

幾何学的制約を考慮した Linear Predictors に基づく顔特徴点自動検出

松田 龍英 原 朋也 前島 謙宣 森島 繁生

早稲田大学先進理工学研究科 〒169-8555 東京都新宿区大久保 3-4-1

E-mail: {matsuda-t@ruri., wap.0921@akane., maejima@aoni., shigeo@}waseda.jp

あらまし 本稿では, Eng-Jon らが提案した Linear Predictors に, 幾何学的制約を加味した新しい顔特徴点検出手法を提案する. Linear Predictors は, 注目画素周辺の輝度値と, 特徴点の正解位置への移動ベクトルを回帰によって対応付ける手法であり, 20 枚程度の学習データで高精度な推定移動ベクトルが得られる. 提案手法では, 各顔器官の重心を基準とした特徴点の有効範囲を定め, 移動ベクトル推定時に特徴点の有効範囲を超えないような制約を加え, 特徴点検出精度の向上を実現した. また, 事前に顔向き角度推定を行い, 推定結果に基づいた学習データの選択を行うことで, 姿勢に依らない特徴点検出を可能にした.

キーワード 顔画像, 顔特徴点検出, 統計的学習, 幾何学的制約

1. はじめに

1.1 研究背景

近年, 顔検出機能付きカメラや顔認証システムなどといった, 顔画像を用いたアプリケーションが普及しつつある. これらの多くは, 特徴量を顔画像から検出する際に, 目や鼻のような顔器官を簡潔に表現する特徴点を基点として用いている[1]. したがって, 特徴点の位置情報がアプリケーションの出力結果を決める上で重要となる. それゆえ, 顔画像を対象とした特徴点検出技術に関する研究は盛んに行われている. 多くの応用研究がなされている代表的な研究例として, Cootes らの Active Appearance Model (AAM)[2]と Active Shape Model (ASM)[3]がある. AAM は学習部において, まず, 顔の特徴点座標群に対して主成分分析を行い, 固有値の大きな基底を選択することによって shape と呼ばれる顔形状を得る. 次に, shape 内部のテクスチャに対しても同様に主成分分析を行い, appearance と呼ばれるテクスチャ情報を取得する. そして, shape と appearance に対してさらに主成分分析を行い, モデルパラメータを得ることによって, 顔形状とテクスチャのモデルバリエーションを 1 つのパラメータにより制御することが可能となる. これを用いて, 入力顔画像に shape をフィッティングすることで, 特徴点を検出する. ASM の場合は, 学習時に AAM と同様に shape を取得するとともに, 各特徴点位置における顔輪郭法線上の局所的なテクスチャ情報から, profile model を構築する. そして, shape の取りうるバリエーションの範囲内において, profile model と画像とのマッチングによりモデルフィッティングを行う. このようにして, AAM, ASM は両者とも, shape が顔らしい形状を保つような拘束条件として働くことにより, 高精度な特徴点検出結果が得られる.

しかし, これらの手法は, モデルの初期配置が大きすぎた場合に正解位置に収束するのが難しい. 加えて, AAM に関しては, 未学習データに対して性能が低下しやすいという欠点も抱えている.

一方, 動画像において顔の特徴点を追跡する手法として, Eng-Jon らの Selected Multi-Resolution Linear Predictors[4]がある. この手法は, まず, 特徴点周辺のテクスチャ情報と移動ベクトルを線形回帰によって対応付ける. 次に, 注目点周辺のテクスチャ情報から写像計算により移動ベクトル推定を行う. そして, その結果に基づく移動を繰り返し行うことで, 顔の移動や向きの変化に対して特徴点をリアルタイムで追跡する手法である. この手法は学習に用いる 1 人の人物にしか対応していないが, 15 枚程度の少数の画像で学習可能である. また, 個々の特徴点を独立して追跡し, 検出を行うという特徴がある.

中野らは, Linear Predictors を静止画に適応させ, 姿勢状態不明の入力顔画像 1 枚から特徴点を自動検出する手法を提案した[5]. この手法は初期配置と正解位置のずれに対して AAM よりも頑健であり, 未学習人物に対しても有効であるという結果が得られた. しかしながら, 各特徴点の検出は独立して行っているため, 誤った箇所を特徴点として検出してしまうという問題点があった.

