

耳介認証における判別分析法の比較

田島祐貴[†] 相馬貢士[†] 崔英泰[†] 渡部大志[†]

判別分析は欠落や傾きを含む正面顔画像を用いた認証に有効な手法である。しかし、PCA などの手法で正面顔と同程度の認証率を示し、顔にはない利点を持つ耳介に用いられた報告は余りない。

そこで、判別分析を耳介画像認証に適用しその有用性を示すと共に、各判別分析手法について認証率の比較を行った。また各判別分析アルゴリズムを組み合わせた 288 種類の手法についても同様に比較し、その有用性について検討した。実験には XM2VTS データベースを用いた。

カーネル法を用いた手法は他手法に比べ認証率の向上が顕著であり、最大で 97.8% の認証率を示した。また Null space LDA は、単体でも精度が高く、カーネル法との組み合わせでさらに高精度になった。

今後は、Random LDA など今回の実験では用いなかった判別分析について比較・検討を行う必要がある。また、判別分析以外の手法との組み合わせについて同様に検討する必要がある。

Comparison of Discriminant Analysis in Ear Recognition

Yuki Tajima[†] Koji Soma[†] Sai Hideyasu[†] Daishi Watabe[†]

Discriminant analyses are popular algorithms for face recognition and various discriminant analysis are proposed in thus far. In this study various discriminant analysis algorithms are thoroughly examined for ear biometrics. Experiment performed on XM2VTS database made 97.8% recognition rate using Null Kernel discriminant analysis.

1. 背景

パターン認証の分野において、判別分析を応用した手法は多数存在している。個人認証では、欠落や傾きを含む正面顔画像を用いた認証に有効な手法である。認証部位については正面顔だけではなく、鼻や耳などの顔の局所的部位を用いた個人認証の可能性も他の研究により報告されている。特に、耳は解剖学的に万人不同であることが示されており、耳介画像を用いた個人認証は他の部位に比べ、低解像度の画像でも認証可能、表情や化粧などの影響を受けにくい、経年変化による影響が少ないなどの利点がある。

2. 先行研究とこの研究の目的

耳介を個人認証に利用することは 1890 年にフランスの犯罪学者である Bertillon により提案され、米国では Iannarelli ら[1]の研究を端緒に 40 年以上にわたり犯罪者特定に利用され、今も研究が進められている。耳介を用いた個人の自動認証の研究で最も初期に報告されたものに篠原らのものがあり、モルフォロジー演算により得られたパターンスペクトラムを特徴ベクトルとして利用した。Moreno ら[2]は Compression Network と呼ばれるニューラルネットワークを利用した。結園ら[3]は耳介検出にテンプレートマッチング、認証に遺伝的アルゴリズムを利用した。Hurley ら[4]は画像を各画素が Gaussian アトラクタで与えられる力場へ変換する手法を導入した。また、Chen ら[5]は 3 次元情報と色情報を用いて耳輪と対耳輪を検出し、それらの表現と特徴点における局所局面パッチ表現を求める手法から成る 3 次元認証システムを提案した。

一方、顔認証の分野ではさまざまな判別分析手法が用いられた。基底空間に射影する際、Yu ら[6]はクラス間分散における基底を用い、Liu ら[7]はクラス内分散の零ベクトル空間を用いて主軸変換を行った。Loag ら[8]は目的関数におけるクラス間分散に自動的な重み付けを行った。Liu ら[9]は高次元特徴空間における判別分析の有用性を示している。顔認証以外の分野では不等分散判別分析と線形判別分析を結合した手法を坂井ら[10]が報告している。

以上に述べたような顔認証や他のパターン認証の分野で用いられる判別分析アルゴリズムは、耳介による個人認証にも有用である可能性がある。そこで当研究では、各判別分析アルゴリズムと各判別分析アルゴリズムを組み合わせ、288 種類の手法について認証率の比較を行い、実システムに組み込むのに適当であるかを検討した。

[†] 埼玉工業大学
Saitama Institute of Technology

3. 理論

3.1 判別分析について

判別分析とは、事前に与えられたデータの分類が既知であるとき、新たに入力するデータがどのグループに属するかを判断する基準となる判別関数を求める手法である。パターン認証の分野においては、判別式を求めるのではなく、データの判別を行うのに適した次元空間への圧縮を行う。

