

## クラス距離を重みとする局所保存射影とその顔画像による 年齢推定への応用

宮 雅一<sup>†</sup> 植木 一也<sup>††</sup> 小林 哲則<sup>†</sup>

<sup>†</sup> 早稲田大学理工学部 〒169-8555 東京都新宿区大久保 3-4-1

<sup>††</sup> NEC ソフト株式会社 〒136-8608 東京都江東区新木場 1-18-7

**あらまし** 局所保存射影 (LPP) を拡張し、クラス距離を重みとする局所保存射影 (CDLPP) を提案する。LPP は、近傍の幾何学的距離の情報を扱い座標変換を行うが、CDLPP ではクラス間距離を重みとして利用し、座標変換を行う。具体的には、近傍クラスのデータ間により大きな重みを与えることで、近傍クラスのデータ構造を保存するように変換行列の学習を行う。顔画像を用いた年齢推定実験において、CDLPP により変換した空間において識別を行ったときの性能が、PCA、LDA、LPP により変換した空間において識別を行ったときの性能を上回ることがわかった。  
**キーワード** LPP, CDLPP, 特徴抽出, 顔画像, 年齢推定

## Class-Distance Weighted Locality Preserving Projection and Its Application To Facial Image Based Age Classification

Masakazu MIYA<sup>†</sup>, Kazuya UEKI<sup>††</sup>, and Tetsunori KOBAYASHI<sup>†</sup>

<sup>†</sup> Science and Engineering, Waseda University Okubo 3-4-1, Shinjuku-ku, Tokyo, 169-8555 Japan

<sup>††</sup> NEC Soft, Ltd. Shinkiba 1-18-7, Koto-ku, Tokyo 136-8606 Japan

**Abstract** A new type of feature transformation technique that extends locality preserving projection (LPP) is proposed and successfully applied to age classification using facial images. We call this technique “class-distance weighted locality preserving projections (CDLPP)”. CDLPP performs coordinate transformation using distances between classes as weights while LPP performs coordinate transformation using information on nearby geometric distances between data. In the proposed method, transformation matrices are trained so as to preserve nearby class data structures by weighting the data of nearby classes. An age classification test shows the effectiveness of the proposed method: it reduced the errors of conventional methods such as PCA, LDA, and LPP.

**Key words** LPP, CDLPP, Feature Extraction, Facial Image, Age Classification

### 1. ま え が き

近年、顔画像認識技術の研究は盛んに行われ、様々な応用製品も普及している。その中でも、顔画像を用いて性別や年齢といった個人の属性を推定する技術は、マーケティングへの応用やヒューマンコンピュータインタラクションという観点から将来性がある技術として市場から期待されており、現在、活発に研究がなされている。

我々は、独自に多様な年齢の顔画像を網羅する大規模な性別・年齢画像データベースとして、Waseda human-computer Interaction Technology Database (WIT-DB) を構築し、顔画像の外観に基づく年齢推定手法について検討を行っている [1]-[4]。しかし、同じ環境 (照明条件) 下で様々な年齢の顔画像を収集することは困難であり、データベースには数万枚の画像が存在しているものの照明条件は同一ではなく、照明条件に対する年齢ごとのデータ数には偏りが生じている。そのため、多様

な照明条件で収録されたデータが存在しない年齢層のデータを識別する場合は、照明条件の影響を受け易い。

そこで本稿では、年齢推定における照明条件の違いを吸収するため、座標変換により年齢推定に有効な特徴のみを画像から抽出することを試みる。また、顔画像の画素値から座標変換によって抽出された年齢の特徴量は、実際の年齢の値と同様に、加齢にしたがって連続的に変化していき、連続的な量になるということが知られている [4]。よって、この連続的な年齢構造の特徴をうまく扱うことができれば、より識別に有効な特徴抽出ができるかと期待できる。顔認識分野においては、座標変換手法として、主成分分析法 (PCA) や判別分析法 (LDA) が広く用いられている。PCA は分散が最大となる軸を選択するように座標変換を行う。また、LDA は空間全体でクラスを判別しやすい軸を選択するように座標変換を行うが、クラス間の距離は考慮されていない。したがって、PCA や LDA では、年齢推定においては常に有効な特徴抽出をできるとは限らない。そこで、

空間全体を部分空間の集合と考え、年齢クラスの構造を保存するように座標変換を行うことで、より年齢特徴の構造を保存したまま識別に有効な特徴を抽出することができると考えられる。