そこで本研究では, Linear Predictors による特徴点検出手法に顔形状による幾何学的制約を加えることで, 誤って検出した特徴点を補正し, より正確な位置に特徴点を検出する手法を提案する.

1.2 研究概要

本研究では, まず, 入力顔画像として複数の人物の顔画像を取得し, [5]の手法により学習および移動ベクトル

推定を行う。ここで、学習時には入力顔画像の特徴点群から、顔の各部位の重心を基準として、特徴点が正解位置として取りうる有効範囲を決定する。また、移動ベクトル推定時には、各特徴点が学習時に定めた有効範囲から外れた場合に、各部位の重心からの距離を平均値に置き換える。本手法の特徴は、Linear Predictors の利点である初期位置からの収束性と未学習人物に対する有効性を保持しつつ、顔形状による幾何学的制約を考慮することで、より正確な位置に特徴点を検出できる点である。

2. Linear Predictors の原理

2.1 手法概要

Linear Predictors(以下 LP)とは、特徴点周辺の画像特徴量と現在位置から正しい特徴点位置への移動ベクトルとを線形回帰によって対応付ける手法である[4]。具体的には、まず一定の半径の円内にサンプリング点を複数配置する。このサンプリング点のことをサポートピクセルと呼ぶ。次に、サポートピクセルを特徴点の正解位置周辺にサンプリングし、各サポートピクセルにおいて取得した輝度値を学習画像間で平均化する。この値をベースサポートピクセル値と呼ぶ。そして、特徴点の正解位置周辺に配置されたサポートピクセル集合をランダム方向に移動する。さらに、この集合の移動後のサポートピクセルでの輝度値とベースサポートピクセル値の差分を画像特徴量として取得する。このランダム移動と画像特徴量の取得を各画像において複数回行う。上記の繰り返しによって得られた移動ベクトルと画像特徴量をそれぞれデータ行列の形に纏め、前者を従属変数、後者を説明変数として重回帰分析を行い、線形写像を求める。特徴点の検出時には、学習画像の各特徴点の平均位置にサポートピクセル集合を配置する。そしてサポートピクセルでの輝度値とベースサポートピクセル値の差分により算出した画像特徴量と学習時に求めた線形写像から移動ベクトルの推定を行い、その結果を用いて特徴点を初期位置から正解位置まで移動させる。以下 2.2 節から 2.5 節ではこの手法の詳細について説明する。

2.2 LP の構成要素

LP は、5 つの成分の組 $L = \{ \mathbf{c}, \mathbf{H}, \mathbf{S}, \mathbf{V}, \mathbf{b} \}$ によって定義される。 \mathbf{c} は使用する画像の原点を基準としたサポートピクセル集合の位置ベクトルを表し、この位置を中心としてサポートピクセルを配置する。 \mathbf{H} は画像特徴量から移動ベクトルを推定するための線形写像である。 \mathbf{S} は \mathbf{c} を基準としたサポートピクセルの位置ベクトルの集合である。ここで、 $|\mathbf{S}|$ をサポートピクセル数と定める。 \mathbf{V} はベースサポートピクセル値を要素として持つ $|\mathbf{S}|$ 次元ベクトルである。 \mathbf{b} はバイアス因子と呼び、線形写像 \mathbf{H} の要素として移動ベクトルの推定精度を向上するために用い




図1 サポートピクセル集合の模式図

る。図1にサポートピクセル集合の模式図を示す。

2.3 LP の各成分の学習

まず、LP の構成要素のうち、 \mathbf{S} から定める。 \mathbf{S} はサポートピクセル集合において、 \mathbf{c} からの相対位置ベクトルを表しており、 \mathbf{c} を中心とする円内に収まるようにランダムにとる。ここで、表記上 $\mathbf{S} = (\mathbf{S}_i)_{i=1}^{|\mathbf{S}|}$ とし、 \mathbf{S}_i は各サポートピクセルの相対位置ベクトルとする。

次に \mathbf{V} を求める。そのため、学習データとして特徴点の正解位置を手動で定めた顔画像を複数枚用意する。そして、各画像の特徴点の正解位置にサポートピクセル集合を配置して輝度値を取得し、それらを学習画像間で平均化する。

