

学習画像の選択に基づく AAM の繰り返し適応

高柳 陽平[†] 滝口 哲也^{††} 有木 康雄^{††}

[†] 神戸大学大学院システム情報学研究科 〒657-8501 兵庫県神戸市灘区六甲台町 1-1

^{††} 神戸大学自然科学系先端融合研究環 〒657-8501 兵庫県神戸市灘区六甲台町 1-1

E-mail: [†]takayanagi@me.cs.scitec.kobe-u.ac.jp, ^{††}{takigu,ariki}@kobe-u.ac.jp

あらまし 顔特徴点の取得法として、顔を追跡する方法として適している Active Appearance Model(AAM) がある。しかし、AAM によって、未知人物を追跡しようとする時、学習データを過剰に用いると、個人の特徴が失われ、多くの局所解が生まれてしまい、追跡精度が低下してしまうので、現状では学習済みの人物でない顔特徴点を正確に取得できないといった問題がある。そこで本研究では、この問題を解決するため、学習データを人物ごとに分けておき、未知人物に対して学習人物との類似度を、Gaussian Mixture Models(GMM) によって求める。この類似度に応じて、学習人物毎に学習データの枚数を決定し、こうして集められた学習データを基に AAM を構築して特徴点を得る。更に得られた特徴点に対して学習データとの類似度によって、繰り返し AAM を構築することで、未知人物に対して特徴点を取得する方法を提案する。学習画像の選択に基づく AAM の繰り返し適応の評価のために、被験者 10 人分の画像データと、テストデータとなる人物 10 人の画像を動画を撮影したものから切り出し、テストデータとなる人物の画像には、AAM を構築する為に手動で特徴点を付与した。これらを用いて顔特徴点の取得を行った。提案手法により得られた特徴点と、未知人物に手動で特徴点を与えた正解特徴点とのユークリッド距離を計算し、これを精度として様々な手法と比較した。この結果、提案手法が有効であることが確認された。

キーワード Active Appearance Model, Gaussian Mixture Models, 顔追跡

1. はじめに

近年、コンピュータビジョンの分野の研究が進歩し、顔認証や表情認識、視線認識など、画像から得られる情報を認識する技術は、我々の身近なところまで浸透するようになってきている。例として、空港における顔画像や目画像における個人認証 [1, 2]、読唇技術による雑音環境下での音声認識 [3, 4]、視線情報によるインターフェイスのツール [5] など、様々な分野で研究が進んでいる。顔画像認識するために、顔特徴点を取得する方法として近年よく使用されているのが、T. F. Cootes らによって提案された Active Appearance Models (AAM) [6, 7, 8, 9] である。これは顔の形状とテクスチャの変化を学習データから構造化する手法で、その構造と勾配法によってテスト画像中の顔の形状を抽出するため、非常に精度がよい。しかし、AAM はモデルの構築を学習データからのみ行うため、学習データ中の人物とテストデータの人物が異なる場合、つまりテストデータが未知人物の場合は、テスト画像中の顔の形状を高精度に抽出できない問題がある。

このことは、Ralph Gross らが行った実験 [10] から明らかである。またこの論文の中で、人物の変動、照明の変動、顔方向の変動のうち、人物による変動が最も精度に悪影響を及ぼすということが主張されている。それに加え、AAM の学習データとして画像に特徴点を手動で与える作業が必要であり、これは非常に時間的コスト

がかかる。そのため、未知人物の画像中の顔位置を正確に探索するために、実用的な場面において学習データを収集し、未知人物専用の AAM を構築することは、事実上不可能であると言える。

そこで学習人物のデータから、ある未知人物に適した AAM を構築し、未知人物に対しても、顔の形状を高精度に抽出することが出来れば、このことは非常に有用であると言える。

本研究では顔の追跡や認識に広く用いられている AAM を未知人物にも適応可能なレベルまで精度を上げるために、学習データを人物ごとに分けておき、未学習人物に対しての学習人物との類似度を、Gaussian Mixture Models によって求め類似度を得て、その類似度を用いて、学習人物毎に学習データの枚数を決定する手法を提案する。また、得られた特徴点に対しての学習データとの類似度によって、繰り返し AAM を構築することで、より未知人物に対して精度の高い特徴点取得方法を提案する。

1.1 本論文の構成

本論文の構成について述べる。2 章では、ベースとなる従来手法の概要を述べる。3 章では、提案手法について述べる。4 章で、実験を行い、最後に 5 章で、本研究の結果をまとめ、今後の課題についても述べる。