その手法として、データの近傍構造を保存するように座標変換を行う manifold learning と呼ばれる手法があり、代表的な手法として、近年、locally linear embedding (LLE) [5] [6], Isomap [7] などが提案されている。その中でも、He らが提案した局所保存射影 (locality preserving projection ; LPP) は、PCA や LDA を上回る識別性能を与えており [8] [9]、様々な拡張がなされている [10]-[20]。例えば、Dewen らは 2D-PCA [21] の考えた方に基づき、2次元画像を効率的に圧縮できる 2D-LPP [10] [11] を開発し、LPP より性能が向上することを示した。しかし、LPP は教師なし学習であるため、そのまま用いても、照明などに代表される年齢推定に直接関係無い他の要因の影響を強く受け、識別に有効な情報が削られてしまい、識別率の劣化を招く可能性が高い。He らは、文献 [8] において LPP を教師ありの枠組へと発展させた、教師付き LPP を提案した。しかし、同一クラス内のデータ構造を均等に考慮するだけであり、LDA と等価な特徴抽出となることが知られている。これは、近傍構造を保存する本来の性質を損なっていると言える。Yum らは、クラスを考慮し、同一クラス内のデータに対してのみ均一でない重みを計算し軸を求める Discriminant LPP (DLPP) を提案した [12]。Zhao らは LPP において、クラス内のデータとクラス間のデータで別々にデータ間の重み行列を算出した locally discriminating projection (LDP) を提案した [13]。しかし、これらは異クラスの場合を同一に扱うだけで、近傍クラスの構造の保存を扱っていない。

本稿では、照明よりも年齢クラスの分離に有効な座標変換であり、年齢のような連続したクラスのラベル情報を扱えるように LPP を拡張した、Class-Distance Weighted Locality Preserving Projection (CDLPP) を提案する。年齢の連続的な特徴を、画像からの特徴抽出の段階で導入することで、年齢推定の識別率の向上を目指す。

以降、2. において、提案手法の基礎となる LPP について述べる。続いて 3. において、提案手法である CDLPP について述べる。次に、4. において、顔の静止画データベースを用いた年齢推定実験を行い、提案法の有効性について調査を行う。最後に 5. で本稿をまとめる。

## 2. LPP

提案する CDLPP を考える上でベースとなる LPP (Laplacianfaces) [8] [9] を紹介する。LPP は、データに備わっている幾何学的構造や局所構造を保存するように線形変換を行う手法である。今、部分的な多様体構造を有している  $n$  次元の  $N$  個のデータ  $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\} \in \mathbf{R}^n$  に対し、同一の局所的近傍構造を持った低次元のデータ  $\{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N\} \in \mathbf{R}^d (d < n)$  を、 $\mathbf{y} = \mathbf{A}^T \mathbf{x}$  なる線形変換により抽出することを考える。このとき、LPP は次のように定式化される。

$$\hat{\mathbf{y}} = \arg \min_{\mathbf{y}} \frac{1}{2} \sum_{i,j} (\mathbf{y}_i - \mathbf{y}_j)^2 W_{i,j} \quad (1)$$

$\hat{\mathbf{y}}$  は画像後の最適な低次元データのベクトルである。ここで、 $\mathbf{W}$  は局所行列であり、その要素  $W_{i,j}$  は、値が大きい程、 $\mathbf{x}_i, \mathbf{x}_j$  の局所性が高いことを示す。局所行列の決め方には任意性があり。文献 [8] では  $\mathbf{W}$  を次のように定義している。

$$W_{i,j} = \begin{cases} \exp(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{t}) & (\mathbf{x}_i \text{ が } \mathbf{x}_j \text{ の } k \text{ 近傍点}) \\ 0 & (\text{otherwise.}) \end{cases} \quad (2)$$

