

Step 2: Sort face classifiers in descending order of Γ^i .

$$\Gamma^i = \sum_{d=1}^D \gamma_d^i$$

Step 3: Sort weak learners in descending order of γ_d^i within each classifier.

図 3 認識木構築の流れ

Fig. 3 The process flow in creating a recognition tree.

徴量から選択することで，有効な特徴量を取り出すことができる．さらに，学習に用いていない検証データに対して，識別器が目標の認識率を示すまで，特徴量の次元を増やして，特徴量の数（弱学習器の数）を決定することができる．

そこで，本論文では，いくつかの指標を用いて予備実験を行い， γ_d^i として，以下のものを選択した．予備実験の結果は，4.2 節で示す．

$$\gamma_d^i = \frac{\alpha_d^i}{\sum_{d=1}^D \alpha_d^i} \quad (9)$$

3.2 分枝操作と識別器の計算順序

分枝限定法は，2.2 節で述べたように，分枝操作と限定操作のアルゴリズムの組合せによって問題に対する有効性が変化する．本論文では，限定操作が効率良く行われるような分枝操作と識別器の計算順序を提案する．まず，分枝操作に関して，2.2.2 項の限定操作を行う場合，識別器の出力の上限値が大きいものから順に計算を行った方が，弱識別器の刈り込みが多く行われ，効率良く認識が行われる可能性が高い．そこで，以下に示す出力値の上限値である各識別器の γ_d^i の値の和 Γ^i ，つまり各識別器の上限値の大きいものから順に計算を行うことで限定操作を効率良く行うことができる．

$$\Gamma^i = \sum_{d=1}^D \gamma_d^i \quad (10)$$

具体的には，子ノードを左から Γ^i の降順で並べるように分枝操作で認識木を構成し，探索を左の子ノードから順に行うことで実現する．

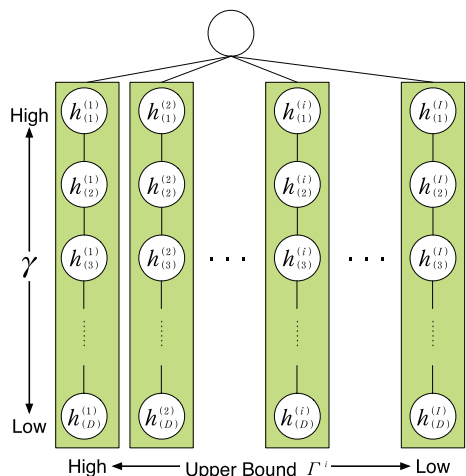


図 4 認識木の概要．緑色の長方形は分枝操作により上限値 Γ^i の値に基づいてソートされた子ノードを示す．また、緑色の長方形内の円は各識別器中の弱識別器を表しており、 γ_d^i の値によってソートされている．

Fig. 4 Outline of recognition tree. Green rectangles are child nodes sorted in descending order of upper bound Γ^i . White circles are weak learners sorted in descending order of γ_d^i .

また、識別器の計算順序に関して限定操作を考慮すると、先に γ_d^i 値の大きいものを計算した方が、弱識別器の計算を最小限にして刈り込みを行える可能性が高くなる．よって、あらかじめ γ_d^i 値が降順になるよう弱識別器をソートしておき、 γ_d^i の大きいものから順番に弱識別器を計算する．認識木作成の流れを図 3 に、この方法により生成された認識木の概要を図 4 に示す．

4. 実験

これまでに述べた分枝限定法を用いた顔認識手法の効率性を評価するために、実験を行った．

4.1 実験環境

本システムの実装は、MacBook Pro (OS: Mac OS X 10.5, CPU: Intel Core 2 Duo 2.4GHz, memory: 4GB) 上で行った．評価実験には 2 つのデータベースを用いた．1 つ目は (a) The Yale Face Database B と The Extended Yale Face Database B^{37),38)}、2 つ目は (b) 本論文で独自に撮影した顔画像データベースである．(a) について、The Yale Face Database B と The Extended Yale Face Database B はそれぞれ 10 人、28 人の顔画像で

表 1 用いたデータベース

Table 1 Database used in this research.

