

顔位置検出と個人識別の並列化

平山 高嗣[†] 岩井 儀雄[†] 谷内田 正彦[†]

顔の形状モデルを用いて画像中から顔位置を検出する場合、最適なモデルが用いられなければ、その精度は低下する。我々は顔位置検出と並行して個人識別を行ない、最適なモデルを選択する手法を提案する。この手法は、クラスタリングによって階層化されたモデルデータベースを用いて個人識別を行なう。つまり、顔位置検出の処理が進むにつれ、その階層構造に従って最適なモデルを含むクラスタを選択していく。我々が既に提案した顔位置と大きさの並列推定法と融合し、顔の個人差と大きさの変化にロバストな顔位置検出システムを構築した。

Parallelization between Face Localization and Person Identification

TAKATSUGU HIRAYAMA,[†] YOSHIO IWAI[†] and MASAHIKO YACHIDA[†]

If the face is localized by using a geometrical model, the localization accuracy deteriorates unless the model is optimal for facial appearance. We propose a method that localizes face in parallel with person identification. The method identifies a person by using a hierarchical face model database. As the face localization proceeds, the method selects the optimal model according to the hierarchical structure. We merge the method into our method that estimates facial position in parallel with facial scale, and construct a face localization system robust for individual differences and facial scale variations.

1. はじめに

顔画像認識は、コンピュータビジョン研究の中で解決が困難な課題の一つである。それは、人間の顔がその姿勢や照明に代表される撮影条件の変化、表情や時間経過に伴う容貌の変化といったそれ自体の変形などによって、その見え方が様々に変化するためである。顔認識研究には、顔位置検出、顔器官（特徴点）検出、個人識別、表情認識、性別認識、年齢認識などがある。これらの中で、最も重要とされるのが顔位置検出である。なぜなら、その検出精度がその他の認識精度に影響を及ぼすからである。顔位置を正確に検出するためには、顔の見え方の変化を推定し、最適なモデルを用いなければならない。一般的には、この問題は様々な見え方のモデルを用意し、その全てを顔画像との照合に用いることで解決できる。しかし、多数のモデルを照合に用いれば、処理時間が増大する。顔認識が応用されるセキュリティシステムやヒューマンインターフェイスはリアルタイム性が要求されるため、この精度と処理時間のトレードオフを解決しなければならない。

我々はまず顔の大きさの変化に注目し、これまでに、この変化に対する上述のトレードオフを解決する手法を提案している¹⁾。我々の研究では、顔の表現に顔グラフ²⁾が用いられている。顔グラフのノードは、顔の特徴点に配置され、その位置情報と特徴点の周辺の画像濃淡情報を保持する。顔認識手法は一般に、幾何学的特徴ベースのタイプ³⁾⁴⁾⁵⁾とアピアランスベースのタイプ⁶⁾⁷⁾⁸⁾⁹⁾¹⁰⁾に大別されるが、顔グラフは両方のタイプを併合した顔の表現である。この表現は、最も有効とされる¹¹⁾。顔グラフを用いて顔の位置と大きさを推定する場合、位置が正確に推定されなければ、大きさも正確に推定されない。また、この逆も成り立つ。我々が提案した従来手法は、計算効率の良い顔位置の推定手法と顔の大きさの推定手法を交互に繰り返すことで、並列的に双方の推定精度を高めていくというものである。顔位置の推定には、ダイナミックリンクアーキテクチャ (DLA)¹²⁾の基本概念に基づく手法を、顔の大きさの推定には、スケール変換 (Scale Conversion)¹³⁾という統計的手法を適用している。この従来手法は、ラスタスキャンを用いた典型的な顔位置推定手法に対して、精度と計算効率の大幅な向上を果たした。しかし、この従来手法の推定結果に基づいた個人識別は、顔の大きさの変化に対して安定した精

[†] 大阪大学大学院基礎工学研究科
Graduate School of Engineering Science, Osaka University

度を示さなかった。我々は、顔の位置と大きさの推定精度が顔の大きさの変化に対してわずかに低下していることがその原因であると考えている。また、従来手法は、それらの推定を平均顔グラフだけで行なっていたため、顔の個人差がその低下に結び付いていると考えている。そこで、本研究では、顔の個人差の変化に対して顔位置の推定精度を高く保つ手法を開発することを目的とする。