\mathbf{H} と \mathbf{b} を求める際には、まず特徴点の正解位置上にサポートピクセル集合を配置し、ランダムな移動ベクトル \mathbf{t} を加えて移動する。次に \mathbf{S}_i において輝度値を取得し、式(1)によって画像特徴量 \mathbf{p} を求める。

$$\mathbf{p} = (\mathbf{V}_i - \mathbf{V}_i^1)_{i=1}^{|\mathbf{S}|} \quad (1)$$

ここで、 \mathbf{V}_i は \mathbf{S}_i におけるベースサポートピクセル値、 \mathbf{V}_i^1 は移動後の \mathbf{S}_i における輝度値である。さらにサンプリング後に、 \mathbf{p} の末項に 1 を加える。この処理を各画像において複数回繰り返す。そして、移動ベクトル \mathbf{t} の集合 \mathbf{T} を従属変数、画像特徴量 \mathbf{p} の集合 \mathbf{P} を説明変数として、式(2)に基づき重回帰分析を行い、 \mathbf{H} および \mathbf{b} を算出する。

$$\mathbf{T} = \mathbf{HP} + \mathbf{b} \quad (2)$$

なお、本研究において乱数の生成には、斎藤らの SIMD-oriented Fast Mersenne Twister (SFMT) を使用する[6]。SFMT のアルゴリズムは線形漸化式を用いて 1 度に 128 ビットの擬似乱数を生成可能である。本研究ではこのアルゴリズムにより $(2^{19937} - 1)$ 周期の乱数を生成する。実用上、この程度の周期があれば乱数生成結果に同じ数列パターンが出現する現象を避けられると考えられる。

2.4 移動ベクトルの推定

特徴点を検出する際には、特徴点の正解位置からサポートピクセル集合の初期位置までの移動ベクトルを推定し、それを基に集合を移動させるといった処理を行う。まず、サポートピクセル集合の現在位置での \mathbf{S}_i における輝度値と学習時に使用した \mathbf{V}_i から、画像特徴量 \mathbf{p} を求め

る。次に学習時に求めた \mathbf{H} および \mathbf{b} から、式(3)によって移動ベクトル \mathbf{t} を求める。

$$\mathbf{t} = \mathbf{H}\mathbf{p} + \mathbf{b} \quad (3)$$

こうして、得られた \mathbf{t} に基づいてサポートピクセル集合を移動し、中心位置 \mathbf{c} を特徴点の検出位置とする。

2.5 サポートピクセル集合の複数使用

これまでに説明したサポートピクセル集合を用いた移動ベクトルの推定手法であるが、単独で用いた場合には画像のノイズの影響を受けやすい。そこで1つの特徴点を検出するために複数のサポートピクセル集合を使用する。ある基点から個々のサポートピクセル集合までの位置ベクトルを固定し、それぞれの集合で学習および移動ベクトル推定を行う。そして、求められた推定結果を平均したものを出力結果とする。このように複数のサポートピクセル集合を1つの群として用いることによって、ノイズなどの影響を減少させることが可能となる。

3. データベースの構築

3.1 顔画像の取得

本節では、本研究で入力顔画像として使用する正面および角度付きの顔画像の取得方法について述べる。

撮影機材には Canon EOS-5D を使用し、被験者の顔を正面から撮影できる位置にカメラを設置した。また、被験者から見たカメラの方向を基準に、 15° 刻みに $\pm 30^\circ$ の範囲で計4本のポールを配置し、ポールの先端には注視点を描いたプレートをつけた。カメラの脚立とポールの高さは、カメラと注視点が被験者の頭部の高さと同しくなるように設定した。

撮影方法としては、20代～50代の男女25名の被験者に、注視点に視線を向け、画像撮影のたびに水平方向に顔向きを変えるように指示した。被験者1名につき、 15° 刻みに $\pm 30^\circ$ の範囲で顔向きを変えた計5枚の画像を撮影した。撮影後、トリミングを行い、顔が画像内に収まるように、肩より上部の 1024×1024 [pixel] の領域を切り取った。図2に取得した角度付き顔画像の例を示す。