	データベース	人数	学習に用いた枚数/人
(a)	Yale Face Database B Extended Yale Face database B	37	190
(b)	本論文で独自撮影	20	315




図 5 顔領域の切り出し

Fig. 5 Clipping the face area.

構成され、1 人あたり 576 種類の画像 (9 つのポーズと 64 種類の照明条件) が撮影されている．また、データベースの画像は顔領域が切り出され、 168×192 pixels に正規化されている．本論文では、正面から撮影され、64 種類の中では照明変化の少ない画像を 1 人あたり 17 枚、37 人分の計 646 枚用いた．このうち、各人物の AdaBoost の学習には、ポジティブサンプルを 10 枚、ネガティブサンプルを他人 1 人あたり 5 枚、36 人分の 180 枚、合計で 190 枚の画像を用いた．また、学習に用いていない画像を 1 人あたり 7 枚、合計 259 枚を用いて AdaBoost の学習の検証や分枝限定法の計算時間の測定に利用した．

また、(b) に関しては、解像度 640×480 pixels のグレースケール画像を用いた．顔の大きさが 3 パターン (大, 中, 小) で 1 つのパターンごとに 15 枚、各人 45 枚の 20 人分、合計 900 枚の画像を用いた．各画像は正面を向いた無表情の顔画像である．AdaBoost による個人ごとの分類器の学習には、1 人の人物の識別器の学習につき、ポジティブサンプル 30 枚、ネガティブサンプル 285 枚、合計 315 枚を使用した．また、学習に用いていない画像を被験者 20 人分、各個人 5 枚、計 100 枚、学習の検証と計算時間の計測に用いた．データベース (a), (b) の内容をまとめたものを表 1 に示す．

画像上の顔の大きさは、カメラと顔の距離の関係によって変化し、顔の認識性能に影響を及ぼす．そこで、データベース (b) において顔の大きさの正規化を図り、一定の大きさの顔画像に対しての認識を行った．本実験では、図 5 に示すように、画像上の鼻の頭を中




図 6 Haar ウェーブレット変換の矩形フィルタ. 黒は -1 , 白は 1 を表す

Fig. 6 Rectangular filters. The black and white regions in this figure represent -1 and 1 , respectively.

心とし、左目と右目の幅 L の 2 倍 $2L$ を 1 辺の長さとした正方形領域を顔領域として切り出す。続いて、切り出された顔領域が一定の大きさになるよう正規化を行う。正規化には、バイキュービック法を用いた。すべての顔画像は、顔の特徴点をもとに顔画像を切り出し、 64×64 pixels に正規化を行った。

正規化された画像に対し、Haar ウェーブレットを用いて、1 次元のウェーブレット変換を縦方向と横方向に行う 2 次元ウェーブレット変換により得られる特徴量を顔認識に利用した。Haar ウェーブレットは、最も単純な矩形のウェーブレットである。また、正弦波とガウシアンとの積により波形が表現される Gabor ウェーブレットと比較して、波形の計算が容易でかつ特徴抽出の際の計算コストが低い。本論文では、計算コストのかからない高速な顔認識を目標に研究を行っているため、計算コストの面でより有利な 2 次元 Haar ウェーブレット特徴量を用いた。

2 次元の Haar ウェーブレット変換は、図 6 (a) のような黒い部分が -1 , 白い部分が 1 となるような矩形フィルタと画像との畳み込み積分として表現できる。この矩形フィルタでは、縦、横方向のエッジ部分に強く反応し、斜め方向のエッジには反応しない。矩形フィルタのみを用いた場合、斜め方向の顔画像のエッジ特徴を抽出することが困難である。そこで、矩形フィルタを回転させ、特徴抽出を行った。本実験では、矩形フィルタを $0, \pi/8, \pi/4, 3\pi/8$ 回転させたフィルタを用いて特徴抽出を行った。回転を行った矩形フィルタを図 6 (b)–(d) に示す。特徴抽出を行った Haar ウェーブレットの大きさは、一辺 $8, 16, 24, 32, 40, 48, 56, 64$ pixels の 8 種類である。