本研究で提案する手法は、上述の顔の位置と大きさの並列推定と基本的な考えは同じである。顔グラフを用いて顔位置を推定する場合、最適な個人モデルが用いられなければ、その推定精度は低下する。我々は、顔位置推定と並行して個人識別を行ない、最適な個人モデルを選択する手法を提案する。この手法は、顔位置推定と個人識別を交互に繰り返すが、これを常に全ての個人モデルを用いて行なうことは非効率的である。そこで、クラスタリングによって階層化されたモデルデータベースを用いて個人識別を行なう。つまり、顔位置推定の処理が進むにつれ、その階層構造に従って最適なモデルを含むクラスタを選択していく。本稿では、まず、個人モデルデータベースの階層的クラスタリングについて述べる。次に、顔の位置と大きさの推定と、個人識別を並列化した手法について述べる。そして、この手法に基づき、顔の個人差と顔画像の大きさの変化にロバストな顔位置検出システムを構築し、評価実験によってその有効性を検証する。

2. 顔の表現

本研究では、目、唇、鼻といった顔の20個の特徴点上に配置されたノードを結ぶグラフによって顔を表現する。図1に顔グラフの例を示す。各ノードは対応する特徴点の位置におけるガボール特徴量を保持する。この特徴量は照明変動にロバストな特徴量で、ガボールウェーブレット変換によって求められる²⁾¹⁴⁾。ガボールウェーブレット変換は、画像とガボールカーネルの畳み込み演算によって行なわれる。本研究では、我々が開発したガボールカーネル¹³⁾を使用する。このカーネルは、顔の大きさに対してガボール特徴量を正規化することに対して優れた性能を持つ。また、この正規化により認識精度が向上し、計算コストが削減されることを我々は確認している

3. 個人モデルの階層的クラスタリング

本手法では、個人識別処理の効率化を図るために、個人モデルデータベースの構造を階層的クラスタリング¹⁵⁾によって階層化する。階層化されたモデルデー




図1 顔の表現 (黒色ノードのみ使用)

タベースは図2のような構造となる。階層的クラスタリングは、ボトムアップ手法とトップダウン手法がある。ボトムアップ手法は、 j 個の1要素クラスタから連続的にクラスタを融合し、各階層でのクラスタを形成していく。一方、トップダウン手法は、 j 個全ての要素を含む1個のクラスタから連続的にクラスタを分割していく。ボトムアップ手法で全ての要素を完全に融合するまでクラスタリングを続けた場合と、トップダウン手法で全ての要素を完全に分割するまでクラスタリングを続けた場合に構成される階層的クラスタは、融合と分割の評価が同じであれば同等となる。 j 個のクラスタを $k(\neq 1)$ 個のクラスタへと段階的に融合する場合にはボトムアップ手法が、1個のクラスタを $k(\neq j)$ 個のクラスタに段階的に分割する場合にはトップダウン手法が適用される。つまり、クラスタリングを途中で打ち切る場合には、適用する手法が異なる。本研究では、クラスタリングを途中で打ち切らないので、どちらの手法も適用することができるが、アルゴリズムがより簡単なボトムアップ手法を適用することにする。

次に、クラスタの融合の評価方法について述べる。まず、評価に用いる測度についてである。一般的には、クラスタリングは特徴空間のユークリッド距離を用いるが、本手法では顔グラフの類似度の計算にガボール特徴量の相関値を用いているので、それを評価の測度とする。式(1)に顔グラフ X と Y の相関関数を示す。式(1)の m は顔グラフのノードを表す。評価のアルゴリズムは、最近傍アルゴリズムと最遠傍アルゴリズムが代表的である。最近傍アルゴリズムは、クラスタ間の最大相関値がある閾値以上であればクラスタを融合する。これは単連結アルゴリズムとも呼ばれ、クラスタ内の要素が互いに必ずしも類似しない細長いクラスタを形成する可能性がある。一方、最遠傍アルゴリズムは、クラスタ間の最小相関値がある閾値以上であればクラスタを融合する。これは完全結合アルゴリズムとも呼ばれ、形成されたクラスタは、クラスタ内の要素が互いに閾値以上の類似度を持つことにな