3.2 特徴点の定義

本節では、本研究で扱う特徴点の定義について述べる。特徴点は正面顔を基準として両目、両眉、鼻、唇の輪郭を簡潔に表すように、各顔器官の周囲にそれぞれ4点ずつ配置する。また、顔の外輪郭点として顎に1点配置する。これらを合わせた計25点を本研究で扱う特徴点とする。なお、顔向き角度の変化により隠れる特徴点については、見えている器官の輪郭を特徴点として再定義する。図3に特徴点の配置図を示す。また、表1に配置図に示した特徴点番号の名称を示す。



図2 角度付き顔画像




図3 特徴点の配置図

表1 特徴点の番号と名称

目領域(16点)		口領域(4点)	
0,9	目尻	20	右唇端点
1,8	目頭	21	左唇端点
2,10	目上端	22	唇上端
3,11	目下端	23	唇下端
4-7,12-15	眉端点	外輪郭領域(1点)	
鼻領域(4点)		24	顎
16	鼻下		
17	右鼻端点		
18	左鼻端点		
19	鼻頭		

4. Linear Predictors を用いた特徴点検出

4.1 サポートピクセル集合の初期配置

本研究では各サポートピクセル集合の初期配置を行うにあたり、オープンソースライブラリ OpenCV において実装されている Viola らの顔検出器[7]を用いる。この顔検出器を用いることによって、矩形の検出窓の左上の点の x, y 座標と矩形の縦幅、横幅が出力される。

学習時において、各顔画像の特徴点の正解位置と検出窓の縦幅、横幅を画像間で平均化する。これにより平均特徴点の位置と平均検出窓の縦幅、横幅を算出する。

特徴点検出時には、まず、入力顔画像に対して顔検出を行い、出力された検出窓と平均検出窓の比を求める。次に、検出窓の中心位置を基準にし、求めた比率に応じて入力顔画像を拡大・縮小する。そして、検出窓の中心



図4 サポートピクセル集合の初期位置例

位置に両目特徴点の2点(1番, 8番)と鼻特徴点の1点(16番)の計3点の重心を基準とした位置を合わせるように, 平均特徴点を配置する. このようにして配置された平均特徴点をサポートピクセル集合の初期位置とする. 図4に入力顔画像に対する初期位置例を示す.

4.2 顔向き角度別学習

入力顔画像に対して最も有効に特徴点検出するために, 入力顔画像が向いている角度で学習した線形写像により特徴点検出を行う必要がある. 本研究では, 中野らによって提案された手法によって, LPを用いた角度推定と線形写像の選択を行う.

具体的には, 2通りの方法でデータベースを参照し, それぞれのデータからLPの学習を行う. ここで, 2通りの方法のうち, 1つは5つの顔向き角度を含む全データベース中の顔画像で学習する LP_{all} である. もう1つはある顔向き角度毎にデータベースを分割して学習を行う $LP_{\Omega} = \{LP_w\}_{w=1}^5$ である. LP_{all} はすべての顔向き角度の顔画像に対して, ロバスト性のある移動ベクトル推定を行うことを目的とする. 一方, LP_{Ω} は入力顔画像の顔向き角度に最も近い学習データで作成されたものを選択することによって, 高精度に移動ベクトル推定を行うことを目的とする.

角度推定画像を取得するために, まず, LP_{all} を用いて学習画像に対する移動ベクトル推定を全特徴点(25点)に対して行う. そして, 得られた移動ベクトルのX, Y成分(50次元)を説明変数, 正解角度を従属変数として回帰を求めることで, 角度推定画像を取得する. ここでの回帰手法にはSupport Vector Regression (SVR)を用いる. 実装については, LinらのLIBSVMを使用する. LIBSVMで実装されているSVRとカーネル関数は複数存在するが, 本研究では中野らの研究において最も有効と検証された, 線形カーネルを用いたEpsilon SVRを使用する.

特徴点検出を行う際には, まず入力顔画像に対して LP_{all} により移動ベクトル推定を行う. その後, 角度推定画像を用いて, 移動ベクトルから顔向き角度を求める. そして, 推定された角度に最も近い角度のデータベースによって学習を行った LP_w を LP_{Ω} から選択し, 改めて




図5 唇の特徴点の有効範囲

移動ベクトルの推定を行い, 特徴点を検出する.