ここで、 $t$  は任意の定数を表す。次に、目的関数に対し、以下のような代数的変換を行う。

$$\begin{aligned} \frac{1}{2} \sum_{i,j=1}^n \|\mathbf{y}_i - \mathbf{y}_j\|^2 W_{i,j} &= \frac{1}{2} \sum_{i,j=1}^n \|\mathbf{A}^T \mathbf{x}_i - \mathbf{A}^T \mathbf{x}_j\|^2 W_{i,j} \\ &= \frac{1}{2} \sum_{i=1}^n \|\mathbf{A}^T \mathbf{x}_i\|^2 \left( \sum_{j=1}^n W_{i,j} \right) - \sum_{i,j=1}^n \mathbf{A}^T \mathbf{x}_i W_{i,j} \mathbf{A}^T \mathbf{x}_j \\ &\quad + \frac{1}{2} \sum_{j=1}^n \|\mathbf{A}^T \mathbf{x}_j\|^2 \left( \sum_{i=1}^n W_{i,j} \right) \\ &= \sum_{i,j=1}^n \mathbf{A}^T \mathbf{x}_i D_{i,j} \mathbf{A}^T \mathbf{x}_j - \sum_{i,j=1}^n \mathbf{A}^T \mathbf{x}_i W_{i,j} \mathbf{A}^T \mathbf{x}_j \\ &= \text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{D} \mathbf{X}^T \mathbf{A}) - \text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{W} \mathbf{X}^T \mathbf{A}) \\ &= \text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{A}) \end{aligned}$$

ここで、 $\mathbf{L} = \mathbf{D} - \mathbf{W}$ 、 $\mathbf{D}$  は対角行列である。

$$D_{i,j} = \begin{cases} \sum_{k=1}^n W_{i,k} & (i = j) \\ 0 & (i \neq j) \end{cases} \quad (3)$$

また、スケールの自由度を取り除く条件として、次の制約条件を付与する。

$$\mathbf{y} \mathbf{D} \mathbf{y}^T = \mathbf{I} \Rightarrow \mathbf{A}^T \mathbf{X} \mathbf{D} \mathbf{X}^T \mathbf{A} = \mathbf{I} \quad (4)$$

この制約は、画像先のスケールと角度を元の空間と高い類似性を保つようにする働きがある。これは、 $\mathbf{A} = \mathbf{0}$  となる自明な解の回避条件となる。以上を整理すると、LPP は次の最小化問題を解くことに帰着される。

$$\mathbf{A}_{opt} = \arg \min_{\mathbf{A}} (\mathbf{A}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{A}) \quad (5)$$

with the constraint

$$\mathbf{A}^T \mathbf{X} \mathbf{D} \mathbf{X}^T \mathbf{A} = \mathbf{I} \quad (6)$$

ここで、 $D_{ii}$  は  $\mathbf{x}_i$  周辺の局所性の度合を表す。 $D_{ii}$  が大きいほど  $\mathbf{x}_i$  は重要な値となる。He らの  $k$ NN を用いる LPP は、近傍にある二点、具体的には  $W_{i,j}$  の値の大きい  $\mathbf{x}_i$  と  $\mathbf{x}_j$  を近くに埋め込むように行列  $\mathbf{A}$  を決定する手法と言える。 $\mathbf{A}$  を求めるには、次の一般化固有値最小化問題を解く。

$$\mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{A} = \lambda \mathbf{X} \mathbf{D} \mathbf{X}^T \mathbf{A} \quad (7)$$

ここで、一般化固有値と一般化固有ベクトルをそれぞれ、 $\{\lambda_i\}_{i=1}^d$ 、 $\{\mathbf{a}_i\}_{i=1}^d$  で表す。一般性を失うことなく、 $\lambda_0 \geq \lambda_1 \geq \dots \geq \lambda_{l-1}$  と仮定すると、LPP の解  $\mathbf{A}_{opt}$  は次式で与えられる。

$$\mathbf{A}_{opt} = (\mathbf{a}_0, \mathbf{a}_1, \dots, \mathbf{a}_{l-1}) \quad (8)$$

ここで、 $\mathbf{A}_{opt}$  は  $n \times l$  次元の行列である。

### 3. Class-Distance Weighted Locality Preserving Projection(CDLPP)

LPPは、単純にデータ間の幾何学的距離関係を用いて類似度行列を算出し、次元圧縮を行う手法である。このときクラスのラベル情報を用いないため、年齢推定にそのまま用いた場合、年齢クラスの識別に有効な情報を抽出できるとは限らない。それに対し提案するCDLPPは、クラス間距離を重みとして利用し、近傍クラスのデータ間により大きな重みを与えることで、近傍クラスのデータ構造を保存するように座標変換を行う。つまり、LPPは教師なし学習であるのに対し、CDLPPはクラスのラベル情報を利用するという意味で教師あり学習の枠組となる。LPPとCDLPPの本質的な違いは、局所行列をデータそのものの距離で定義するか、データに付与されたクラスの距離で定義するかの違いであり、CDLPPにおいても式(5)の最適化問題を解くことで変換行列を求めることができる。データ  $\mathbf{x}_i, \mathbf{x}_j$  のクラスを  $C_i, C_j$  と表すと、CDLPPの局所行列  $W$  は以下のように定義できる。

$$W_{i,j} = \begin{cases} \exp(-\frac{|C_i - C_j|}{t}) & \text{if } C_i \neq C_j \\ 1 & \text{otherwise.} \end{cases} \quad (9)$$