2. ベースとなる従来手法

2.1 AdaBoost による顔領域の検出

提案手法では、入力画像に対して顔領域を抽出するアルゴリズムとして、Viola らによって提案された、Haar-like 特徴量と AdaBoost による顔領域検出の手法 [11, 12] を利用する。AAM による特徴点探索において、AAM の初期探索点によって精度が大きく変わるので、AdaBoost による顔領域検出をすることにより、特徴点がより正確に探索可能となる。

2.2 Haar-like 特徴量

Haar-like 特徴量とは隣り合う矩形領域の平均輝度差として求められる特徴量である。Viola らは顔検出に適した 4 種類の Haar 型の矩形フィルタを提案した。この 4 種類の矩形について、縦横比、スケール、位置を変化させたものを複数作成し、それらを AdaBoost の弱識別器として学習し、線形結合することで強識別器を構成し顔領域を検出する。

2.3 Active Appearance Models

Active Appearance Models は、T. F. Cootes らによって提案された顔をモデル化する手法であり、顔特徴点探索や、顔の形状やテクスチャの状態を推定するために用いられる。shape と呼ばれる特徴点の形状と、texture と呼ばれる特徴点の変動量に主成分分析 [13, 14] を行い、部分空間を構成することによって、低次元のパラメータで人間の顔らしさを保ちつつ顔の変化を表現することが出来る。また、構成した部分空間内で、入力画像に最も近いパラメータを決定し、そのパラメータを用いて、モデルより再構築された画像と入力画像をフィッティングすることで顔特徴点の抽出を行う。

本研究では、特徴点の位置こそがもっとも人間の類似性を表すものと考え、shape を用いることで未知人物と学習人物との類似度を計算する。

AAM による顔モデルの構築では、顔画像の各特徴点座標を並べたベクトル s を Shape ベクトルとして用いる。本論文では、この特徴点を 64 点として、図 1 のように与える。

2.3.1 AAM によるモデルの構築

s は、式 (1) で与えられる。

$$s = (x_1, y_1, x_2, y_2, \dots, x_n, y_n)^T, n = 64 \quad (1)$$

また、すべての学習画像の Shape ベクトルを平均して得られる \bar{s} を平均 Shape ベクトルと呼ぶ。 s は \bar{s} からの偏差を主成分分析して得られる固有ベクトル行列 P_s を用いて、

$$s = \bar{s} + P_s b_s \quad (2)$$

と表すことが出来る。ここで、主成分分析の係数 b_s は、

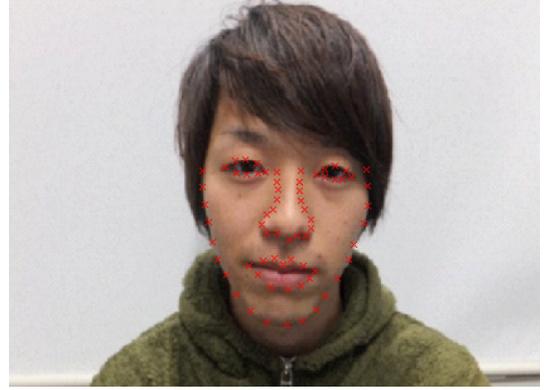


図 1 特徴点の例

部分空間内で平均 shape からの変化を表すパラメータであり、Shape パラメータと呼ぶ。次に、全ての学習画像を平均形状に正規化し、平均形状内に含まれる画素の輝度値 $g_j (j \leq m)$ を並べた texture ベクトル g を式 (3) のように定義する。

$$g = (g_1, g_2, \dots, g_m)^T \quad (3)$$

g についても s と同様に、それらを平均した平均輝度値 \bar{g} からの偏差を主成分分析することで得られる固有ベクトル行列 P_g を用いて、

$$g = \bar{g} + P_g b_g \quad (4)$$

と表すことが出来る。ここで、主成分分析の係数 b_g は、部分空間内で平均 texture からの変化を表すパラメータであり、Texture パラメータと呼ぶ。

また、位置とテクスチャには相関があることから、 \bar{s} 、 \bar{g} をさらに主成分分析し、式 (5) のように表現する。

$$b = \begin{pmatrix} W_s b_s \\ b_g \end{pmatrix} = \begin{pmatrix} W_s P_s^T (s - \bar{s}) \\ P_g^T (g - \bar{g}) \end{pmatrix} = Qc \quad (5)$$

ここで、 W_s は Shape ベクトルと Texture ベクトルの単位の違いを正規化する行列、 Q は主成分分析によって得られた固有ベクトル行列、 c は shape と texture 両方を制御するパラメータで、Combined パラメータと呼ぶ。

$$s(c) = \bar{s} + P_s W_s^T Q_s c \quad (6)$$

$$g(c) = \bar{g} + P_g Q_g c \quad (7)$$

ただし、

$$Q = \begin{pmatrix} Q_s \\ Q_g \end{pmatrix} \quad (8)$$

2.3.2 AAM による探索

本節では、テスト画像が与えられた時に、学習した AAM を用いて、テスト画像に最も良く似ている画像を生成する Combined パラメータベクトル c を決定し、特徴量を抽出する方法について述べる。入力画像をア