特徴ベクトル x を線形の次元圧縮写像により、

$$y = Ax \quad (1)$$

のように変換し、低次元への写像データ y を得る。このとき、変換行列 A は判別基底 (Discriminant Criterion) と呼ばれる。行列 A は (2) 式を満たす。ここで (3) 式はクラス間分散行列、(4) 式はクラス内分散行列である。

$$J = \frac{A^T S_b A}{A^T S_w A} \rightarrow \max \quad (2)$$

$$S_b = \frac{1}{K} \sum_{c=1}^K (\mu_c - \mu)(\mu_c - \mu)^T \quad (3)$$

$$S_w = \sum_{c=1}^K \frac{N_c}{N} S_c \quad (\because S_c = \sum_{i(c)=1}^{N_c} (x_i - \mu_c)(x_i - \mu_c)^T) \quad (4)$$

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad \mu_c = \frac{1}{N_c} \sum_{i=1}^{N_c} x_i$$

K はクラス数、 N は学習データ数、 N_c はクラス c に属する学習データ数を表す。

3.2 判別基底の選び方

元データの次元数が判別基底の本数よりも非常に多い場合、固有値問題を解く際にクラス内分散行列が退化する (SSS 問題)。この問題を解決するための手法として以下のものが挙げられる。

3.2.1 PCA+LDA

元データに対して主成分分析 (PCA) による射影を行い、その射影空間上で LDA による変換を行う。この手法は Belhumeur ら [11] の他、複数の研究者により報告されている。今回の実験では SSS 問題解決のために、PCA を用いることで元データの次元を削減し、その上で各種判別分析手法を用いている。

3.2.2 Direct LDA (DLDA) [6][11]

元データのクラス間分散における寄与率を持つ固有ベクトルを基底とした次元圧縮を行い、判別基底を求める。まず、クラス間分散をベクトル空間に射影し、正規直交基底行列 Z を求める。

$$Y^T S_b Y = D_b > 0 \quad (5)$$

$$Z = Y D_b^{-1/2} \quad (6)$$

行列 Z をもちいてクラス内分散行列をベクトル空間に射影し、基底行列 U を求める。

$$U^T Z^T S_w Z U = D_w \quad (7)$$

(6), (7) 式の行列 U, Z を用いて判別基底行列 A を求める。

$$A = U^T Z^T \quad (8)$$

(8) 式で得られた判別基底行列 A より、元データを判別空間へ変換する。その際、基底行列 A は固有値行列 D_w により正規化される。

$$D_w^{-1/2} A x \rightarrow x^* \quad (9)$$

3.2.3 Null space LDA (NLDA) [7]

元データのクラス内分散における寄与率を持たないベクトルを基底とした次元圧縮を行い、判別基底を求める。クラス内分散を寄与率を持たないベクトル空間に射影し、基底行列 Y を求める。

$$Y^T S_b Y = 0 \quad (10)$$

行列 Y を用いてクラス間分散行列をベクトル空間に射影し、基底行列 U を求める。

$$U^T Y^T S_b Y U = D_w \quad (11)$$

(10), (11) 式の行列 U, Z を用いて判別基底行列 A を求める。

$$A = U^T Y^T \quad (12)$$

(12) 式の判別基底行列 A より、元データを判別空間へ変換する。

$$A x \rightarrow x^* \quad (13)$$

3.3 目的関数

判別基底を求めるための目的関数について、LDA はクラス内分散とクラス間分散の

相関比を最大にする(2)式を用いたが、これを応用した手法を以下に挙げる。

3.3.1 Power LDA (PLDA) [10]

LDA((14)式)と不等分散判別分析(HAD)((15)式)を結合した手法で、クラス内分散を累乗し、データ全体に対する個々のクラスの影響を考慮している。

$$J(A, m) = \frac{A^T S_b A}{A^T \left(\sum_{c=1}^K P_c S_c \right) A} \rightarrow \max \quad (14)$$

$$J(A, m) = \frac{A^T S_b A}{A^T \left(\prod_{c=1}^K S_c^{P_c} \right) A} \rightarrow \max \quad (15)$$

$$J(A, m) = \frac{A^T S_b A}{A^T \left(\sum_{c=1}^K P_c S_c^m \right)^{1/m} A} \rightarrow \max \quad (16)$$