ここで、 $t$  は任意の定数を表す。この局所行列は、クラスが近いデータ同士に大きな重みを与え、クラスが離れているデータ同士の重みは0となり、計算上互いに影響を及ぼさないことを意味する。この手法の利点としては、クラスのラベルが連続値を持つような問題を扱う場合、クラスの情報だけでなく、クラス間の情報をうまく扱えるという点が挙げられる。また、クラスラベルを用いた局所行列は扱う問題に応じて、任意に設定できる。例えば、以下のようなものも定義できる。

- $W_{i,j} = \frac{t}{|C_i - C_j|}$
- $W_{i,j} = \exp(-\frac{|C_i - C_j|^2}{t})$

本稿では、クラスは年齢となるが、本提案手法は連続した数値をクラスのラベル情報として持つタスクであれば応用が可能である。例えば、顔方向認識、視線方向認識、照度認識などが挙げられる。

#### 4. 年齢識別実験

本章では、提案手法の有効性を確認するために、様々な座標変換を用い、座標変換後のデータの分布と、年齢推定性能について調査を行った。

##### 4.1 画像データベース

本実験では、男性データと女性データを個別に扱い、それぞれの性別において、同じ人が学習データとテストデータに含まれないようにして2重交差検定(2-fold cross-validation)を行い、識別率を計測した。男性データは9499枚(セット1:4641枚, セット2:4858枚), 女性データは5466枚(セット1:2455枚, セット2:3011枚)である。年齢ごとの画像枚数は一定ではない。年齢の範囲としては3歳から69歳までを扱い、識別のカテゴリは合計67となる。64×48の顔画像にマスクを掛け、ヒストグラム平坦化処理を施した。座標変換を行う前のデータ

は男性は1486次元、女性は1308次元のベクトルとなる。

##### 4.2 評価項目

特徴抽出を行う際に利用する座標変換手法に対する年齢推定精度を評価する。本実験では、以下の5種類の座標変換手法を評価項目とする。

- PCA
  - LDA
  - LPP-kNN [8]
  - LPP-LS: local scaling [22] を局所行列に用いる [15].
  - CDLPP: クラス間情報を局所行列に埋め込む。( $t=2$ )
- ここで、dのlocal scalingとは以下のような局所行列を表す。

$$W_{i,j} = \exp(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{\sigma_i \sigma_j}) \quad (10)$$

$\sigma_i$  はデータ  $\mathbf{x}_i$  の局所的距離を表し、

$$\sigma_i = \|\mathbf{x}_i - \mathbf{x}_i^{(k)}\| \quad (11)$$

で定義される。 $\mathbf{x}_i^{(k)}$  は  $\mathbf{x}_i$  の  $k$  番目の近傍点を表す。 $k$  の値は経験的に7としている。教師なしの枠組の上、実験的な距離の定義であるが、文献[15]では局所行列として性能が高いことを実験的に示している。

##### 4.3 識別条件

識別器として多次元混合正規分布(Gaussian mixture model; GMM)を採用した。性別ごとに1歳刻みで年齢モデルを作成し、それぞれのモデルから出力される尤度が最大となる年齢を識別結果とした。分散行列は対角共分散行列を用いた。また、混合数は2とした。

性別ごとにセット1で変換行列、GMMを学習した場合は、セット2を用いて評価を行い、その組み合わせを変えて実験を行った。また、年齢識別は、人が判別しても困難であり、ある程度の年齢の幅の許容をもって判断する例が多い。そこで本稿では、正解以外にも、前後を許容した上下1歳以内、上下5歳以内に識別された場合の識別率も算出した。