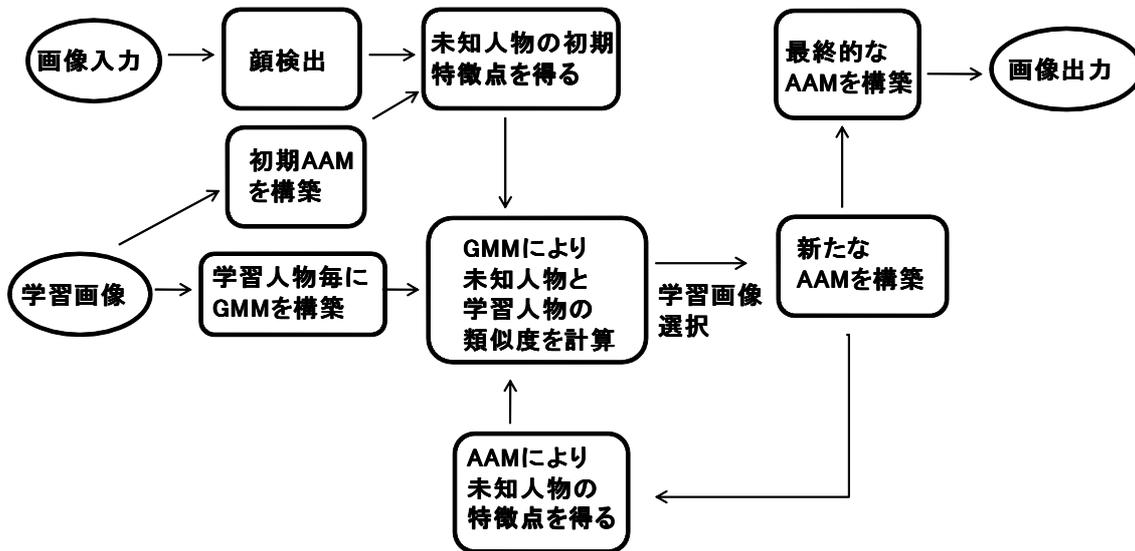


図 2 提案手法の流れ

フィン変換させて得られる画像を $I(W(p))$ とする。ただし、 p はアフィン変換をする為の拡大縮小、回転、平行移動に関するパラメータで、Pose ベクトルと呼ばれ、式 (9) で表される。

$$p = (\text{scale } \text{rotation } t_x \ t_y) \quad (9)$$

scale は、顔画像の拡大縮小に関するパラメータであり、 rotation は二次元画像平面上での回転移動に関するアフィン変換のパラメータである。 t_x, t_y は平行移動に関するアフィン変換のパラメータである。また、 W はアフィン変換を施す関数であり、最適な Combined パラメータ c と Pose パラメータ p を決定する為に、式 (10) で表される。つまり、モデル $g(c)$ と入力画像のアフィン変換後の画像 $I(W(p))$ との差分が最小となるように、最急降下法を用いて計算を行うということである。

$$\|g(c) - I(W(p))\| \quad (10)$$

ただし、 $g(c)$ は、式 (7) に示した Texture ベクトルである。このようにして、入力画像から最適な Combined パラメータが決定される。

3. 提案手法

3.1 提案手法の概要

図 2 に全体の簡単な流れを示す。データベースには 10 人の学習データがそれぞれ 100 枚ずつ用意されている。各画像には AAM 構築用に、手動で特徴点が付与されている。

最初に、未知人物入力画像に対して Haar-like 特徴を用いた AdaBoost 法による顔領域検出を行う。次に検出した顔領域に対して、学習人物 10 名から平均的に 2 枚ずつ集めた 20 枚の画像を用いて、不特定人物の AAM を構築することで未知人物の初期特徴点を得る。この初期特徴点は今後の精度に大きく関わる。このことについ

ては、4.3 節で実験を行い、適切な枚数を求めた。

次に、各学習人物ごとに、手動で与えた特徴点をもとに GMM を構成しておき、先ほどの未知人物の初期特徴点と各学習人物の GMM との類似度を求める。そして、その類似度を考慮して、学習人物から画像の枚数を選択し、未知人物に、より適した AAM を構成する。この時、画像の合計学習枚数は 30 枚とする。この 30 枚という値も実験によって、1 枚から 100 枚のうち、最適なものを選んだ。