データベース (a), (b) ともに正規化された顔領域に対して矩形フィルタを 4 pixels ずつ移動させ、2,720 個の特徴量を抽出を行い、AdaBoost M1 アルゴリズムにより学習を行った。

4.2 特徴量の指標の選択

3.1 節で述べたように、複数の識別器から特徴量を選択するために、新たな指標を用いる




図 7 特徴量選択指標 A_d, B_d, Γ_d を用いた場合の特徴次元と認識率の関係

Fig. 7 Recognition rates using A_d, B_d, Γ_d as a criterion of feature selection.

必要がある。そこで、3 種類の特徴量選択の指標 A_d, B_d, Γ_d を考案し、データベース (b) の学習結果を用いて指標が大きいものから順に選択を行い、認識を行った。3 種類の指標は以下の式で表される。

$$A_d = \sum_{i=1}^I \alpha_d^i$$

$$B_d = \sum_{i=1}^I \beta_d^i, \quad \beta_d^i = \frac{\alpha_d^i}{\alpha_{\max}^i}, \quad \alpha_{\max}^i = \max_d \alpha_d^i$$

$$\Gamma_d = \sum_{i=1}^I \gamma_d^i, \quad \gamma_d^i = \frac{\alpha_d^i}{\sum_{d=1}^D \alpha_d^i}$$

A_d, B_d, Γ_d を用いて特徴量選択を行い、テストデータを識別器に入力した場合の認識率、FRR, FAR をそれぞれ図 7, 図 8, 図 9 に示す。これらの結果から、3 つの指標とも、特徴次元が増えると認識率が上昇することが明らかとなり、 A_d, B_d, Γ_d はすべて特徴選択の指標にふさわしいと考えられる。特徴次元が多い場合、3 つの指標に目立った差は存在しなかったが、特徴次元が少ない場合、 Γ_d を用いた場合が最も良い認識率を示した。指標の大きいものから特徴量を選択しているため、特徴次元が少ない場合でより良い識別率を示すことは、顔の識別に有効な特徴量ほど指標が大きな値を示していることがいえ、より良い指標であることがいえる。よって、本論文では Γ_d を特徴量選択の指標として用いることとする。




図 8 特徴量選択指標 A_d, B_d, Γ_d を用いた特徴次元と FRR の関係
Fig. 8 FRRs using A_d, B_d, Γ_d as a criterion of feature selection.




図 9 特徴量選択指標 A_d, B_d, Γ_d を用いた特徴次元と FAR の関係
Fig. 9 FARs using A_d, B_d, Γ_d as a criterion of feature selection.

4.3 γ_d^i による特徴量の選択

各データベースごとに学習を行って得られた各識別器の α_d^i 値を正規化して γ_d^i を求め、 Γ_d を計算し、これをもとに認識率が 99% となるように特徴量の選択を行った。検証用画像において、 Γ_d の大きい特徴量から順に認識に用いた場合の認識率、FRR、FAR の変化を表すグラフを図 10、図 11 に示す。図 10、11 より、データベース (a) では特徴次元が 200




図 10 データベース (a) の認識に用いた特徴次元と認識率、FRR、FAR
Fig. 10 Recognition rate, FRR and FAR in database (a).





図 11 データベース (b) の認識に用いた特徴次元と認識率、FRR、FAR
Fig. 11 Recognition rate, FRR and FAR in database (b).