(16)式の分母部分について $m > 1$ のとき分散の大きいクラスが支配的となり $0 < m < 1$ のとき分散の小さいクラスが支配的になる $m = 1$ のときはLDAの $m = 0$ のときはHDAの目的関数と近似する。

3.3.2 Fractional LDA (FLDA)

Fractional LDAはG.Daiら[12]の考えを元に、Leeら[13]によって報告された。クラス間分散行列を求める際に、各クラス間との距離を累乗した重み付けを行う。クラス間の距離が大きいものほど、分散行列に影響する割合が大きくなる。

$$S_b = \sum_{i=1}^{K-1} \sum_{j=i+1}^K n_i n_j \omega(d_{ij}) (\mu_i - \mu_j) (\mu_i - \mu_j)^T \quad (17)$$

$$\omega(d_{ij}) = (d_{ij})^p \quad (\because p \geq 3)$$

3.3.3 Weighted LDA (WLDA) [8]

クラス間分散行列を求める際に、クラス内分散行列の分散を考慮した、マハラノビス距離を重みとして重み付けを行う。

$$S_b = \sum_{i=1}^{K-1} \sum_{j=i+1}^K n_i n_j \alpha(\Delta_{ij}) (\mu_i - \mu_j) (\mu_i - \mu_j)^T \quad (18)$$

$$\Delta_{ij} = \sqrt{(\mu_i - \mu_j)^T S_w^{-1} (\mu_i - \mu_j)}$$

$$\alpha(\Delta_{ij}) = \frac{1}{2\Delta_{ij}^2} \operatorname{erf} \left(\frac{\Delta_{ij}}{2\sqrt{2}} \right)$$

erfは誤差関数である。

3.3.4 最大化から最小化へ

相関比の逆数を目的関数として採用した場合、最大化ではなく最小化する基底を求めることとなる。

$$J(A) = \frac{A^T S_w A}{A^T S_b A} \rightarrow \min \quad (19)$$

3.3.5 分散の相関比 (/sb, /st)

目的関数にクラス間分散とクラス内分散の相関比ではなく、クラス間分散と全分散の相関比を用いる。

$$J(A) = \frac{A^T S_b A}{A^T S_t A} \rightarrow \max \quad (20)$$

3.3.6 固有値問題を解く際の行列

目的関数において、固有値問題を解くときの行列について、非対称であれば(21)式で、対称であれば(22)式で求める。

$$(S_w^{-1} S_b) A = \lambda A \quad (21)$$

$$(D_w^{-1/2} U_w^T S_b U_w D_w^{-1/2}) V_b = \lambda V_b \quad (22)$$

$$\rightarrow A = U_w D_w^{-1/2} V_b$$

3.4 カーネル法

可測空間のデータを高次元特徴空間へと写像する手法のことで、非線形判別のために用いられる。一般に、元の空間から高次元特徴空間Hへの写像を行うと、その特徴空間上での計算は非常に困難となるため、カーネルトリックと呼ばれる手法を用いる(23)。ここでΦは変換写像を表す。

カーネルトリックとは、正定値カーネルを用いて高次元特徴空間への写像をデータの内積で表し、解析を容易にする手法である。正定値カーネルはいくつかあるが、今回は(24)式のガウシアンカーネルを用いる。

$$\langle \Phi(x), \Phi(y) \rangle_H = \langle k(\cdot, x), k(\cdot, y) \rangle = k(x, y) \quad (23)$$

$$k(x, y) = \exp\left(-\frac{1}{\sigma^2} \|y - x\|^2\right) \quad (24)$$

カーネル法と判別分析を組み合わせた手法も報告されており、その有用性が知られている[14][15][16]。

3.4.1 Kernel PCA

入力データを高次元特徴空間へと写像(25)した後 PCA を行う。PCA と同様にして分散共分散行列(26)を作り固有値問題(27)を解く。

$$x_i \rightarrow \phi(x_i) \quad (25)$$

$$S = \sum_{i=1}^n \bar{\phi}(x_i) \bar{\phi}(x_i)^T \quad (\because \bar{\phi}(x_i) = \phi(x_i) - \frac{1}{n} \sum_{m=1}^n \phi(x_m)) \quad (26)$$

$$(\lambda I - S)V = 0 \quad (27)$$

その際カーネルトリックを用いて計算を簡略化する。

$$K_{ij} := (\bar{\phi}(x_i), \bar{\phi}(x_j)) \quad (28)$$

$$\bar{K}_{ij} = K(x_i, x_j) - \frac{1}{n} \sum_{a=1}^n K(x_i, x_a) - \frac{1}{n} \sum_{a=1}^n K(x_a, x_j) + \frac{1}{n^2} \sum_{a,b=1}^n K(x_a, x_b) \quad (29)$$