図 2 階層的モデルデータベースの例

る．本手法では，クラスタ内の要素が互いに類似していることが望ましいので，最遠近傍アルゴリズムを利用してクラスタを形成する．階層構造は，本研究ではボトムアップ手法を利用するので，閾値を大きな値から徐々に小さくすることで構築できる．

$$R = \frac{1}{20} \cdot \frac{\sum_{m=1}^{20} X_m Y_m}{\sqrt{\sum_{m=1}^{20} X_m^2 \sum_{m=1}^{20} Y_m^2}}. \quad (1)$$

個人識別は，このように構築された階層構造を上位階層からたどることで行なう．そのためには，各クラスタの代表データを定義しなければならない．本研究では，クラスタ内の要素が互いに類似していることから，代表データをクラスタ中心とする．これは，個人モデルグラフが持つガボール特徴量の平均から求められる，我々はこれをクラスタ平均モデルグラフと呼ぶ．このグラフが顔の位置と大きさを推定するための参照モデルグラフとなる．

4. 顔位置検出と個人識別の並列化

4.1 提案手法の概要

提案手法の概略を図 3 に示す．本手法は，大域探索による位置推定，局所探索による位置推定，推定位置と大きさの検証，スケール変換，個人識別の 5 つの状態から構成され，これらの遷移の繰り返しによって顔の位置と大きさの推定と，個人識別を行なう．大域探索による位置推定は顔の位置を小さな計算コストで推定することができる．しかし，その反面，安定した推定を行なえない．そこで，次にこの推定位置を中心に局所的に詳細な探索を行なう手法を適用する．その手法が局所探索による位置推定である．この推定法は，大域探索によるものより大きな計算コストを要するが，より正確な推定を行なえる．検証状態は推定した位置と大きさで生成された顔グラフの妥当性を検証する．スケール変換は我々が開発した手法で，顔の大きさを推定する．この手法は，他の顔の大きさ推定の手法より計算効率が良い．そして，個人識別は階層化されたモデルデータベースと優先度付き待ち行列を用いて行

なう．本手法は，この待ち行列の上位に存在する顔グラフの位置と大きさを更新し，その顔グラフが参照するクラスタ平均モデルグラフから階層構造をたどって最適なモデルを選択していくという処理を繰り返す．

5 つの状態のそれぞれについてと，各状態間の遷移について次節より詳しく順に述べる．

4.2 大域探索による位置推定

大域探索による位置推定は，ダイナミックリンクアーキテクチャ (DLA)¹²⁾ の基本概念に基づく．まず，画像全体に d_G 画素間隔で矩形格子状に $n_G \times n_G$ 個のサンプリング点を配置し，それらの点上からガボール特徴量を抽出する．そして，参照モデルグラフの各ノードに対して次の特徴量類似度 ϕ_{ml} を計算する．

$$\phi_{ml} = 1 - \|V_m - D_l\|, \quad (2)$$

$$m = 1, \dots, 20,$$

$$l = 1, \dots, n_G^2.$$

この類似度を局所特徴量類似度と呼ぶことにする．ここで， D_l はサンプリング点 l のガボール特徴量， V_m は参照モデルグラフのノード m のそれである．また，この参照モデルグラフは，最上位階層のクラスタ平均モデルグラフ，つまり，全ての個人モデルグラフの平均グラフである．位置の推定は，最も局所特徴量類似度が高いサンプリング点 l を探索し (図 4)，ノード m がその点 l と一致するように参照モデルグラフを配置することによって行なわれる．この一連の処理が参照モデルグラフの全てのノードに対して行なわれる．ゆえに，大域探索による位置推定は m 個の推定を行なう．

4.3 推定した位置と大きさの検証

推定した顔の位置と大きさの検証は，大域特徴量類似度 π を用いて行なう．顔の大きさの推定を行なうスケール変換については 4.4 節で示す．

$$\pi(G(x, y, s_{opt})) = \frac{1}{20} \cdot \frac{\sum_{m=1}^{20} V_m W_m(G(x, y, s_{opt}))}{\sqrt{\sum_{m=1}^{20} V_m^2 \sum_{m=1}^{20} W_m(G(x, y, s_{opt}))^2}}. \quad (3)$$