次元、データベース (b) では特徴次元が 150 次元の際に認識率がそれぞれ 99.2%、99.3% となり、2,720 個の特徴量のうち、データベース (a) では Γ_d の上位 7.35%、データベース (b) では上位 5.5% の特徴量を利用するだけで精度良く認識を行えることが明らかとなった。

図 12 に、データベース (b) で得られた Γ_d の上位 30 個の特徴量の矩形フィルタを示す。図 12 に示された矩形フィルタは、目や鼻、口の周辺に多く見られ、分類精度が高い特徴量は、目や鼻、口の特徴を抽出していると考えられる。よって、顔の認識には、目、鼻、口といった部分の特徴が有効であることがいえる。また、 Γ_d が大きな値を持つ矩形フィルタのサイズは、16、24、32、40、48 pixels が多く見られた。正規化した 64×64 pixels の顔画像に対し、56、64 pixels とした大きな矩形フィルタを用いた場合、口、鼻、目といった顔の特徴的な部位の局所的な特徴を抽出できず、特徴量に個人差が反映されないと考えられる。よって、顔画像全体を覆ってしまうような大きさの矩形フィルタでは、顔認識に有効な

図 12 Γ_d 上位 30 個の矩形フィルタFig. 12 Top 30 rectangular filters for Γ_d .

特徴量が得られない。また、8 pixels といった小さな矩形フィルタでは、非常に局所的な特徴量しか得られない。よって、この場合も個人差が特徴量に反映されなかったと考えられる。図 10, 11 から、認識率が 99% を超えるデータベース (a) では 200 個、データベース (b) では 150 個の特徴量を用いて分枝限定法による顔認識の計算コストの評価を行う。

4.4 分枝限定法を用いた顔認識の計算コスト評価

分枝限定法における計算コストの評価実験を行う。データベース (a) では、37 人の各識別器を Γ_d によって選択された 200 個の特徴量で構築すると、認識木の弱識別器の総数は $37 \times 200 = 7,400$ 個となる。また、データベース (b) では、20 人の各識別器を Γ_d によって選択された 150 個の特徴量で構成すると、認識木の弱識別器の総数は $20 \times 150 = 3,000$ 個となる。3.2 節で述べた分枝操作を行って各データベースでの子ノードと弱識別器をソートし、認識木を構成した。データベース (a), (b) でそれぞれ 37 人、20 人の検証用画像が

表 2 分枝操作と限定操作によって削減される弱識別器の平均

Table 2 Average number of weak learners pruned and the average rate of pruning weak learners using the branch and bound method.

		刈り込み個数平均 (個)	刈り込み率平均 (%)
データベース (a)	(1)	3,404	46.0
	(2)	5,063	68.4
データベース (b)	(1)	1,373	47.3
	(2)	2,164	72.1

表 3 認識木生成にかかる平均計算時間

Table 3 Average computational time for generating recognition tree.

	計算時間 (s)
データベース (a)	0.150
データベース (b)	0.088

ら 1 人あたり 1 枚入力し、2.2.2 項で述べた限定操作によって弱識別器の計算を途中で打ち切りながら、効率良く認識が行えるか評価実験を行った。

実験結果として、刈り込みを行った弱識別器の数と、刈り込みをした弱識別器の割合の平均を表 2 に示す。ただし、(1) は 3.2 節で述べた Γ^i による弱分類器のソート、弱識別器の γ_d^i によるソートを行わなかった場合、(2) は Γ^i による弱分類器のソート、弱識別器の γ_d^i によるソートを行った場合を表す。表 2 より、(1), (2) いずれの場合でも、弱識別器の刈り込みが行われており、分枝限定法によって最大で 72.1% 弱識別器の計算が削減され、顔認識の効率化が行えることが明らかとなった。また、(1), (2) を比較した場合、(2) の Γ^i による弱分類器のソート、弱識別器の γ_d^i によるソートを行った方が、(1) の何もせずに認識木を構成した場合と比較して、刈り込まれる弱識別器の数が増加していることが分かる。これは、本論文で提案した分枝限定法の分枝操作と限定操作が顔認識問題に対して有効であり、また、提案した分枝操作と限定操作のアルゴリズムの組合せが適していることがいえる。