(29)式は中心化グラム行列であり、実計算ではこの行列から固有値問題を解く。

$$(\lambda I - \bar{K})V = 0 \quad (30)$$

行列 V が正規直交行列であるとき、

$$g = \lambda^{-1/2} V \quad (31)$$

行列 g が Kernel PCA における基底行列となる。

3.4.2 Kernel LDA (KDA)

入力データを高次元特徴空間へと写像する。その後、LDA と同様にしてクラス内分散行列とクラス間分散行列を写像空間から算出し、目的関数から判別基底を求める。

ここで、クラス間分散行列やクラス内分散行列はカーネル関数を用いて直接的に書き換えることが出来ない。そのため、Kernel PCA で次元圧縮した後に LDA を行う手法や、一般化特異値分解と組み合わせた手法が提案されている。

また、クラス間分散行列とクラス内分散行列との相関関係をカーネル関数を用いて置き換えることが可能であり、これを用いた一般化判別分析 (GDA) が報告されている[17]。

4. 実験

4.1 システム概要

今回実験に用いたシステムの構成を図1に示す。

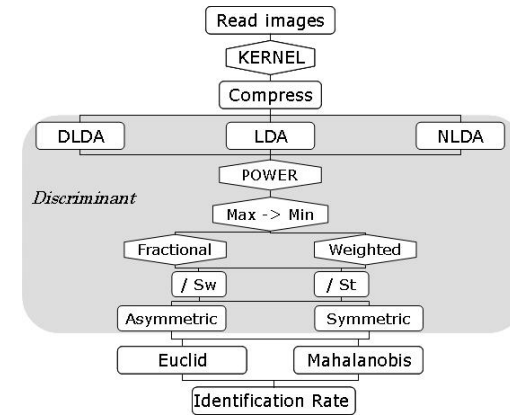


図1 システム概要図

画像の読み込み、カーネル法、次元圧縮、判別分析、内積による類似度、ランクの取得からなるシステムを構築した。判別分析の各手法を加えると、11の手順で認証を行う。図中の長方形で示す手法は必須、六角形で示す手法は任意の手法である。判別分析の組み合わせが288種類、内積による類似度の計算が2種類で、計576種類の手法について比較を行った。

4.2 実験対象

顔画像データベース XM2VTS[16]は M2VTS で獲得したデータベースである。XM2VTS[18]の横顔画像から、右耳の部位だけを切りだし、ヒストグラム均等化を行った画像を用いた。画像枚数は各人4枚、121名の計484枚。その中から学習データは各人3枚、121名の計363枚を用いた。登録データは学習データを3つに分け、そ

のうちの1セット, 各人1枚, 121名の計121枚を用いた。比較データは学習データに含まれない各人1枚, 121人の計121枚を用いた。



図2 用いた画像のサンプル

4.3 実験方法

288種類の判別分析手法について2種類の類似度計算を行いそれぞれランクを求め、ファーストランクの数から認証率を算出する。

4.3.1 類似度計算

類似度計算に、判別基底から得られた登録データと比較データの判別係数で内積を取ったものを用いた。係数は正規化を行った。登録データの係数行列をG, 比較データをPとすると、ユークリッド内積は(32)で、マハラノビス内積は(33)式で表される。

$$-1 \leq \left(\frac{G}{\|G\|}, \frac{P}{\|P\|} \right) \leq 1 \quad (32)$$

$$-1 \leq \left(\frac{G}{\sqrt{G^T \Sigma_G^{-1} G}}, \frac{\Sigma_G^{-1} P}{\sqrt{P^T \Sigma_G^{-1} P}} \right) \leq 1 \quad (33)$$