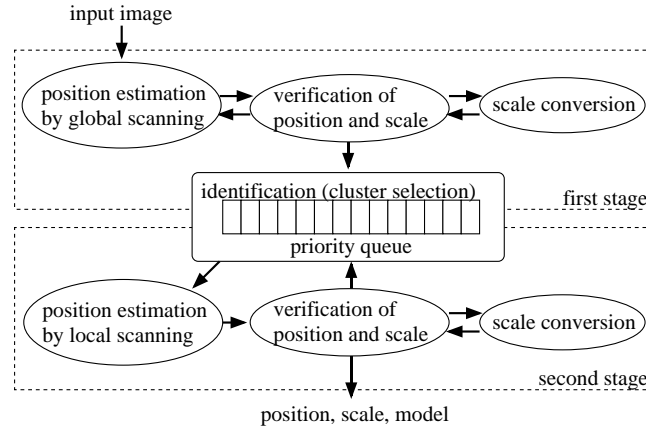


図 3 提案手法の状態遷移




図 4 大域探索による位置推定

ここで、 $G(x, y, s_{opt})$ は参照モデルグラフから生成されたシャドウグラフ G である。シャドウグラフは推定された位置 (x, y) と大きさ (s_{opt}) を持つ。また、 W_m はシャドウグラフのガボール特徴量である。このシャドウグラフが個人識別状態へ入力される。

4.4 スケール変換

スケール変換は顔グラフを入力画像に対して適切な大きさに効率的に伸縮させる役割を果たす。これには、スケール辞書というデータベースを利用する。スケール辞書はあらかじめシステム構築時に作成される。

まず、スケール辞書の生成について説明する。顔の大きさが平均グラフとほぼ等しい N_t 枚の教師顔画像を用意する。この平均グラフは全ての個人モデルグラフから生成されたものである。次に、平均グラフを伸縮率 s_T で T 段階に伸縮させたグラフを、各教師顔画像の顔位置 (x_{true}, y_{true}) に配置する。このグラフの妥当性は大域特徴量類似度 π によって求められる。つまり、式 (3) の V_m を平均グラフのガボール特徴量、 W_m を伸縮グラフのそれとして求められる。次に、この大域特徴量類似度がスケール辞書と呼ばれるデータベースに学習データとして登録される。

グラフの適切な大きさへの伸縮は、この辞書を用いて行われる。まず、検証状態から遷移してきたシャ

ドウグラフ G のガボール特徴量を抽出する。そして、大域特徴量類似度を求め、スケール辞書の学習データと比較する。比較は教師顔画像ごとに行ない、最も誤差の小さい学習データをそれぞれ検出し、そのデータに対応した平均グラフの伸縮率 r_i を導き出す。

$$r_i = \arg \min_{s_T} [\pi(G(x, y, s_{opt})) - \pi(G_{ave}(x_{true}, y_{true}, s_T))] \quad (4)$$

for each training image,

$$i = 1, \dots, N_t, \quad T = 1, \dots, T.$$

ここで、式 (4) の $\pi(G_{ave}(x_{true}, y_{true}, s_T))$ はスケール辞書の学習データである。次に、全ての教師顔画像から求めた r_i のヒストグラムを生成する。このヒストグラムから求まる r_i の確率分布に従い、入力画像に対するグラフの大きさの比率 t_{new} を推定する。シャドウグラフの適切な大きさへの伸縮は、 t_{new} によって更新された伸縮率 s_{opt} を求めて行なわれる ($s_{opt} \leftarrow s_{opt} \times s_{new} (s_{new} = 1/t_{new})$)。また、伸縮率 s_{opt} は、画像から抽出されるガボール特徴量を顔の大きさに対して正規化するために用いられる。図 5 にスケール変換の処理の流れを示す。

4.5 個人識別

個人識別は、検証状態から遷移してきたシャドウグラフ G がどのクラスタに属するかを判定する。シャドウグラフが参照するクラスタ平均モデルグラフが、レベル L の階層のあるクラスタの代表とする。個人識別は、このクラスタに属する下位階層 ($L+1$) の全てのクラスタ平均モデルグラフとシャドウグラフの照合を行なう。照合には大域特徴量類似度 π を用いる。つまり、式 (3) の V_m をクラスタ平均モデルグラフのガボール特徴量とする。そして、照合後の全てのシャドウグラフをその大域特徴量類似度を優先度として優