続いて、分枝限定法の使用の有無による実行時間の比較実験を行った。まず、データベース (a), (b) に関して 37 人、20 人分の認識木を生成し、生成にかかる時間を計測した。続いて、データベース (a), (b) の認識木にそれぞれ 37 人、20 人分の検証用画像各 1 枚の特徴量を入力し、認識が終了するまでの時間を計測し、分枝限定法を用いない場合と比較を行った。認識木生成を 10 回行い、生成にかかる時間の平均を表 3 に、認識の計算時間を示すグラフを図 13, 図 14 に示す。表 3 より、認識木の生成に若干の時間がかかるが、認識木は認識前に 1 度だけ作成すればよく、認識中に再構築する必要がないため、特に問題はな




図 13 データベース (a) の探索にかかる時間の比較。ただし Without BB は分枝限定法を用いない場合、With BB は分枝限定法を用いた場合を表す

Fig. 13 Computational time for face recognition in database (a). “Without BB” means without using the branch and bound method and “With BB” means with the branch and bound method.

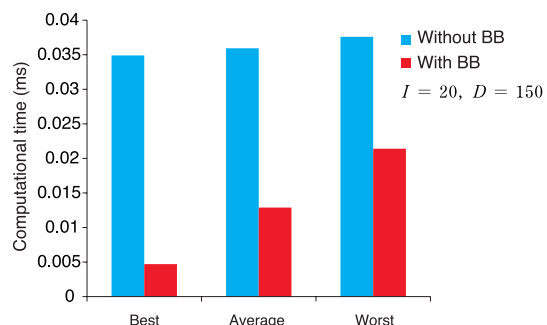


図 14 データベース (b) の探索にかかる時間の比較。ただし Without BB は分枝限定法を用いない場合、With BB は分枝限定法を用いた場合を表す

Fig. 14 Computational time for face recognition in database (b). “Without BB” means without using the branch and bound method and “With BB” means with the branch and bound method.

い。図 13, 14 に示したとおり、データベース (a) の場合は分枝限定法を使用した場合の平均実行時間は 0.0308 ms、使用しない場合の平均実行時間は 0.0897 ms、データベース (b) では分枝限定法を使用した場合の平均実行時間は 0.0128 ms、使用しない場合の平均実行時間は 0.0359 ms となり、分枝限定法によってそれぞれ 66.7%、64.3% 計算にかかる時間が削減されることが確認された。よって、分枝限定法を用いることにより、すべての識別器の計算を行っていた場合と比較して、高速に顔認識が行えることが明らかとなった。

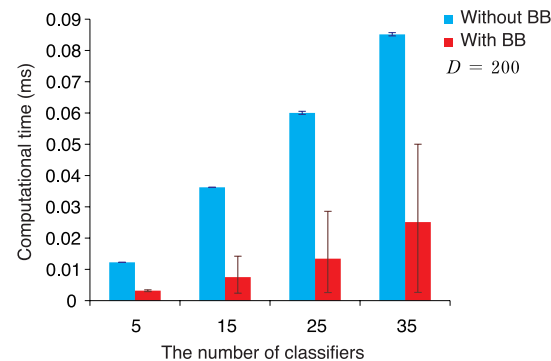


図 15 データベース (a) での用いた識別器の数と計算時間の関係。茶色と紺色の棒の端は、それぞれの計算時間の最大、最小を示す

Fig. 15 Relation between the number of face classifiers and computation time for face recognition in database (a). Bars denote the average computation time, while the top and bottom ends of the sticks represent the maximum and minimum computation times, respectively.




図 16 データベース (b) での用いた識別器の数と計算時間の関係。茶色と紺色の棒の端は、それぞれの計算時間の最大、最小を示す

Fig. 16 Relation between the number of face classifiers and computation time for face recognition in database (b). Bars denote the average computation time, while the top and bottom ends of the sticks represent the maximum and minimum computation times, respectively.