また、出力結果の年齢と正解年齢の差を測るため、正解からの年齢差の平均値(平均年齢誤差)を算出した。平均年齢誤差を

$$d_{jk} = \frac{1}{n} \sum_{i=1}^n |C_j - C_k| \quad (12)$$

のように定義し、誤りの度合いを計測する。 $C_j$  は実年齢に基づくクラスのラベル、 $C_k$  は推定されたクラスのラベルである。これは実際の年齢と離れた年齢に識別されるにつれ、値が大きくなるような指標である。例えば、20歳の人が45歳に誤識別された場合は、25歳に誤識別された場合に比べて深刻であり、このような場合、この平均年齢誤差は大きくなる。

##### 4.4 写像の例

PCA, LDA, LPP-kNN, LPP-LS, CDLPPにより、年齢識別に有効な空間に写像可能かどうか、年齢ごとのデータがどのように分布しているかを確認するため、セット1で学習したときのセット1の写像結果を1次元目-2次元目、3次元目-4次元目というようにプロットした。ここでは、男性のデータセットからPCA, LDA, LPP-kNN, LPP-LS, CDLPPを用いて

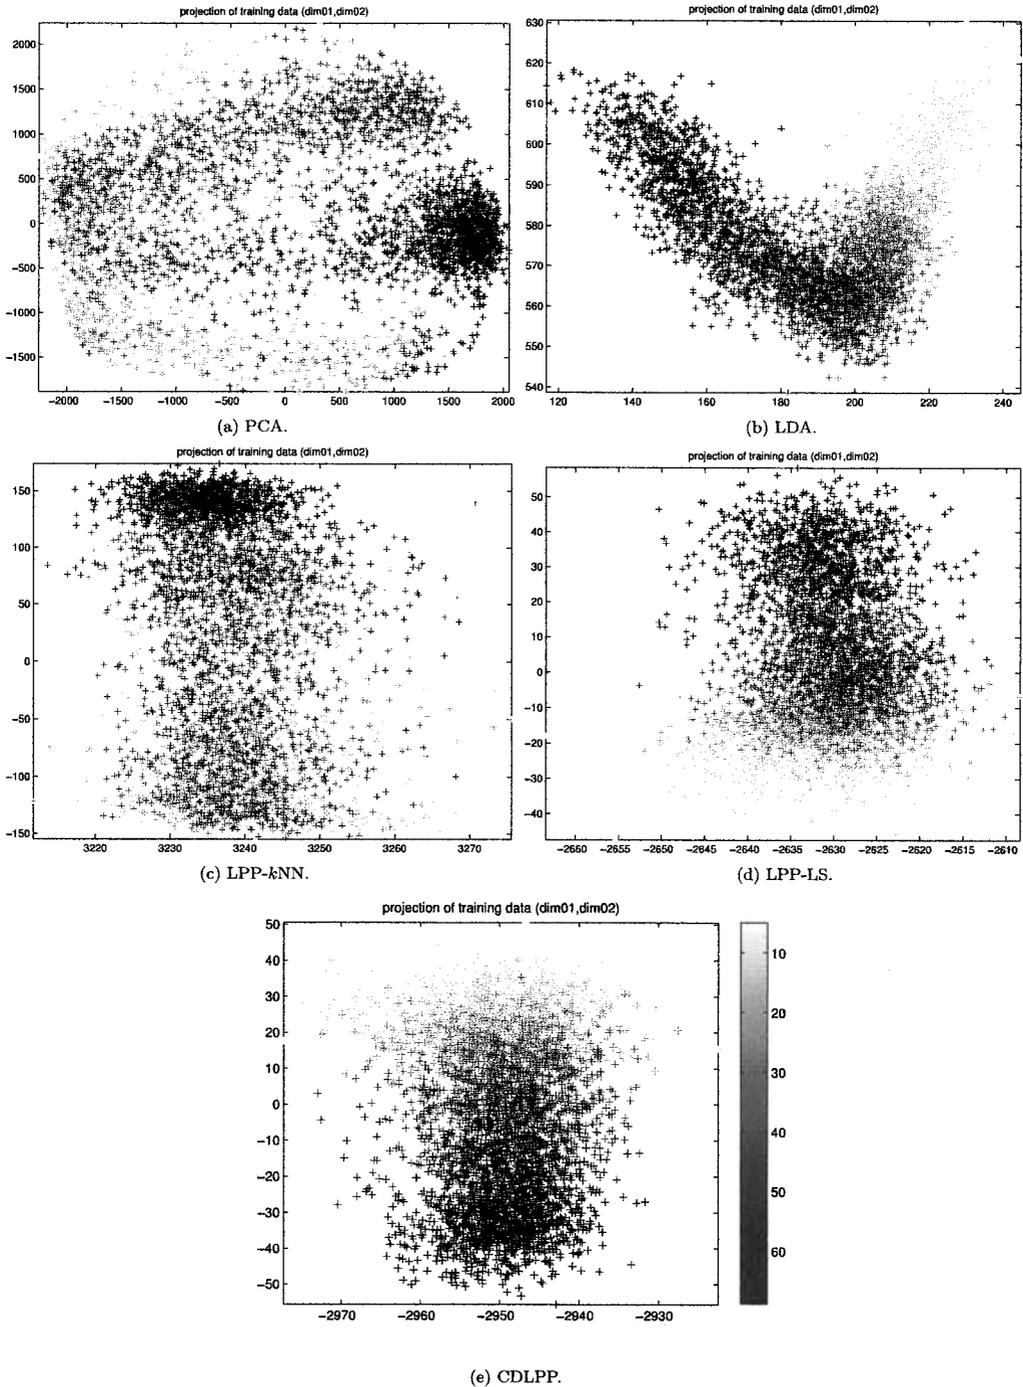


図1 PCA, LDA, LPP-kNN, LPP-LS, CDLPP による学習データ (男性) の写像結果。  
 横軸は1次元目, 縦軸は2次元目を表す。

Fig.1 The projected male learning data by PCA, LDA, LPP-kNN, LPP-LS and CDLPP.  
 Horizontal axis shows the first and vertical axis shows the second dimension.

表 1 年齢識別率 (男性). () 内は変換後の次元数.

Table 1 Age classification rates(%) using male data. () shows dimension of the transformed space.

特徴抽出手法	1 歳刻み	前後正解	5 歳以内正解