4.3 幾何学的形状による制約

本手法では, LPによって特徴点検出を行う際に顔形状を考慮した制約を加えることによって, 検出精度を向上させることを目的としている. 本節では, 特徴点の取り得る有効範囲の決定方法と, 移動ベクトル推定時における制約の付加について述べる.

4.3.1 特徴点の有効範囲の決定

顔形状を考慮した制約を加えるために, 各顔器官の重心を基準として, 特徴点の取り得る有効範囲を学習時にあらかじめ定めておく必要がある. 本研究では, 特徴点群の平均と標準偏差に基づいて有効範囲を決定する[8].

まず, 学習で用いた各画像において, 各顔器官の特徴点の重心座標をそれぞれ求める. 次に重心と各特徴点の距離を求め, 各画像間での平均 μ と標準偏差 σ を算出する. そして, 得られた値から, $\mu \pm 4\sigma$ を特徴点の有効範囲とする. 図5に有効範囲の概念図を示す.

同様に各顔器官の重心に対しても, それぞれが取り得る有効範囲を設ける. この場合, 鼻の重心を基準として各顔器官の重心までの距離を求め, 各画像間での平均 μ と標準偏差 σ を算出し, $\mu \pm 4\sigma$ を有効範囲とする.

4.3.2 移動ベクトル推定時における制約の付加

移動ベクトルを推定する際に, 従来手法[5]では誤った移動ベクトル推定を行い, 結果として明らかに異なる箇所を特徴点として検出するという問題点があった. そこで, 本項では移動ベクトル推定時における顔形状を考慮した制約について述べる.

まず, 2章で述べた手法により学習および移動ベクトル推定を行い, 全特徴点を移動する. 次に, 移動した位置で各顔器官の特徴点の重心座標をそれぞれ求め, 重心同士の距離と, 重心と各特徴点との距離を算出する. そして, これらの距離が前節で定めた有効範囲から超えた場合には平均距離に置き換える, という処理を行う. なお, 重心同士の距離を置き換える場合, その顔器官の重心を構成する特徴点すべてを移動させることとなる. この処理により, 誤推定を行うLPが特徴点の取り得る有

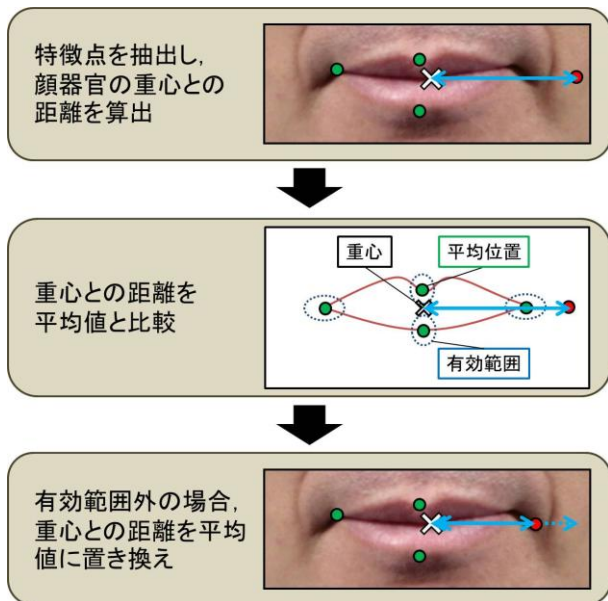


図 6 制約を付加する手順

有効範囲から外れないように補正を加えつつ、移動ベクトル推定を繰り返し行うことで、LP を徐々に正解位置に近づけることが可能となる。特徴点に対して顔形状による制約が働いた際の一連の流れを図 6 に示す。

4.4 特徴点検出の手順

特徴点検出を行うには、まず、入力顔に対して 4.1 節で定めたサポートピクセル集合の初期位置から LP_{all} を用いて 2 章で述べた方法により移動ベクトル推定を行う。その後、角度推定画像を用いて、移動ベクトルから顔向き角度を求め、推定された角度に最も近い角度のデータベースによって学習を行った LP_w を LP_Q から選択する。さらに、 LP_w の学習データに基づいてサポートピクセル集合の初期位置を再決定する。そして、4.3 節で述べた幾何学的形状による制約を考慮して、改めて移動ベクトル推定を行い、特徴点を検出する。