最後に、識別器の数の変化に対して計算時間がどのように変化するかを調べるため、識別器の数を変化させて認識木を構築し、計算時間を計測した。識別器の数の変化と認識にかかった計算時間の平均の関係を示すグラフを図 15, 図 16 に示す。分枝限定法を使用しな

い場合、つねに一定の探索処理を行うため、識別器の個数倍で実行時間が増加する。図 15, 16 より、データベース (a), (b) とともに分枝限定法を使用する場合、限定操作により、弱識別器の刈り込みにより計算コストが削減され、分枝限定法を使わない場合と比較して、実行時間の増加が緩やかである。よって、分枝限定法は識別する人数が増加した場合でも、従来の分枝限定法を用いない場合と比較して、計算コストを抑えながら認識を行うことが可能である。

5. おわりに

本論文では、分枝限定法を用いた高速な顔認識手法を提案した。個々の顔の識別に AdaBoost M1 アルゴリズムにより学習を行った識別器を用いた。この識別器は α_d^i を各識別器で正規化した γ_d^i の値を特徴量ごとに和をとった Γ_d をもとに特徴量を選択する。分枝限定法の限定操作では、子ノードの識別器の上限値を用いて、上限値が認識木の暫定最大値を超えない場合、弱識別器の計算を停止し、弱識別器の刈り込みを行った。また、分枝操作では、各識別器の出力の上限値 Γ^i で左からソートされるように認識木の子ノードを生成した。さらに、子ノードごとに、弱識別器を γ_d^i でソートした。これらの操作によって、限定操作の弱識別器の刈り込みを効率良く行うことが可能となった。

実験の結果、分枝限定法を利用することで、分枝限定法を利用しない場合と比較して、データベース (b) で平均 72.1% の弱識別器の計算の削減が可能となり、提案手法での顔認識の計算コストを大幅に削減できることが示された。また、認識処理の実行時間をデータベース (a) で平均 66.7% 削減でき、高速に顔認識できることが確認できた。


謝辞 本研究の一部は、科学研究補助金、課題番号 21-558 の助成を受けたものである。

参考文献

- 1) Otto, C., Milenkovic, A., Sanders, C. and Jovanov, E.: System Architecture of a Wireless Body Area Sensor Network for Ubiquitous Health Monitoring, *Journal of Mobile Multimedia*, Vol.1, No.4, pp.307–326 (2006).
- 2) Liarokapis, F., Sylaiou, S., Basu, A., Mourkoussis, N., White, M. and Lister, P.: An Interactive Visualisation Interface for Virtual Museums, *Proc. 5th International Symposium on Virtual Reality, Archaeology and Cultural Heritage*, pp.47–56 (2004).
- 3) 伊藤英明, 中西英之, 石田 亨: 超越型コミュニケーションを用いた位置に基づく遠隔指示の分析, *情報処理学会論文誌*, Vol.48, No.3, pp.1372–1380 (2007).
- 4) 中村仁彦, 岸 宏亮, 岡田昌史: 高速度カメラを用いた心拍動同期とそれを用いた心臓外科手術支援ロボットシステム, *日本ロボット学会誌*, Vol.21, No.4, pp.117–125