PCA	6.80 (38)	19.82 (37)	49.81 (41)
LDA	9.67 (49)	26.69 (43)	60.03 (10)
LPP-kNN	6.20 (48)	18.25 (49)	46.73 (32)
LPP-LS	8.51 (44)	22.67 (10)	58.62 (10)
CDLPP	11.98 (18)	30.56 (23)	66.64 (13)

表 2 年齢識別率 (女性). () 内は変換後の次元数.

Table 2 Age classification rates(%) using female data. () shows dimension of the transformed space.

特徴抽出手法	1 歳刻み	前後正解	5 歳以内正解
PCA	6.49 (31)	17.27 (36)	41.64 (49)
LDA	6.73 (49)	19.19 (33)	47.33 (22)
LPP-kNN	5.93 (36)	15.79 (36)	36.04 (39)
LPP-LS	6.79 (10)	18.28 (13)	43.12 (4)
CDLPP	8.93 (12)	25.92 (12)	60.56 (8)

写像した場合, 特に識別に有効と思われた最初の 2 次元のプロット例を図 1 に示す. 横軸は 1 次元目, 縦軸は 2 次元目を表す. 図において, 濃度が高いほど年齢が高いデータを表す. 図より, PCA を除いてはどの手法も年齢順にデータが分布していることが見て取れる. LDA は中年層周辺を軸に放物線を描くように分布しているのに対し, LPP, CDLPP は, 直線を描くように年齢が分布している. これより, LDA よりも大きな誤りを起こすことが少ないことが予想できる. LPP-kNN, LPP-LS, CDLPP の違いは, LPP-kNN の方が年齢ごとのクラス内分散が大きいことであり, 全体的な形状の違いは, どれも見受けられない. 年齢ごとの分離度に関しては, LDA と LPP-LS, CDLPP が比較的高いのに対し, PCA, LPP-kNN では, 特定の年齢に対してまとまったクラスは存在するものの, 分離度が低い結果となっている.