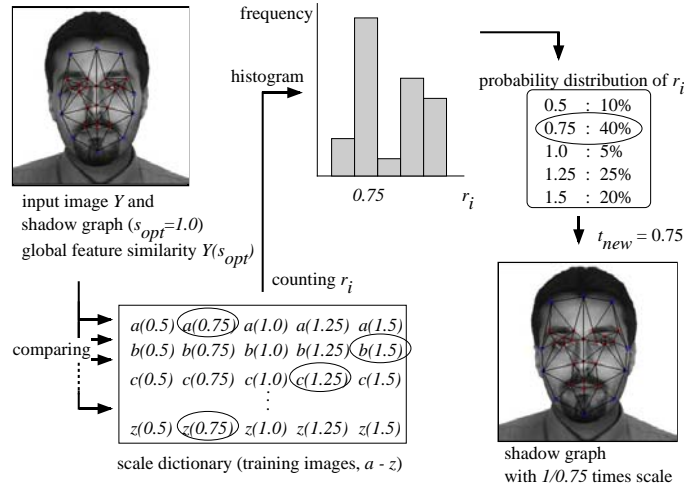


図 5 スケール変換

先度付き待ち行列に格納する．この際、シャドウグラフの参照モデルグラフを、照合に用いたそれぞれのクラスタ平均モデルグラフに変更する．最終的には、優先度付き待ち行列の最上位に存在するシャドウグラフの参照モデルグラフが個人識別の結果となる．

4.6 局所探索による位置推定

局所探索による位置推定も、DLA の基本概念に基づく．この推定法は、大域探索による位置推定と類似するが、探索領域の大きさと局所特徴量類似度の計算に用いられるガボール特徴量の数に関してそれと異なる．

まず、優先度付き待ち行列から取り出されたシャドウグラフが持つ推定位置のまわりに、 $d_L \times s_{opt}$ 画素間隔で矩形格子状に $n_L \times n_L (< n_G \times n_G)$ 個のサンプリング点を配置する．状態遷移の初期には、 $d_L \times s_{opt} \times n_L$ は顔の大きさとほぼ等しくなる．なお、状態遷移の過程でサンプリング点が同じ位置に配置されることを防ぐために、 d_L を単調減少させる．次に、シャドウグラフが参照するクラスタ平均モデルグラフのノード m に対して式 (5) の局所特徴量類似度が計算される．

$$\phi_{ml} = 1 - \|V_m - D_l(s_{opt})\|, \quad (5)$$

$$m = 1, \dots, 20,$$

$$l = 1, \dots, n_L^2.$$

この式はガボール特徴量が顔の大きさと正規化される点で式 (2) と異なる．そして、最も高い局所特徴量類似度を持つ点 l を探索し、参照モデルグラフをそのノード m が点 l と一致するように移動させる．それから、その移動されたグラフ上で n_D 個のガボール特徴量 (R_n) を抽出する (図 6)．図 6 中の白色ノードは n_D 個のガボール特徴量を抽出するためのサンプリング




図 6 局所探索による位置推定

点の例である．そして、次の式で表される局所特徴量類似度の合計 ψ を計算する．

$$\psi = \phi_{ml} + \sum_{n=1}^{n_D} [1 - \|V_n - R_n(s_{opt})\|]. \quad (6)$$

この一連の処理が参照モデルグラフの全てのノードに適用され、最も高い ψ を持つグラフの位置を局所探索による位置推定の結果とする．

4.7 状態遷移

前節までに示したそれぞれの処理の遷移について述べる．図 3 に示すように、本手法は 2 つのステージで構成される．第 1 ステージでは、大域探索による位置推定とスケール変換が、検証状態を介して交互に行なわれる．第 2 ステージは第 1 ステージに類似するが、局所探索による位置推定が大域探索による位置推定の代わりに行なわれる．それぞれのステージにおいて、スケール変換への遷移は、検証時に求まる大域特徴量類似度がスケール辞書の学習データの範囲内となった時に行なわれる．なお、終了状態への遷移は、個人識別が階層的クラスタの最下位層まで進み、かつ大域特徴量類似度がある閾値を越えた場