この AAM により得られた新たな特徴点を用いて再度、各人物との類似度を同様の手順で求める。これを繰り返すことにより、最終的に、より精度の高い未知人物の顔特徴点の取得を目指す。この論文の新規提案手法として、AAM によるモデルの再構築や、GMM による類似度を用いた AAM の構築が挙げられる。

3.2 Gaussian Mixture Models を用いた類似度による Active Appearance Models の構築

本論文では AAM を構築する時のモデル選択の為に、顔画像間の類似度を計算する際に Gaussian Mixture Models (GMM) [15, 16] を用いる手法を提案する。GMM とは、正規分布の和で表される確率分布モデルである。図 3 に混合数 4 の GMM の例を示す。 μ は正規分布の平均ベクトル、 Σ は正規分布の共分散行列である。

本論文では、各学習人物ごとに顔特徴点座標値を用いて GMM を学習する。

つまり学習人物ごとに、100 枚の画像を用いて、特徴点 64×2 (x, y) の 128 次元 GMM (対角行列) を構成する。そうすることで、未知人物の初期特徴点に対する各 GMM との類似度を求め、その特徴点がどの学習人物の特徴点に類似しているのかを求めることが出来る。得られる人物間の類似度から、次の AAM の構築に

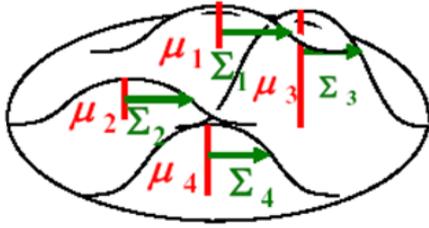


図3 混合数4のGMM

用いる学習人物の画像を選択する。

時刻 x_t における特徴量 x の確率密度分布 $p(x_t)$ を、 K 個の正規分布 $N(x_t, \mu_i, \Sigma_i) (i = 1, \dots, K)$ の重みつき線形結合によりモデル化すると以下の式ようになる。

$$p(x_t) = \sum_{i=1}^K \alpha_i N(x_t, \mu_i, \Sigma_i) \quad (11)$$

ここで、 α_i は重み係数、 μ_i は正規分布の平均ベクトル、 Σ_i は正規分布の共分散行列である。また、 i 番目の正規分布に対する重み係数 α_i は以下の条件を満たす。

$$\sum_{i=1}^K \alpha_i = 1, 0 \leq \alpha_i < 1 \quad (12)$$

また、正規分布の確率密度関数は以下のように表される。

$$N(x_t, \mu_i, \Sigma_i) = \frac{1}{\sqrt{(2\pi)^d |\Sigma_i|}} \exp\left[-\frac{1}{2}(x_t - \mu_i)^T \Sigma_i^{-1} (x_t - \mu_i)\right] \quad (13)$$

GMM の正規分布の各パラメータは、その解を逐次改良することにより次第に最適な解を推定していく、EM アルゴリズムによって求められる。

GMM を用いることによって、少ない学習画像から人物間の類似度を正確に確率密度関数から推定することができ、テストデータである未知人物に適した AAM の構築が可能となる。

3.3 Active Appearance Models の再構築

複数人の学習データから構築された不特定人物の AAM を用いて、未知人物の特徴点を求め、学習人物との類似度によって選ばれた画像だけを使って構築した AAM によって求めた特徴点を最終出力結果とするのではなく、こうして構築した AAM を、未知人物画像に再度適用し、得られた特徴点と手動で与えた特徴点（正解）との差が小さくなるのであれば、新たに得られた特徴点と学習人物ごとの GMM との類似度に基づき、再度、より未知人物に適した画像を選択し直して AAM を構築すると、特徴点抽出の精度はより向上するはずである。従って、今回は類似度が同じになるまで、AAM の構築を繰り返すという手法を提案する。

具体的に、学習人物 A ~ J の十人の GMM が構成されている場合を、図4に沿って説明する。不特定人物 AAM で抽出した初期特徴点 (Initial feature points) と、学習人物の特徴点から構築した GMM との間で類似度を計算する。学習人物画像の類似度上位三人の画像を、その類似度を考慮して、選択する枚数を決める。図4では、上位三名は、A,B,C としている。この画像に含まれている特徴点を基に、新しく AAM を構築する。これを用いて得られる新しい特徴点 (second feature points) が、初期特徴点 (Initial feature points) よりも精度が上がっていれば、新しい特徴点 (second feature points) を用いて類似度を再計算する。同様に、類似度上位三人の画像を類似度を考慮し枚数を決め、次の AAM 構築に選択する。図4では、それを B,A,C としている。これを用いて構成する AAM によって得られる新たな特徴点 (third feature points) の精度は、向上することが期待できる。なぜなら、新しい特徴点になればなるほど、より未知人物の正解特徴点に近づいていると予想されるからである。