#### 4.5 年齢識別実験結果

各座標変換により抽出した特徴量を用いたときの年齢識別率を比較した. 1 歳刻みの正解 (correct), 前後 1 歳を許容として正解とする場合 (within 1-year), 前後 5 歳を許容として正解とする場合の識別率 (within 5-year) を算出した. 座標変換により 1 次元~50 次元にまで次元圧縮を行ったときの識別性能を調査し, 最高の性能を与えたときの認識率を, 男性は表 1, 図 2 に, 女性は表 2, 図 3 に示す. 表の括弧内は最高識別率を与えた次元数を示す. 図より男性, 女性共に 1 歳刻み, 前後 1 歳許容, 前後 5 歳許容全ての識別率において CDLPP は最高の性能を与え, 従来手法より改善が見られた. 5 歳許容の場合, CDLPP は LDA と比較して, 男性では 6.61 ポイント, 女性では 13.23 ポイント性能を改善した. これは, LDA が空間全体でクラスを判別しやすい軸を決定しているのに対し, CDLPP ではクラス間距離情報を扱い, 元の空間の構造を保存するように

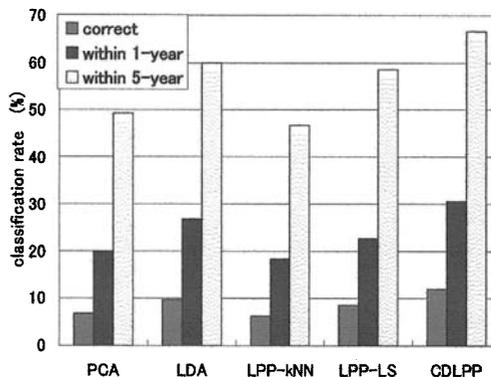


図 2 年齢識別率 (男性)

Fig. 2 The classification rate of age using male data.

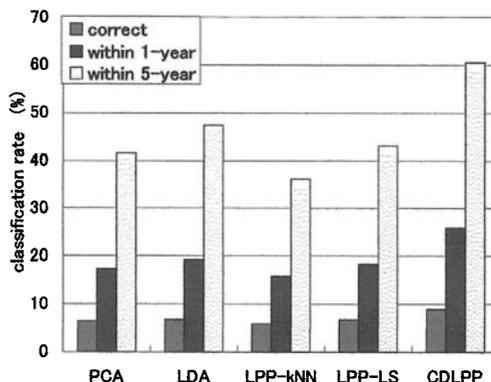


図 3 年齢識別率 (女性)

Fig. 3 The classification rate of age using female data.

軸を決定したことが年齢識別の精度向上に寄与したことを示している. なお, 過去の文献では, LPP が PCA や LDA を上回る性能を示したものがあるが, 本実験においては, 既存の LPP では PCA や LDA を上回ることは確認できなかった.

また, 図 4 は年齢識別結果における平均年齢誤差を表す. 図より, 最も CDLPP が誤差を減らし, 明確な間違いを削除していることを示している. CDLPP は従来手法で最も良い性能を与える LDA と比較して, 平均年齢誤差を, 男性では 5.10 歳から 4.95 歳に, 女性では 7.54 歳から 6.65 歳に減少させた. 結果として, CDLPP は, 従来手法である PCA, LDA, LPP-kNN, LPP-LS に比べて優れているということが証明された.

## 5. まとめ

本稿では, LPP を拡張し, 近傍クラスのデータ間により大

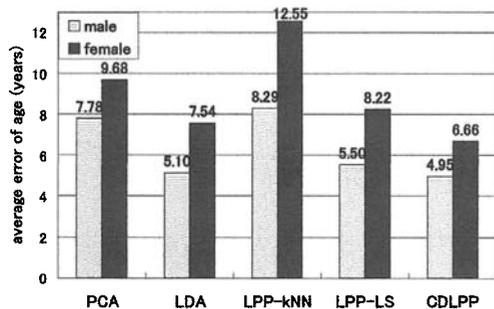


図4 平均年齢誤差  
Fig.4 Average error of age

きな重みを与えることで近傍クラスのデータ構造を保存するように座標変換を行う, CDLPP を提案した。CDLPP は, 従来の LPP とは異なり, 教師あり学習の枠組である。写像結果を観察し比較した結果, 従来手法よりも年齢識別に有効な特徴抽出ができることを確認した。また, 年齢識別実験では, 従来手法よりも CDLPP の識別率が向上したことを確認し, CDLPP の有効性を確認した。今後は, 写像結果の分布形状や年齢が連続値であることを利用し, 年齢推定の問題を識別問題ではなく regression 問題として捉え, 検討を行う予定である。

#### 文 献

[1] K. Ueki, H. Komatsu, S. Imaizumi, K. Kaneko, S. Imaizumi, N. Sekine, J. Katto and T. Kobayashi, "A method of gender classification by integrating facial, hairstyle, and clothing images," Proc. ICPR, pp.446-449, Aug. 2004.