合に起こる。

本手法では、顔の位置と大きさの推定と個人識別の精度を向上させるために、ビーム探索¹⁶⁾によってこれらの更新を行なう。我々は、優先度付き待ち行列を利用してこれを実現する。つまり、この待ち行列から優先度の高いシャドウグラフを c 個選択し、それぞれから並列的にさらなる推定と個人識別を行なう。そして、これを繰り返す。ビーム探索は計算効率が c の数に依存するが、 c 個からの更新はそれぞれ独立に行なうことができるため、 c 個のプロセスに負荷分散させるという並列処理に展開することが可能である。すなわち、この並列処理により、顔認識の精度と処理時間のトレードオフの解決が期待できる。

5. 評価実験

5.1 実験環境

提案手法の有効性を検証するために実験システムを構築し、評価実験を行なった。比較に用いるシステムは、我々が提案した2つの従来システム¹⁾である。従来システム1は、5画素間隔のラスタスキャンによって顔位置を検出し、その後スケール変換によって顔の大きさを推定する。そして我々が開発したフレキシブル特徴照合法を用いて顔の特徴点を抽出し、その特徴量とモデルデータベースとの比較により個人識別を行なうというシステムである。一方、従来システム2は、顔の位置と大きさの並列推定法とフレキシブル特徴照合法を経て、個人識別を行なう。それぞれのシステムの実装はSGI製ワークステーション Origin300 (8CPU R14000, 500 MHz, memory 4 GB, OS IRIX6.5.16m) 上で行なった。画像はPurdue大学のAR Face データベース¹⁷⁾のもの (256 × 256 画素, 8bit 濃淡) を利用した。個人モデルデータベースには、ほぼ等しい大きさの50人の顔画像とそれぞれのモデルグラフが登録されている。画像は1人につき1枚で、全てが無表情の正面顔である。ただし、眼鏡をかけた画像や照明変動のある画像も含まれる。モデルグラフの特徴点は我々が目視によって画像中で定義した。ガボールウェーブレット変換は2つの大きさと8方向のカーネルを用いて行なわれた。提案システムで用いられるパラメータは以下のように設定された: $n_G = 12, d_G = 20, n_L = 5, d_L = 30, n_D = 2, N_t = 20, T = 11, s_T = 0.5 \sim 1.5$ (0.1 刻み), $c = 5$ 。また、 n_D 個のガボール特徴量は目の位置から抽出された。なお、従来システム2のパラメータ c は提案システムと異なり、 $c = 10$ とした。テスト画像は、モデルデータベースに登録された人物のモデル画像、登録さ




図7 構成された階層的クラスタ

れていない人物の画像がそれぞれ50枚 (テストセット100%) と、それらを80%と120%に伸縮した画像 (テストセット80%, 120%) の計300枚とした。画像の伸縮はMacOS X上でAdobe Photoshop7.0を用いてbi-cubic内挿法で行なわれた。

5.2 構成された階層的クラスタ

本研究では、階層的クラスタリングを行なうために設定する相関値の閾値を0.9から0.02刻みで減少させた。個人モデルグラフ間の相関値の最大は0.92、最小は0.78であった。構成された階層的クラスタを図7に示す。図中の楕円と円はクラスタを表す。数字はクラスタ内の要素 (個人モデルグラフ) の数である。この階層的クラスタはレベル数が8、最大分岐数が8である。我々がこの階層的クラスタから得る見解は、本研究で用いた個人モデルデータベースの特徴量空間は、いくつかの大きなクラスタに分割できるような分布ではなく、正規分布のような分布をしているということである。

5.3 位置と大きさの推定精度

図8に提案システムを用いて顔位置と大きさを推定した結果を示す。この結果から、顔位置と大きさが変化した画像だけでなく、照明が眼鏡に反射し、目が隠れている顔画像 (右中, 左下) や照明条件の異なる顔画像 (右下) に対しても顔位置と大きさの推定が正しく行なわれていることがわかる。また、個人識別によって最適なモデルグラフを選択しているため、正確に特徴点を検出できていることもわかる。