これを繰り返すことで、精度が徐々に向上し、図4の Third feature points と Fourth feature points のように、類似度の順位 (Rank of similarity) が同じになった時点で終了する。図4の場合であれば、Third feature points を最終の出力特徴点とする。

また、図5に、その概念図を示す。

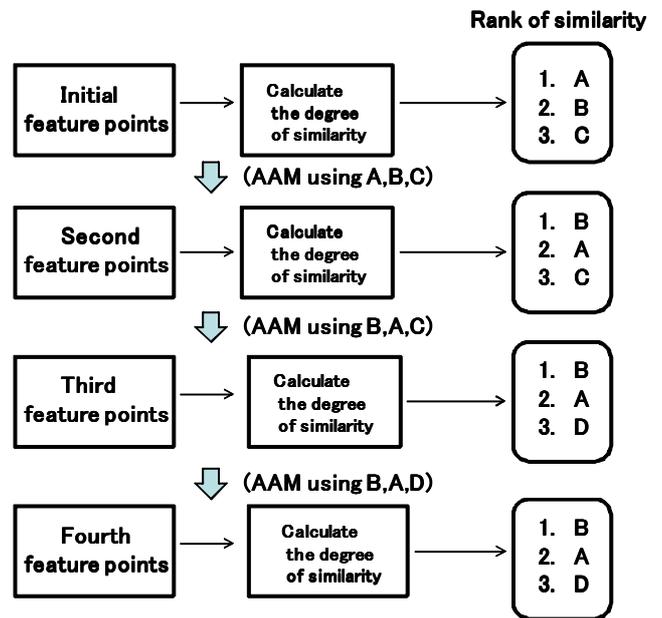


図4 AAM 再構築の例

最初に初期特徴点を抽出するための不特定人物 AAM は、学習人物の平均顔から構成する。つまり、初期特徴点の精度が悪いと、そもそも本実験で求める類似度自体が信頼できないものになってしまう。よって、4.3 節で、初期モデルの実験を行い、平均顔を何枚の画像から構成するべきか調べておく。

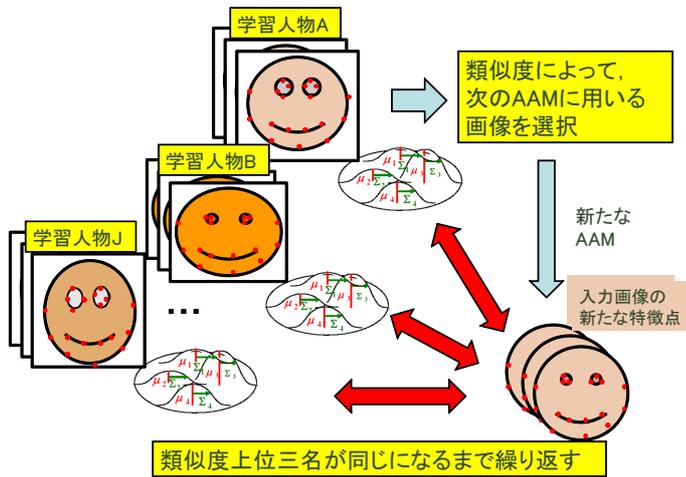


図5 AAM再構築の概念図

との誤差が小さくなっているのので、適切な値となることが分かる。AAMを再構築する際は、各人物間の類似度の差を大きくするために、類似度を確率密度関数の値の三乗の値に設定する。それぞれAAMを再構築する際は、

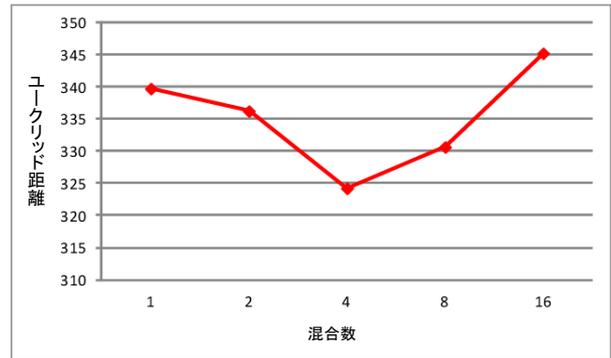


図6 GMMの混合数

4. 評価実験

4.1 実験環境

テスト画像は未知人物10人を対象として、それぞれ10枚ずつ用意した。学習画像は10人を対象として、それぞれ100枚ずつ用意した。これらはビデオで10秒ほど撮影したものを画像として切り出す方法で得る。テスト画像、学習画像ともに、手動で特徴点を付与している。テスト画像の特徴点は真値（正解）として、特徴点抽出の精度を評価するためである。今回の目標は、未知人物の画像から顔特徴点を抽出することなので、正面顔のみでほぼ無表情の顔画像を用いた。なお、AAMの特徴点は、図1の64点である。撮影機器はFINEPIX F600 EXRで、解像度は480×360画素である。背景は白色であり、眼鏡は無しとした。