- (2003).
- 5) 植村充典, 猪口久仁, 上西 智, 金岡克弥, 川村真夫: 人間・アクチュエータ・機械的弾性要素の協調を用いたパワーアシストシステムの実験的検討, *日本ロボット学会誌*, Vol.25, No.6, pp.881–886 (2007).
- 6) Rusu, R.B., Gerkey, B. and Beetz, M.: Robots in the kitchen: Exploiting ubiquitous sensing and actuation, *Robotics and Autonomous Systems*, Vol.56, No.10, pp.844–856 (2008).
- 7) Obata, A. and Sasaki, K.: OfficeWalker: a virtual visiting system based on proxemics, *Proc. 1998 ACM Conference on Computer Supported Cooperative Work*, pp.1–10 (1998).
- 8) 松原孝志, 白杵正郎, 杉山公造, 西本一志: 言い訳オブジェクトとサイバー囲炉裏: 共有インフォーマル空間におけるコミュニケーションを誘発するメディアの提案, *情報処理学会論文誌*, Vol.44, No.12, pp.3174–3187 (2003).
- 9) Jouppe, N.P. and Thomas, S.: Telepresence Systems With Automatic Preservation of User Head Height, Local Rotation, and Remote Translation, *Proc. 2005 IEEE International Conference on Robotics and Automation*, pp.62–68 (2005).
- 10) Tee, K., Greenberg, S. and Gutwin, C.: Providing artifact awareness to a distributed group through screen sharing, *Proc. 2006 20th Anniversary Conference on Computer Supported Cooperative Work*, pp.99–108 (2006).
- 11) 中西英之, 野上大輔, 石黒 浩: テレロボビジョン: ネットワークカメラとロボットによるコミュニティ支援, *人工知能学会全国大会* (2007).
- 12) Pentland, A. and Choudhury, T.: Personalizing Smart Environments: Face Recognition for Human Interaction, *IEEE Computer*, Vol.33, No.2, pp.50–55 (1999).
- 13) Turk, M. and Pentland, A.: Eigenface for recognition, *Journal of Cognitive neuroscience*, Vol.3, No.1, pp.71–86 (1991).
- 14) Penev, P.S. and Atick, J.J.: Local feature analysis: A general statistical theory for object representation, *Network: Computation in Neural Systems*, Vol.7, No.3, pp.477–500 (1996).
- 15) Yang, J., Ahang, D., Frangi, A.F. and Yu Yang, J.: Two-dimensional PCA: A new approach to appearance-based face representation and recognition, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.26, No.1, pp.131–137 (2004).
- 16) Tan, K. and Chen, S.: Adaptively weighted sub-pattern PCA for face recognition, *Neurocomputing*, Vol.64, pp.505–511 (2005).
- 17) Belhumeur, P.N., Hespanha, J.P. and Kriegman, D.J.: Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.19, No.7, pp.711–720 (1997).
- 18) Wang, X. and Tang, X.: Random sampling LDA for face recognition, *Proc. 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*