マハラノビス内積を求める際、係数の正規化には登録データの共分散行列の逆行列 Σ_G^{-1} を用いた。

4.3.2 認証率

本人同士の類似度の値を順位づけした時の順位の度数分布をランクと呼ぶ。特に1番目のランクについて、ファーストランクと呼ぶ。認証率はファーストランクの値とクラス数の比により算出する。

5. 実験結果

全288通りの判別分析手法の内、一番認証率が高かった手法は「全分散を分母とした目的関数の最大化によるKDA」であった。また、カーネル法については認証率が高い組み合わせのほとんどに含まれていた。そこで、カーネル法を用いることで認証率がどのように変化するか、全分散を分母とした目的関数を用いることで認証率がどのような影響を与えるかを実験した。

また、全体的に見て高い精度を示していたのはNLDAである。そこで、同ステップの処理であるPCA+LDA, DLDAと比較して、どの程度精度に差が出るかを実験した。

5.1 カーネル法の有無による比較

PCA+LDA, DLDA, NLDAの3つの手法について、カーネル法を適用しなかった手法とカーネル法を適用した手法をそれぞれ比較した。その際、類似度計算にはユークリッド内積を用いた。

各手法のRank one Recognition Rateを表1に、Cumulative Match Characteristic(CMC)曲線を図3に示す。

表1 比較する各手法のRank one Recognition Rate

	Recognition Rate(%)		Recognition Rate(%)
PCA+LDA	95.52	KDA	96.76
DLDA	92.73	DKDA	93.6
NLDA	95.45	NKDA	96.57

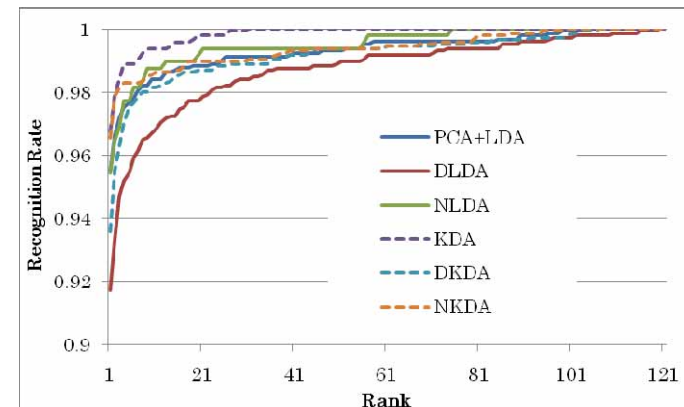


図3 カーネル法非適用手法と適用手法のCMC曲線

5.2 相関比最大化に用いる分散による比較

目的関数について、クラス間分散行列とクラス内分散行列の相関比を最大化する手法とクラス間分散行列と全分散行列の相関比を最大化する手法について、認証率による比較を行った。類似度にはユークリッド内積とマハラノビス内積を用いた。2つの手法の Rank one Recognition Rate を表 2 に、CMC 曲線を図 4 に示す。

表 2 Sw との相関最大化, St との相関最大化の Rank one Recognition Rate

	Euclid Recognition Rate(%)	Mahalanobis Recognition Rate(%)
/ Sw	95.52	92.56
/ St	95.52	94.28

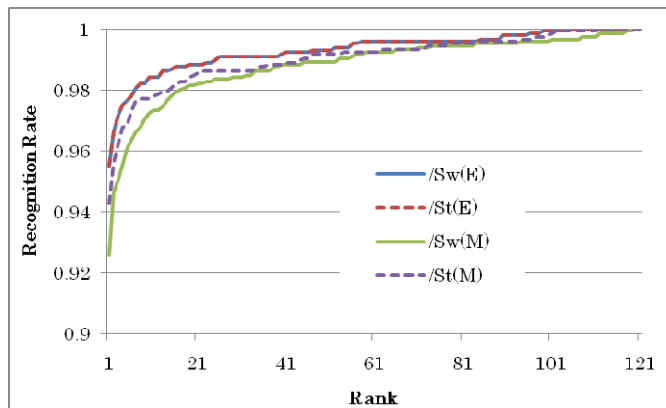


図 4 St との相関最大化, Sw との相関最大化の CMC 曲線

5.3 基底の取り方による比較

判別基底 A の求め方が異なる, PCA+LDA, DLDA, NLDA の 3 つの手法について、認証率による比較を行った。類似度計算にはユークリッド内積とマハラノビス内積を用いた。