4.2 実験の流れ

初めに、初期モデルについての評価実験を5.3節で行う。学習人物と未知人物の類似度を求める際に、まず未知人物の画像から初期特徴点を抽出しなければ比較ができない。そこで、すべての学習人物のデータを用いて、不特定人物のAAMを構築し、それを用いて初期特徴点を抽出する。この時、学習画像である10人の画像を何枚ずつ学習に用いるかで精度が変わることが予想されるため、その枚数を決定しなければならない。これは、今後の精度に大きく関わってくるので、とても重要である。

次に提案手法による実験を行う。まず、先ほどの実験によって得られた未知人物の初期特徴点64点について、GMMを用いて学習人物に対する類似度を計算する。GMMの混合数は実験的に最も良い4とした。これを図6に示す。横軸は混合数であり、縦軸は未知人物に手動で与えた正解特徴点と、AAMにより抽出された特徴点とのユークリッド距離の総和である。それぞれ、ランダムで選ばれた5人のテストデータを用いて実験し、平均を求めた。図6より、混合数4の場合が最も正解特徴点

各人物間の類似度の差を大きくするために、類似度を確率密度関数の値の三乗の値に設定する。これは図7により、一乗、二乗、四乗、五乗と比べて今回の実験では三乗の時、最も精度が良い結果となっていることが分かる。図7の横軸は、類似度の計算に用いる累乗の値であり、縦軸は、未知人物に手動で与えた正解特徴点と、AAMにより抽出された特徴点とのユークリッド距離の総和である。ランダムで選ばれた5人のテストデータを用いて実験し、平均を求めた。

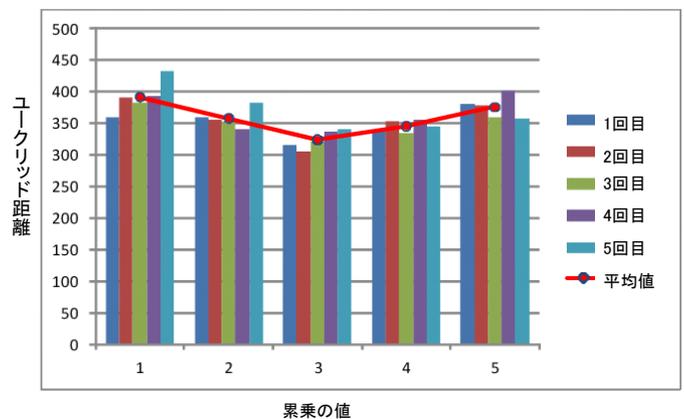


図7 適切な累乗の値

また、その割合を用いて、類似度上位3人の画像の合計が30枚になるようにする。これも実験的に最適な値を求めた。これを図8に示す。図8の横軸は、AAM構築に用いる類似度上位3人の画像の合計枚数であり、縦軸は、未知人物に手動で与えた正解特徴点と、AAMにより抽出された特徴点とのユークリッド距離の総和である。それぞれランダムで選ばれた5人のテストデータを用いて実験し、平均を求めた。

次に、AAMを再構築する際に、類似度をもとに選択する画像の枚数を決定する方法について説明する。図9の

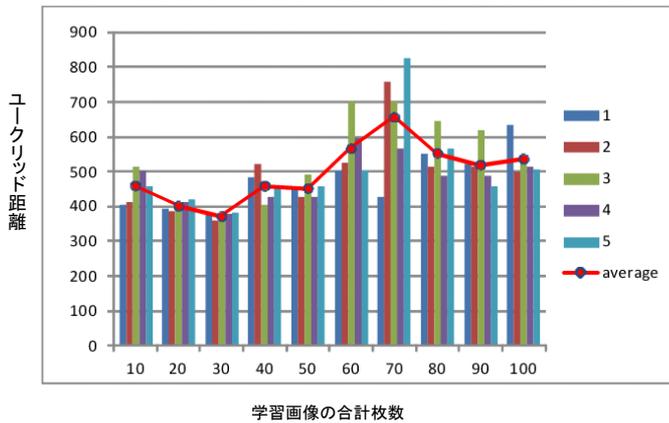


図 8 適切な学習画像の枚数

縦軸は未学習人物に手動で与えた正解特徴点と、AAMにより抽出された特徴点とのユークリッド距離の総和である。横軸は手法の種類であり、

- A. 類似度を考慮して 10 人すべての画像を用いる (30 枚)
- B. 最上位の人物の画像を 30 枚用いる (30 枚)
- C. 類似度を考慮して上位二名の画像を用いる (30 枚)
- D. 類似度を考慮して上位三名の画像を用いる (30 枚)
- E. 類似度を考慮して上位四名の画像を用いる (30 枚)
- F. 類似度を考慮して上位五名の画像を用いる (30 枚)
- G. 上位三名の画像を 10 枚ずつ用いる (30 枚)