- (*CVPR'04*), Vol.2, pp.259–265 (2004).
- 19) Marcel, S.: A symmetric transformation for LDA-based face verification, *Proc. 6th IEEE International Conference on Automatic Face and Gesture Recognition (FG'04)*, pp.207–212 (2004).
 - 20) Bartlett, M.S., Movellan, J.R. and Sejnowski, T.J.: Face recognition by independent component analysis, *IEEE Trans. Neural Networks*, Vol.13, No.6, pp.1450–1464 (2002).
 - 21) Kim, J., Choi, J., Yi, J. and Turk, M.: Effective representation using ICA for face recognition robust to local distortion and partial occlusion, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.27, No.12, pp.1977–1981 (2005).
 - 22) Fleming, M.K. and Cottell, G.W.: Categorization of faces using unsupervised feature extraction, *Proc. International Joint Conference on Neural Network (IJCNN 1990)*, San Diego, CA, USA, Vol.2, pp.17–21 (1990).
 - 23) Haddadnia, J. and Ahmadi, M.: N-feature neural network human face recognition, *Image and Vision Computing*, Vol.22, No.12, pp.1071–1082 (2004).
 - 24) Fan, J., Dimitriva, N. and Philomin, V.: Online face recognition system for videos based on modified probabilistic neural network, *Proc. 2004 International Conference on Image Processing (ICIP 2004)*, Singapore, Vol.3, pp.2019–2022 (2004).
 - 25) Er, M.J., Chen, W. and Wu, S.: High-speed face recognition based on discrete cosine transform and RBF neural network, *IEEE Trans. Neural Networks*, Vol.16, No.3, pp.679–691 (2005).
 - 26) Samaria, F. and Young, S.: HMM-based architecture for face identification, *Image and Vision Computing*, Vol.12, No.8, pp.537–543 (1994).
 - 27) Chen, L., Man, H. and Nefian, A.V.: Face recognition based on multi-class mapping of Fisher scores, *Pattern Recognition*, Vol.38, No.6, pp.799–811 (2005).
 - 28) Chien, J.-T. and Liao, C.-P.: Maximum confidence hidden Markov modeling for face recognition, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.30, No.4, pp.606–616 (2008).
 - 29) Pontil, M. and Verri, A.: Support vector machines for 3D object recognition, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.20, No.6, pp.638–646 (1998).
 - 30) Liu, Y.-H. and Chen, Y.-T.: Face recognition using total margin-based adaptive fuzzy support vector machines, *IEEE Trans. Neural Networks*, Vol.18, No.1, pp.178–192 (2007).
 - 31) Vatsa, M., Singh, R., Ross, A. and Noore, A.: Likelihood ratio in a SVM framework: fusion linear and non-linear face classifiers, *Proc. IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshop (CVPRW'08)*, Anchorage, pp.1–6 (2008).
 - 32) Hotta, K.: Robust face recognition under partial occlusion based on support vector machine with local Gaussian summation kernel, *Image and Vision Computing*, Vol.26, No.11, pp.1490–1498 (2008).
 - 33) Lampert, C.H., Blaschko, M.B. and Hofman, T.: Beyond Sliding Windows: Object Localization by Effective Subwindow Search, *Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2008)*, pp.1–8 (2008).
 - 34) Utsumi, Y., Iwai, Y. and Yachida, M.: Performance evaluation of face recognition in the wavelet domain, *Proc. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS'06)*, pp.3344–3351 (2006).
 - 35) Land, A.H. and Doig, A.G.: An automatic method of solving discrete programming problems, *Econometrica*, Vol.28, No.3, pp.497–520 (1960).
 - 36) Viola, P. and Jones, M.J.: Robust Real-Time Face Detection, *International Journal of Computer Vision*, Vol.57, No.2, pp.137–154 (2004).
 - 37) Georghiadis, A.S., Belhumeur, P.N. and Kriegman, D.J.: From Few to Many: Illumination Cone Models for Face Recognition under Variable Lighting and Pose, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.23, No.6, pp.643–660 (2001).
 - 38) Lee, K.-C., Ho, J. and Kriegman, D.: Acquiring Linear Subspaces for Face Recognition under Variable Lighting, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.27, No.5, pp.1–15 (2005).
 - 39) 内海ゆづ子, 岩井儀雄, 谷内田正彦: 顔認識のためのウェーブレット特徴量の評価, 知能と情報 (日本知能情報ファジィ学会誌), Vol.19, No.5, pp.467–487 (2007).
(平成 21 年 4 月 17 日受付)
(平成 21 年 11 月 6 日採録)



内海ゆづ子

平成 17 年大阪大学基礎工学部システム科学科中退。平成 19 年同大学大学院基礎工学研究科博士前期課程修了。現在、同大学院基礎工学研究科博士後期課程に在籍。平成 21 年より日本学術振興会特別研究員 (DC2)。パターン認識に興味を持ち、顔認識の研究に従事。IEEE, 人工知能学会各会員。



松本 雄大

平成 20 年大阪大学基礎工学部システム科学科卒業。現在，同大学大学院基礎工学研究科博士前期課程に在籍。顔認識に興味を持つ。



岩井 儀雄（正会員）

平成 4 年大阪大学基礎工学部情報工学科卒業。平成 6 年同大学大学院基礎工学研究科修士課程修了。平成 9 年同大学院基礎工学研究科博士課程修了。同年同大学院基礎工学研究科助手，平成 15 年同大学院基礎工学研究科助教授。平成 16～17 年英国ケンブリッジ大学にて客員研究員。コンピュータビジョン，パターン認識に関する研究に従事。IEEE，電子情報通信学会各会員。博士（工学）。