表1にテストセット100%, 80%, 120%に関して推定位置と真値の誤差, 推定した大きさ, 計算コストを求めた結果を示す。計算コストはガボールウェーブレット変換を行なったノードの数である。なお、従来システムの計算コストにフレキシブル特徴照合法で費された計算コストは含まれない。この表から、提案システムは、顔位置と大きさの推定精度に関して、2つの従来システムより向上し、真値に近い値を得たこと

表 1 顔の位置と大きさの推定の精度と計算コスト

| system | test set | position error (pixel) | estimated scale (%) | cost |
|-----------|----------|------------------------|---------------------|-------|
| proposed | 100% | 1.36 | 100+1.5 | 6024 |
| | 80% | 1.72 | 80+2.4 | 5831 |
| | 120% | 2.37 | 120+2.9 | 6252 |
| previous1 | 100% | 3.14 | 100+1.6 | 52080 |
| | 80% | 7.52 | 80+4.2 | 52080 |
| | 120% | 19.5 | 120+10 | 52080 |
| previous2 | 100% | 4.66 | 100+1.4 | 628 |
| | 80% | 4.09 | 80+7.4 | 1141 |
| | 120% | 7.97 | 120+7.7 | 714 |

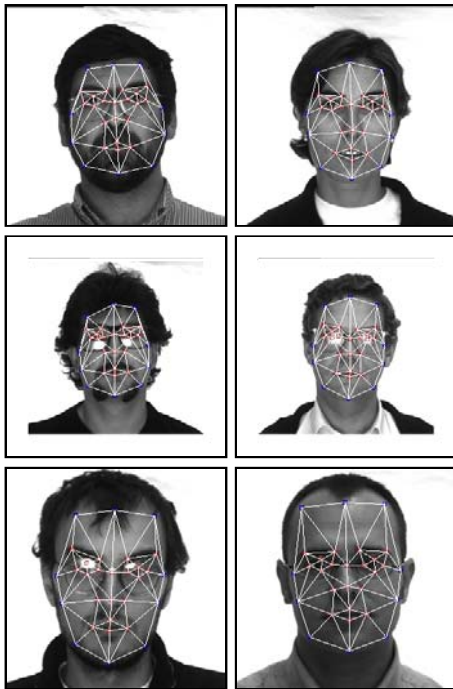


図 8 実験結果

がわかる．計算コストに関しては，従来システム 1 よりは軽減されたが，従来システム 2 より大きくなった．ゆえに，精度と効率のトレードオフは十分には解決されていないといえる．しかし，従来システムの推定精度を提案システム程度にまで向上させるには，全ての個人モデルを用いることになると考えられる．この場合の計算コストは提案システムより大きくなる．なお，提案システムと従来システム 2 は， c 個のプロセッサを用いて並列処理を行なうことができる．本実験では $c = 10$ としているので，提案システムの計算コストは，表中の値よりさらに 1/10 程度の軽減が可能である．なお，本実験では，1 個のノードに対してガボールウェーブレット変換を施すのにかかる処理時間は約 6 ミリ秒であった．

5.4 個人識別の精度

認識率は，モデルデータベースに登録されている人

物の顔画像を入力した場合はその人物の同定成功率であり，未登録の人物の顔画像を入力した場合は，モデルデータベースに登録されていない人物であるとシステムが判定した割合である．図 9 に 3 つの実験システムの認識率を示す．この図は，提案システムでは，終了状態への遷移の判定基準の閾値を変化させ，従来システムでは，個人識別処理で設定する必要がある閾値を変化させ，それに対する認識率を ROC 曲線の形で表したものである．この曲線はグラフの右上に位置するほど，その精度が良いといえる．従って，テストセット 80%，100%，120% 全てに対して，提案システムの精度向上が確認できる．

提案システムの問題点としては，データベースに登録される個人モデルが増加した場合に，1 つのクラスタから分岐するクラスタ数も増加するという点である．この場合，本実験結果の精度を維持するためには，ビーム探索の c を大きくしなければならない可能性がある．我々は，登録人物を増やして提案システムの性能を検証しなければならない．