となっている。また、ここでの類似度とは、GMMで得られた出力値の三乗の値であり、その比率を用いて合計 30 枚の学習データとなるようにした。これらの手法をランダムで選ばれた 5 人のテストデータで実験し、平均を求めている。図 9 より、ユークリッド距離が小さいほうが類似度は高いので、D の方法が精度が高いことがわかる。

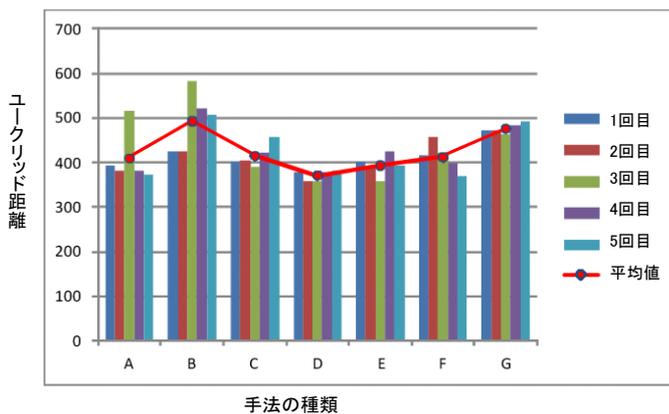


図 9 AAM の学習画像選択

また、AAM 再構築という提案手法が有効であるか調べるために、再構築せずに一度だけ AAM を適用した場合との比較した。

4.3 初期モデルの評価実験

4.3.1 概要

未知人物の初期特徴点を求める際に、学習人物から何枚ずつの画像を使って AAM を適用するのかを求めておく。実験の評価は、未知人物テストデータから得られた特徴点と、その人物に手動で点を与えた正解特徴点との、6 4 点間のユークリッド距離の総和で求めた。実験はそれぞれの枚数について、ランダムに 5 人のテストデータを選択して行った。また、入力画像や学習画像は毎回ランダムに選んだ。

4.3.2 結果

図 10 に結果を示す。横軸は学習人物一人当たりの学習枚数であり、縦軸は正解特徴点とのユークリッド距離であり、値が小さいほうが精度が高い。5 回ずつ試行を行った結果、一人当たり二枚ずつの学習データを用いることが最も精度が高いと言える。よって、今回の未知人物に特徴点を付与する実験では、一回目の類似度を測るために得る初期特徴点を一人二枚ずつ合計 20 枚を用いて構築した AAM から得ることとする。

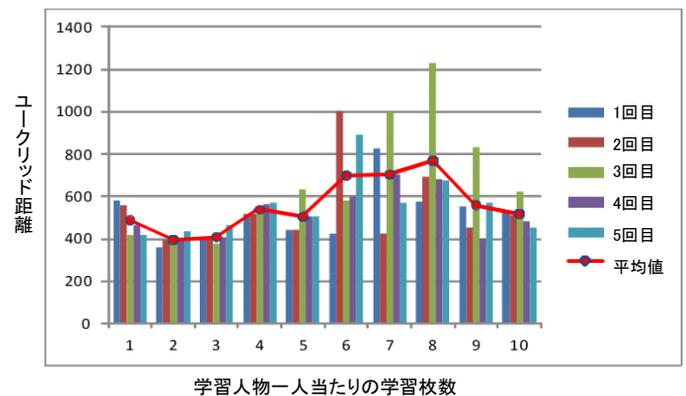


図 10 初期モデルの評価実験

4.4 実験結果

図 11 に結果を示す。縦軸は正解特徴点とのユークリッド距離であり、横軸は手法の種類であり、

- A. 10 人 × 10 枚による初期特徴点
- B. 10 人 × 2 枚による初期特徴点
- C. GMM により類似度を求め、AAM を構築した場合
- D. 提案手法
- E. 既知人物の場合