各手法の Rank one Recognition Rate を表 3 に、CMC 曲線を図 5 に示す。

表 3 LDA, DLDA, NLDA の Rank one Recognition Rate

	Euclid Recognition Rate(%)	Mahalanobis Recognition Rate(%)
PCA + LDA	95.52	92.56
Direct LDA	91.74	91.32
Null space LDA	95.45	94.42

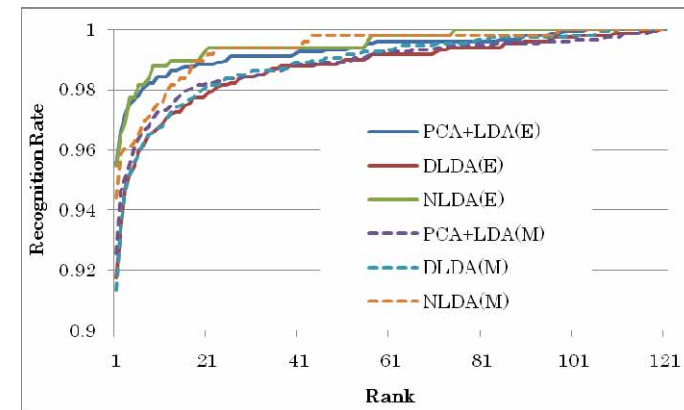


図 5 LDA, DLDA, NLDA の CMC 曲線

6. まとめ

カーネル法を用いた手法と用いなかった手法を比較すると、用いなかった手法と比べて認証率が上昇していることがわかる。カーネル法を組み合わせた手法が認証率の高い順で上位に多くあることから、精度の向上という面で有用であると言える。処理中にカーネルの計算が含まれることから、一般的な判別分析手法と比べて実行時間は増えると考えられる。

相関比に用いる分散については、本実験では大きな差は見られなかった。他にも目的関数から基底を求める部分で工夫した手法では認証率の増加はあまり見られなかった。

基底の取り方による比較では PCA+LDA と Null space LDA が高い認証率であった。その中で Null space LDA は単体での精度も高く、カーネル法との組み合わせでさらに精度が上がるが、その他の手法との組み合わせでは精度の変化が見られなかった。

Direct LDA に関しては、他の手法と組み合わせを行わない場合の方が組み合わせた場合より高い精度を示していた。判別を考慮した処理を行ったため、のちに行う重みづけなどの処理がノイズになってしまったと考えられる。

Null space LDA と Direct LDA に関して、通常の LDA よりも実行時間が非常に速かった。これは、どちらの手法も入力データの基底が少ない為であると考えられる。Null space LDA は他の基底の取り方に比べて高速で、性能も良いことがわかる。

以上からカーネル法が精度向上に有用であること、Null space LDA が実行速度の点で有用であることがわかった。一部の手法について認証率の向上が見られないものがあったが、その点については手法を組み合わせることから本来の利点を生かせなかったと考えられる。

今後の課題について、Random LDA や Fuzzy LDA など、今回の実験で用いなかった判別分析手法が報告されているので、それらを加えた実験が挙げられる。また、判別分析手法以外との組み合わせについても同様に実験を行うことも挙げられる。特に、Gabor Jet との組み合わせについては、試験的に実験した結果高い認証率を示した。