6. おわりに

本稿では，顔の位置検出と個人識別を並列的に効率良く行なう手法を提案した．提案手法は，大域探索による位置推定，局所探索による位置推定，顔の大きさを推定するスケール変換，推定された位置と大きさの検証，個人識別の 5 状態の遷移をビーム探索によって繰り返す．効率的な個人識別を行なうために，階層的クラスタリングによって個人モデルデータベースの構造を階層化した．我々は顔認識実験によって提案システムの性能を評価し，顔位置の検出と個人識別の並列化が顔認識の精度と計算効率のトレードオフを解決できるという着目点の正しさも実証した．

今後の課題としては，個人モデルデータベースの大きさによって提案システムの性能がどう変化するかを検証することや，表情などの撮影条件がモデル画像と異なるテスト画像に対して評価実験を行なうこと，そして我々が提案している従来システム以外との比較を




図 9 個人識別率

行なうことなどが挙げられる。

謝辞 本論文で述べた研究の一部は日本学術振興会 未来開拓研究推進事業「感性的ヒューマンインタフェース」(プロジェクト番号 JSPS-RFTF99P01404) の援助を受けた。

参考文献

- 1) T. Hirayama, Y. Iwai and M. Yachida: Face recognition system using accurate and rapid estimation of facial position and scale, *Proceedings of the 4th International Conference on AUDIO- and VIDEO-BASED BIOMETRIC PERSON AUTHENTICATION*, (2003)(in press).
- 2) L. Wiskott, J. M. Fellous, N. Krüger and C. von der Malsburg: Face recognition by Elastic Bunch Graph Matching, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol.19, No. 7, pp. 775–779 (1997).
- 3) R. Brunelli and T. Poggio: Face recognition through geometrical features, *Proceedings of the 2nd European Conference on Computer Vision*, pp. 792–800 (1992).
- 4) A. Lanitis, C. J. Taylor and T. F. Cootes: Automatic interpretation and coding of face images using flexible models, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 19, No. 7, pp. 743–756 (1997).
- 5) K. C. Yow and R. Cipolla: Enhancing human face detection using motion and active contours, *Proceedings of the 3rd Asian Conference on Computer Vision*, pp. 515–522 (1998).
- 6) M. Turk and A. Pentland: Eigenface for recognition, *Journal of Cognitive Neuroscience*, Vol. 3, No. 1, pp. 71–86 (1991).
- 7) H. Rowley, S. Baluja and T. Kanade: Neural network-based face detection, *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pp. 203–208 (1996).
- 8) P. Penev and J. Atick: Local feature analysis: A general statistical theory for object representation, *Neural Systems*, Vol. 7, No. 3, pp. 477–500 (1996).
- 9) P. Belhumeur, J. Hespanha and D. Kriegman: Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 19, No. 7, pp. 711–720 (1997).
- 10) P. Viola and M. Jones: Rapid object detection using a boosted cascade of simple features, *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pp. 511–518 (2001).
- 11) O. Ayinde and Y.-H. Yang: Face recognition approach based on rank correlation of Gabor-filtered images, *Pattern Recognition*, Vol. 35, pp. 1275–1289 (2002).
- 12) M. Lades, J. C. Vorbrüggen, J. Buhmann, J. Lange, C. von der Malsburg, R. P. Würtz and W. Konen: Distortion invariant object recognition in the Dynamic Link Architecture, *IEEE Trans. on Computers*, Vol. 42, pp. 300–311 (1993).
- 13) 平山 高嗣, 岩井 儀雄, 谷内田 正彦: 顔の大きさの変化にロバストな個人識別システム, *情報処理学会論文誌*, Vol. 44, No. 6 (2003)(in press).
- 14) J. G. Daugman: Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters, *Journal of the Optical Society of America A*, Vol. 2, pp. 1160–1169 (1985).
- 15) R. O. Duda, P. E. Hart and D. G. Stork: *Pattern classification*, Wiley-Interscience (2001).
- 16) A. Barr and E. A. Feigenbaum: *The Handbook of Artificial Intelligence*, Addison-Wesley, Menlo Park, CA (1981).
- 17) A. M. Martinez and R. Benavente: The AR face database, CVC Technical Report24 (1998).