である。また E の既知人物の場合の手法では、既知人物の顔画像 30 枚を AAM 構築に使用した。

5. まとめ

本研究では、未知人物に対する AAM の適応について実験した。

実験結果により、提案手法はテストデータ中の、どの未知人物の画像に対しても精度が向上した。また、実験

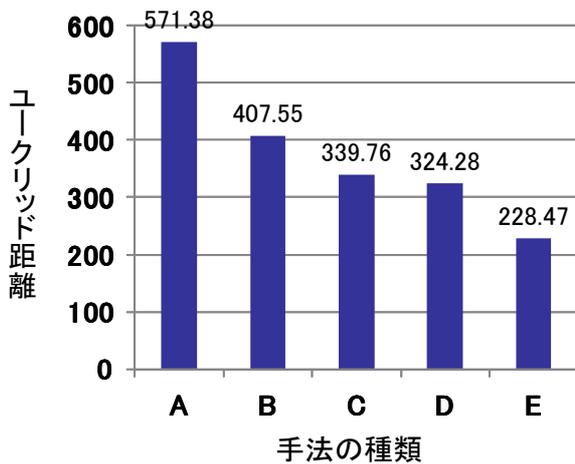


図 11 実験結果

により最も適切であると考えられる学習人物の平均顔から得られた特徴点と精度と、提案手法によって得られた特徴点の精度を比較すると、約 38 % の精度が向上した。このことから提案手法は有効であったと言える。

しかし、非正面の顔画像や、感情がある場合、照明変動がある場合などに AAM により特徴点を抽出することを本論文では実行しておらず、今後、改善を行う必要がある。また、未知人物において精度は向上したが、学習済み人物の場合と比べると少し見劣りしてしまう部分があるので、学習人物のデータ人数や枚数を増やしたり、別の手法と組み合わせずことで、提案手法の改善を行っていく必要がある。

文 献

- [1] 小西嘉典, 木下航一, 宍生紘, 川出雅人, “リアルタイム笑顔度推定,” 情報処理学会インタラクシオン 2008, (予稿集).
- [2] 山口修, 福井和広, “顔向きや表情の変化にロバストな顔認識システム“ Smartface ”,” 電子情報通信学会論文誌, D-II, Vol. J84-D-II, No. 6, pp.1045-1052, 2001.
- [3] Masaki Aoki, Ken Masuda, Hiroyoshi Matsuda, Tetsuya Takiguchi, Yasuo Arika, “Voice Activity Detection by Lip Shape Tracking using EBGM,” ACM Multimedia 2007 (ACM MM 2007), pp.561-564, 2007-09.
- [4] Chikot Miyamoto, Yuto Komai, Tetsuya Takiguchi, Yasuo Arika, Ichao Li, “Multimodal Speech Recognition of a Person with Articulation Disorders using AAM and MAF,” IEEE International Workshop on Multimedia Signal Processing (MMSp 2010), pp. 517-520, 2010-10.
- [5] 大野健彦, “視線インターフェースから視線コミュニケーションへ - 視線のある環境を目指して -,” 情報処理学会研究報告 2001, HI-95, pp. 171-178, 2001
- [6] T. F. Cootes, G. J. Edwards, and C. J. Taylor, “Active Appearance Models,” The 15th European Conference on Computer Vision (ECCV 1998), Vol. II, pp. 484-498, 1998.
- [7] T. F. Cootes, G. J. Edwards, and C. J. Taylor, “View-based Active Appearance Models,” Image and Vision Computing 2002, pp. 227-232, 2002.
- [8] Sungsoo Park, Jongju Shin, and Daijin Kim, “Facial expression analysis with facial expression deformation,” The 19th International Conference on Pattern Recognition (ICPR 2008), pp. 1-4, 2008.

- [9] Jing Xial, Simon Baker, Iain Matthews, and Takeo Kanade, “Real-Time Combined 2D+3D Active Appearance Models,” Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 535-542, 2004.
- [10] Ralph Gross, Iain Matthews, Simon Baker, “Generic vs. Person Specific Active Appearance Models,” Image and Vision Computing, Vol. 23, No. 11, pp. 1080-41 1093, 2005.
- [11] Paul Viola, Michael Jones, “Rapid Object Detection using a Boosted Cascade of Simple Features,” The 4th IEEE International Conference, pp. 40-45, 2000.
- [12] 林伸治, 長谷川修, “低解像度画像からの顔検出,” 画像電子学会誌, 第 34 巻, 2005.
- [13] 石井健一郎, “わかりやすいパターン認識,” オーム社, 1998
- [14] エルッキ・オヤ, “パターン認識と部分空間法,” 産業図書, 1986.
- [15] 部分空間法研究会 2010, -部分空間法のフロンティア-, MIRU2010.
- [16] 戸田 智基, “GMM に基づく声質変換を用いた感情音声合成, Emotional Speech Synthesis Using GMM-based Voice Conversion Technique,” 電子情報通信学会技術研究報告. SP, 音声 102(619), pp. 11-16, 2003.