[2] 植木一也, 林田輝英, 小林哲則, "多様な照明環境の顔画像を利用した年齢層の識別," 信学技報, PRMU, pp.13-18, Nov. 2005.

[3] K. Ueki, T. Hayashida and T. Kobayashi, "Two-dimensional Heteroscedastic Linear Discriminant Analysis for Age-group Classification," Proc. ICPR, pp.585-588, Nov. 2006.

[4] K. Ueki, T. Hayashida and T. Kobayashi, "Subspace-based Age-group Classification Using Facial Images Under Various Lighting Conditions," Proc. FGR, pp.43-48, April 2006.

[5] S. Rowis, and L. Soul, "Nonlinear Dimensionality Reduction by Locally Linear Embedding," Science, vol.290, no.5500, pp.2323-2326, Dec. 2000.

[6] L. Soul, and S. Rowis, "Think Globally Fit Locally; Unsupervised Learning of Low Dimensional Manifolds," J. Machine Learning Research, vol.4, pp.119-155, 2003.

[7] J. B. Tenenbaum, V. de Silva, and J. C. Langford, "A Global Gemotric Framework for Nonlinear Dimensionality Reduction," Science, vol.290, no.5500, pp.2319-2323, Dec.2000.

[8] X. He and P. Niyogi, "Locality preserving projection," Advances in Neural Infomation Processing System 16, pp.153-160, 2004.

[9] X. He, S. Yan, Y. Hu, P. Niyogi and H. Zhang, "Face Recognition Using Laplacianfaces," IEEE Trans. on Pattern Anal. Machine Intel., vol.27, pp.328-340, March 2005.

[10] H. Dewen, F. Guiyu and Z. Zongtan, "Two-dimensional locality preserving projections (2DLPP) with its application to palmprint recognition," Proc. Pattern Recognition,

vol.40, pp.339-342, 2007.

[11] C. Sibao, Z. Haifeng and K. Min, "2D-LPP:A Two-dimensional extension of locality preserving projections," Neurocomputing, vol.70, pp.912-921, 2007.

[12] W. Yum, X. Teng and C. Liu "Discriminant Locality Preserving Projections: A New Method to Face Representation and Recognition," Visual Surveillance and Performance Evaluation of Tracking and Surveillance, IEEE 2nd Joint, pp.201-207, Oct. 2005.

[13] H. Zhao, S. Sun, Z. Jing and J. Yang, "Local structure based supervised feature extraction," Pattern Recognition, vol.39, pp.1546-1550, 2006.

[14] 品川優貴, 杉山将, "ラベル付きマルチモーダルデータの埋め込み," 信学技報, NC, vol.105, no.544, pp.25-30, 2006.

[15] M. Sugiyama, "Local Fisher discriminant Analysis for Supervised Dimensionality Reduction," Technical Report TR06-0008, Department of Computer Science, Tokyo, Institute of Technology, Japan, 2006.

[16] C. Jian, L. Qingshan, Lu. Hanqing and C. Yen-Wei, "Supervised kernel locality preserving projections for face recognition," Neurocomputing, vol.67, no.8, pp.443-449, 2005.

[17] D. Cai, X. Han, J. Han, H.J. Zhang, "Orthogonal Laplacian-faces for for Face Recognition," IEEE Trans. Image Process., D-11, vol.15, no.11, pp.3609-3614, Nov. 2006.

[18] F. Guiyu, H. Dewen, Z. David, and Z. Zongtan, "An alternative formulation of kernel LPP with application to image recognition," Neurocomputation, vol.69, Issues.13-15, pp.1733-1738, 2006.

[19] Z. Lei and Z. Shanan, "Face recognition based on orthogonal discriminant locality preserving projections," Neurocomputing, vol.70, pp.1543-1546, 2007.

[20] 杜偉薇, 浦浜喜一, "クラスタリング写像を介する半教師付き局所保存射影," 信学技報, PRMU2006-211, no.2, pp.29-34, Feb. 2007.

[21] J. Yang, D. Zhang, A. F. Frangi and J. Yang, "Two-Dimensional PCA: A New Approach to Appearance-Based Face Representation and Recognition," IEEE Trans. on Pattern Anal. Machine Intel., vol.26, no.1, Jan. 2004.

[22] L. Zelnik-Monon and P. Perona, "Self-tuning spectral clustering," Advances in neural information processing systtem 17, Cambridge MA MIT Press, pp.1601-1608, 2005.