ただし、1 度の処理だけではサポートピクセル集合を正解位置まで移動できない場合があり、4.3 節でも述べたように、移動ベクトルの推定を繰り返し行う必要がある。そのため、収束条件を前もって設定しなければならない。収束条件としては、あらかじめ定めた繰り返し回数で終了する方法と、各繰り返しで推定される移動量が一定値以下になったら終了する方法などがある。本手法では、上記した 2 つの方法を組み合わせたものを収束条件として用いる。具体的には、収束するのに十分であると実験的に判断した繰り返し回数（本研究では 10 回に設定）行う、もしくは推定移動量が 2[pixel]以下となった場合に処理を終了し、その時点でのサポートピクセル集合の位置を特徴点の検出結果とする。

5. システム評価

本章では、 LP_{all} による顔向き角度推定が成功したと仮定し、各顔向き角度により学習した LP_Q の収束性能の評価や処理時間に対する検証について述べる。

5.1 類似手法との比較

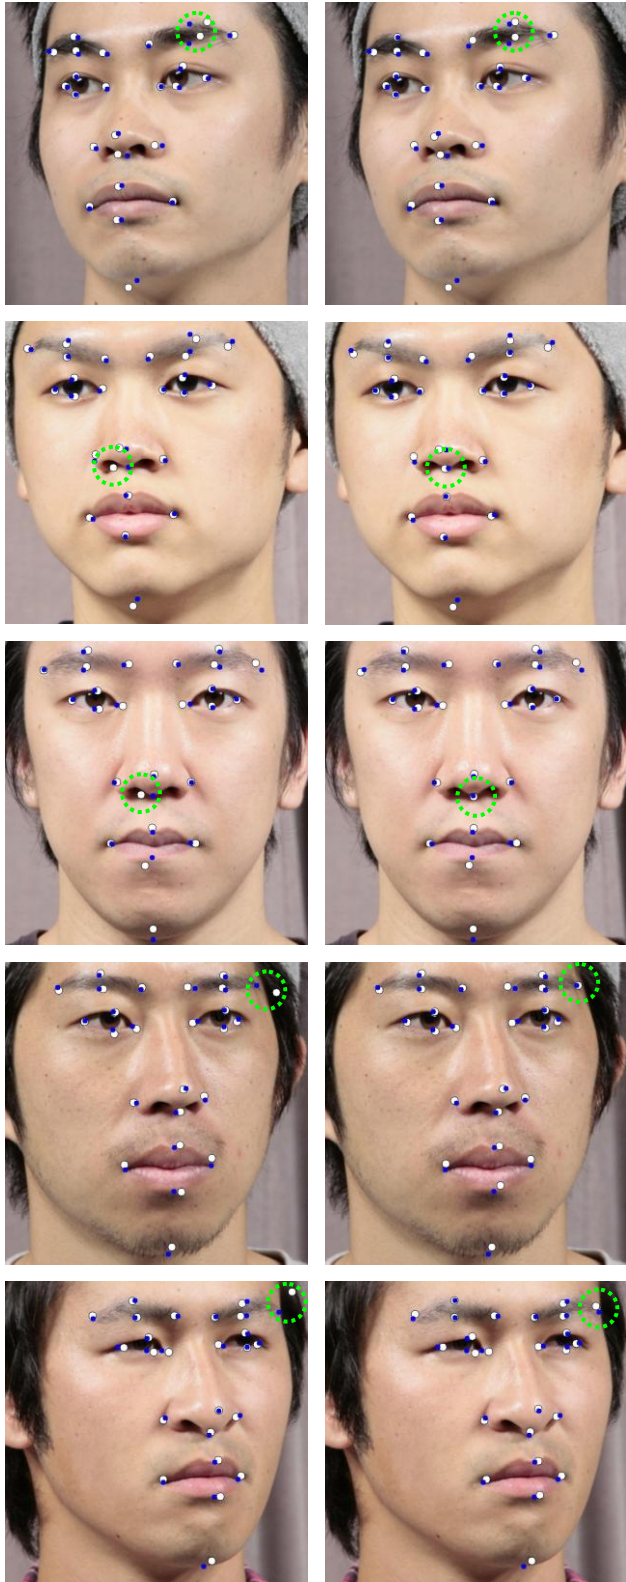
LP に幾何学的制約を設けた本手法と設けていない中野らの手法との比較を行った。まず、3.1 節で取得した 25 枚の顔画像を学習用 20 枚と入力用 5 枚の組み合わせに分け、入力用の顔画像に同じものを使用しないようにそれらを 5 種類用意する。次に、それぞれの組み合わせで学習データから線形写像を作成し、4 章で述べた方法で特徴点検出を行った。そして、顔検出が成功した特徴点検出結果に対して、誤差率（目の両端の特徴点の中心を結んだ距離を 100%とした場合の、特徴点の検出結果と正解位置との距離の比率）を計算した。この一連の処理を各顔向き角度に対して行った。