参考文献

- 1) A. Iannarelli, "Ear Identification", Forensic Identification series. Paramount Publishing Company, Fremont, California 1989
- 2) B. Moreno and A. Sanchez, "On the Use of Outer Ear Images for Personal Identification in Security Applications," IEEE 33rd Annual Intl. Conf. on Security Technology, pp. 469-476, 1999
- 3) T. Yuizono, Y. Wang, K. Satoh, and S. Nakayama, "Study on Individual Recognition for Ear Images by Using Genetic Local search", Proceedings of the 2002 Congress on Evolutionary Computation (CEC2002), pp.237-242, 2002.
- 4) D. J. Hurley, M. S. Nixon, and J. N. Carter, "Force Field Energy Functionals for Image Feature Extraction," Image and Vision Computing Journal, Vol. 20, pp. 311-317, 2002.
- 5) H. Chen and B. Bhanu, "Human Ear Recognition in 3D," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 29, 4, pp. 718-737, 2007.
- 6) H. Yu, J. Yang, "A direct LDA algorithm for high dimensional data—with application to face recognition", Pattern Recognition 34 (10) 2067–2070, 2001
- 7) Wei Liu, Yunhong Wang, Stan Z. Li, Tieniu Tan, "Null Space Approach of Fisher Discriminant Analysis for Face Recognition", ECCV Workshop BioAW, 2004
- 8) M. Loog, R.P.W. Duin, R. Haeb-Umbach, "Multiclass linear dimension reduction by weighted pairwise Fisher criteria", IEEE Trans. Pattern Anal. Mach. Intell, 23 (7) (2001) 762–766
- 9) Q.S.Liu, R.Huang, H.Q.Lu and S.D.Ma, "Face Recognition Using Kernel Based Fisher Discriminant Analysis", In the Proc. of. Int. Conf. Automatic Face and Gesture Recognition, pp. 197-201, Washington DC, USA, May, 2002.
- 10) 坂井誠, 北岡教英, 服部佑哉, 中川聖一, 武田一哉, "判別分析に基づく音響特徴と識別学習の組み合わせによる単語音声認識", Signal Processing and Its Applications, 2007. ISSPA 2007. 9th

International Symposium on Volume , Issue , 12-15 Feb. 2007 Page(s):1 – 4

- 11) H. Yu, J. Yang, "A direct LDA algorithm for high dimensional data—with application to face recognition", Pattern Recognition 34 (10) 2067–2070, 2001
- 12) G. Dai, Y.T. Qian, and S.Jia, "A kernel fractional-step nonlinear discriminant analysis for pattern recognition", In Proceedings of the Eighteenth International Conference on Pattern Recognition, volume 2, pages 431-434, August 2004
- 13) Lee Hui Kueh, Jon-Tark Lee, "Face Recognition Using Linear Discriminant Analysis (LDA) of Principal Component Analysis (PCA)", ISIS 2007 Proceedings of the 8th Symposium on advanced intelligent systems, 2007. 9
- 14) Heiko Hoffmann, "Kernel PCA for Novelty Detection", Pattern Recognition, Vol. 40, No. 3. (2006), pp. 863-874
- 15) Q.S.Liu, R.Huang, H.Q.Lu and S.D.Ma, "Face Recognition Using Kernel Based Fisher Discriminant Analysis", In the Proc. of. Int. Conf. Automatic Face and Gesture Recognition, pp. 197-201, Washington DC, USA, May, 2002.
- 16) W.U. Xiao-Jun, J. Kittler, Y. Jing-Yu, K. Messer, W. Shi-Tong, "A new kernel direct discriminant analysis (KDDA) algorithm for face recognition", in: Conference on British Machine Vision, Kingston University, London, September 7-9, 2004.
- 17) G.Baudat and F.Anouar, "Generalized Discriminant Analysis Using a Kernel Approach", Neural Computation, vol. 12, no. 10, pp. 2385-2404, 2000.
- 18) K.Messer, J.Matas, J.Kittler, J.Luettin, G.Maitre, "XM2VTSDB:the extended M2VTS Database", Proceedings 2nd Conference on Audio and Video-base Biometric Personal Verification (AVBPA'99) Washington DC, (1999) SVSSP URL:<http://www.ee.surrey.ac.uk/Research/VSSP/xm2vtsdb/>

著者紹介



田島祐貴 (非会員)

2009年、埼玉工業大学工学部卒業。主として画像処理に関する研究に従事。




相馬貢士 (非会員)

2009年、埼玉工業大学工学部卒業。現在、埼玉工業大学大学院システム工学専攻博士前期課程在学中。主として画像処理に関する研究に従事。



崔英泰 (非会員)

2002年，埼玉工業大学工学部卒業．2007年，埼玉工業大学大学院システム工学専攻博士前期課程修了．現在，埼玉工業大学大学院システム工学専攻博士後期課程在学中．主として画像処理に関する研究に従事．



渡部大志 (正会員)

2000年，東北大学大学院理学研究科数学専攻博士後期課程修了．2001年，埼玉工業大学工学部講師．2008年，埼玉工業大学工学部准教授．主として数理情報に関する研究に従事．博士（理学）．