図 7 に特徴点検出結果例を示す。なお、図中の白点、青点は特徴点の検出位置、正解位置を表す。また、表 2 に各顔向き角度における全特徴点の誤差率の平均値を示す。図 7 から、点線で囲んだ特徴点で正解位置との誤差が減少していることが見て取れる。さらに、表 2 から、全角度において本手法の誤差率の方が低いことが分かる。

5.2 異なる手法との比較

LP を使用しない顔特徴点検出手法との比較を行った。3.1 節で取得した 25 枚の正面顔を入力顔画像として、本手法と Zhang らの手法[9]との特徴点検出精度の比較を行った。この手法は、本手法と比較して大規模なデータベースを使用し、高精度かつ姿勢や照明の変化にロバストな特徴点検出手法である。比較には、学習データとして本手法では 5.1 節で用いたものを、Zhang らの手法では彼らが独自に収集したデータベースを使用した。

表 3 に各顔器官と全体の特徴点の誤差率の平均値を示す。この結果から、鼻と顎において誤差率に大きな差があることが分かる。鼻は他の顔器官より立体的であるため、角度変化により見え方が大きく変化する。そのため、Zhang らの手法では用いている学習データの縦向き角度が我々ものと異なり、特徴点を正しく検出できなかったためだと思われる。また、顎については、首との境界が曖昧な画像に対して、本手法では効果的に特徴点を検出できなかったためだと考えられる。さらに、他の顔器官においては誤差率の差が 1%以内となっている。これらの結果から、本手法は Zhang らの手法と異なり、使用する画像について照明環境が一定という条件があるものの、学習画像枚数が 20 枚程度と大幅に少なく、学習の手間がかからないながらも、同等以上の検出精度を実現することができた。



(a)中野らの手法 (b)本手法
 図7 特徴点検出例
 (上から-30° , -15° , 0° , +15° , +30°)

表2 各角度における両目間隔を基準とした誤差率

顔向き角度[°]	-30	-15	0	+15	+30
中野らの手法[%]	4.81	4.26	3.60	3.90	4.93
本手法[%]	4.32	3.79	3.17	3.55	4.07

表3 各顔器官と全体の両目間隔を基準とした誤差率

顔器官	目	眉	鼻	口	顎	全体
Zhang らの手法[%]	1.77	4.97	8.01	2.41	4.38	4.00
本手法 [%]	2.40	4.33	2.24	2.68	5.78	3.17

表4 LPの個数と処理時間, 誤差率の関係

LPの個数	400	200	100	50	25
処理時間[ms]	6974	3703	2025	1226	804
誤差率[%]	3.17	3.29	3.37	3.33	3.56

5.3 特徴点検出時間の検証

本手法は繰り返し演算を行うため、処理に多くの時間を必要とする。しかし、2.5節で述べた群におけるサポートピクセル集合の個数(5.1, 5.2節では400個)を変化させることで、処理時間を減らすことができる。そこで、3.1節で取得した25枚の正面顔を入力顔画像として、5.1節と同様の手順により、サポートピクセル集合の個数を変化させて特徴点検出を行った。そして各場合における繰り返し演算の処理時間と誤差率を計算した。なお、実験環境としてCPUはIntel® Core™2 Duo E6750 2.66GHz、メモリは4GBのPCを使用した。

表4に群におけるサポートピクセル集合個数に対する処理時間と誤差率の平均値を示す。この結果から、個数の減少にほぼ比例して処理時間が短くなり、また多少の上下があるものの誤差率が徐々に増加していることが分かる。このことから、若干の検出精度を犠牲にすることで処理時間を大幅に減少できるということが言える。

6. おわりに

6.1 まとめ

本研究では顔画像から、幾何学的制約を考慮したLPによる移動ベクトル推定により、特徴点検出精度の向上を実現した。

評価実験では中野らの手法との比較から、幾何学的制約を加えたことによる特徴点検出精度の向上が見られた。また、Zhangらの手法との比較により、LPを用いた特徴点検出の有効性を確認することができた。さらに、群におけるサポートピクセル集合の個数の変化に対する処理時間と検出精度の関係について調査した。

6.2 今後の課題

今後は、学習画像と異なる撮影環境下での利用を想定し、特徴量として輝度値ではなく、照明変化やノイズの影響を受けにくいとされている haar-like[10]などの特徴量について検証する予定である。また LP の写像計算に重回帰分析を用いたが、学習データによっては解が求まりにくい可能性が考えられる。そのため、非線形回帰による手法についても検討していく方針である。

謝辞:本研究は文部科学省の平成 23 年度科学技術戦略推進費による「安全・安心な社会のための犯罪・テロ対策技術等を実用化するプログラム」の一環として実施されたものである。また、顔特徴点検出の比較検証の為に技術支援を頂いたオムロン株式会社の川出雅人氏、Shihong Lao 氏に深く感謝致します。

文 献

- [1] 井辺昭人, 佐藤康之, 前島謙宣, 森島繁生, ”特徴点の 3 次元情報を利用した顔認証システムの構築, ”電子情報通信学会技術研究報告, Vol.104, No.748, pp.25-30, Mar.2005.
- [2] T.F.Cootes, G.J.Edwards, and C.J.Taylor, ”Active appearance models, ” 5th European Conference on Computer Vision vol.2, pp.484-498, Freiburg, Germany, June.1998.
- [3] T.F.Cootes, C.J.Taylor, D.Cooper and J.Graham, ”Active shape models - their training and application, ”Computer Vision and Image Understanding, vol.61, No.1, pp.38-59, Jan.1995.
- [4] Eng-Jon et al, ”Robust Facial Feature Tracking using Selected Multi-Resolution Linear Predictors, ”IEEE International Conference on Computer Vision 2009, no.997, pp.1483-1490, Kyoto, Japan, Sept-Oct.2009.
- [5] 中野真也, 前島謙宣, 森島繁生, ”顔向き変化にロバストな Linear Predictors に基づく特徴点自動検出, ”画像の認識・理解シンポジウム 2010, no.IS2-40.pdf, Jul.2010.
- [6] Mutsuo Saito and Makoto Matsumoto, ”SIMD-oriented Fast Mersenne Twister: a 128-bit Pseudorandom Number Generator, ”7th International Conference on Monte Carlo and Quasi-Monte Carlo Methods in Scientific Computing, pp.607-622, Ulm, Germany, Aug.2006.
- [7] Viola and M. Jones, ”Rapid object detection using a boosted cascade of simple features, ” 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp.511-518, Kauai, HI, USA, Dec.2001.
- [8] 宇和伸明, 向田茂, 河野みちよ, 大西敏夫, ”標準顔情報を用いた顔画像認識, ”日本顔学会誌, vol.10, pp.150, Oct.2010.
- [9] L.Zhang, H.Ai, S.Tsukiji, S.Lao, ”A Fast and Robust Automatic Face Alignment System, ” 10th IEEE International Conference on Computer Vision 2005, demo program, Beijing, China, Oct.2005.
- [10] R.Lienhart and J.Maydt, ”An Extended Set of Haar-like Features for Rapid Object Detection, ”IEEE International Conference on Image Processing 2002, Vol.1, pp900-903, Rochester, New York, Sep.2002.