

Title	固有空間法と重判別分析による顔画像の個人性と表情の解析
Author(s)	黒住, 隆行
Citation	
Issue Date	1999-03
Type	Thesis or Dissertation
Text version	author
URL	http://hdl.handle.net/10119/1243
Rights	
Description	Supervisor:小谷 一孔, 情報科学研究科, 修士

修士論文

固有空間法と重判別分析による顔画像の個人性と表情の解析

指導教官 小谷 一孔 助教授

北陸先端科学技術大学院大学
情報科学研究科情報処理学専攻

黒住 隆行

1999年2月15日

要旨

人間のコミュニケーションにおいて顔が重要な役割をはたしていることが知られている。そして、ネットワークを介したコミュニケーションにおいて顔の重要な情報である個人性や表情が伝送できれば、より親密かつ効率の良いコミュニケーションができると考えられる。本研究はそのようなコミュニケーションを実現するために顔画像から個人性及び表情の解析を行うことを目的としている。

顔画像から個人性や表情を解析する代表的手法として主成分分析 (Principal Components Analysis; PCA) がある。PCA は抽出した特徴ベクトル (ex. 顔画像の輝度値, 顔形状, オプティカルフロー, etc) の集合から, 射影成分の分散が大きい射影軸をあらかじめ求めておき, 特徴ベクトルをその射影軸への射影成分 (主成分) で表す手法である。しかし, PCA により求めた主成分は個人性や表情, 照明等の様々な影響が混合した成分である。よって, PCA により個人性を解析する場合, 表情, 照明等のばらつきによって解析結果が大きく影響されるという問題がある。

このような影響を軽減する方法としてフィッシャーの線形識別を多クラスに拡張した重判別分析 (Multiple Discriminant Analysis; MDA) を用いる方法がある。MDA は級内分散と級間分散の比が大きい軸を求める手法である。本研究では従来の PCA に基づく固有空間法を変形して得た, 級間分散と級内分散の差が大きい軸を求める手法 (本稿では本手法のことをクラス特徴に基づく固有空間法 (Eigenspace Method based on Class features; EMC) と呼ぶ) を提案する。そして, EMC と MDA のそれぞれを使用し, 任意の顔パターンに対して個人性または表情の特徴を表す軸, すなわち EMC, MDA における固有ベクトルを導出する。その固有ベクトルで顔パターンを変換して得た特徴ベクトルにより個人性と表情の解析を行う。また, 手法の妥当性を示すため, クラス特徴に基づく固有空間法と重判別分析を 50 人の人物の個人識別と 7 表情の表情識別に適用した結果と固有ベクトルの表す顔画像の傾向も示す。

目次

1	はじめに	1
2	クラス特徴の解析手法	3
2.1	級間分散と級内分散	3
2.2	EMC による解析	5
2.3	MDA による解析	6
3	顔画像のクラス特徴解析	8
3.1	顔画像データベース	8
3.1.1	撮影条件	8
3.1.2	顔画像の正規化	10
3.2	個人性の解析	10
3.2.1	個人性の分離度と単一固有ベクトルによる識別率の関係	10
3.2.2	個人識別実験	14
3.2.3	固有ベクトルの表す顔画像の傾向	17
3.3	表情の解析	20
3.3.1	主観評価実験による顔画像の選び出し	20
3.3.2	表情の分離度と単一固有ベクトルによる識別率の関係	20
3.3.3	表情識別実験	23
3.3.4	固有ベクトルの表す顔画像の傾向	25
3.4	顔画像の正規化と主観評価の影響	25
3.4.1	輝度値の正規化の有効性	25
3.4.2	顔領域の切り出し範囲の影響	29
3.4.3	画像解像度の影響	29
3.4.4	目・鼻の特徴抽出精度の影響	31

3.4.5	主観評価との関係	32
4	まとめ	35
4.1	結果・考察	35
4.2	結論	38
4.3	今後の課題	38
	謝辞	39
A	定理の証明	42
A.1	定理 1 の証明	42

第 1 章

はじめに

人間はコミュニケーションにおいて言葉や文字などのバーバルな情報以外に，顔の表情，ジェスチャ，声の調子などのノンバーバルな情報をも伝達し，コミュニケーションの効率化を行っている．特に，感情の 55%は顔の表情で表現されるという心理学者 Mehrabian の報告があるように，顔の表情は重要である [1]．このことから，ネットワークを介した人間同士のコミュニケーションにおいて，顔の個人性や表情が伝送できれば，より親密かつ効率の良いコミュニケーションができると考えられる．本研究はこのようなコミュニケーションを実現するために顔画像から個人性及び表情の解析を行うことを目的としている．

顔画像から個人性や表情を解析する代表的手法として主成分分析 (Principal Components Analysis; PCA) がある [2, 3, 4, 5, 6, 7, 8]．PCA は抽出した特徴ベクトル (ex. 顔画像の輝度値，顔形状，オプティカルフロー，etc) の集合から，射影成分の分散が大きい射影軸をあらかじめ求めておき，特徴ベクトルをその射影軸への射影成分 (主成分) で表す手法である．しかし，PCA により求めた主成分は個人性や表情，照明等の様々な影響が混合した成分である．よって，PCA により個人性を解析する場合，表情，照明等のばらつきによって解析結果が大きく影響されるという問題がある．

このような影響を軽減する方法としてフィッシャーの線形識別を多クラスに拡張した重判別分析 (Multiple Discriminant Analysis; MDA) を用いる方法がある [9, 10]．MDA は級内分散と級間分散の比が大きい軸を求める手法である．本研究では従来の PCA に基づく固有空間法を変形して得た，級間分散と級内分散の差が大きい軸を求める手法 (本稿では本手法のことをクラス特徴に基づく固有空間法 (Eigenspace Method based on Class features; EMC) と呼ぶ) を提案する [11, 12]．そして，EMC と MDA のそれぞれを使用し，任意の顔パターンに対して個人性または表情の特徴を表す軸，すなわち EMC，MDA における固有ベクトルを導出する．その固有ベクトルで顔パターンを変換して得た特徴ベク

トルにより個人性と表情の解析を行う。

本研究では次の項目について検討する。

- EMC, MDA による個人性の解析
 - 個人性の分離度と単一固有ベクトルによる識別率の関係を示す。
 - 個人識別実験を行う。
 - 固有ベクトルの表す顔画像の傾向を示す。

- EMC, MDA による表情の解析
 - 表情の分離度と単一固有ベクトルによる識別率の関係を示す。
 - 表情識別実験を行う。
 - 固有ベクトルの表す顔画像の傾向を示す。

- 顔画像の正規化の影響を示す。
 - 輝度値の正規化の有効性を示す。
 - 顔領域の切り出し範囲の影響を示す。
 - 画像解像度の影響を示す。
 - 目・鼻の特徴抽出精度の影響を示す。
 - 主観評価との関係を示す。

第 2 章

クラス特徴の解析手法

2.1 級間分散と級内分散

解析したいクラスの集合を F とする．ここで， F は個人性を解析したい場合は各人物クラスの集合を，表情を解析したい場合は各表情クラスの集合を表す．各クラス $f \in F$ に対し M_f 枚の顔パターンが与えられているとする． $m = 1, 2, \dots, M_f$ 枚目の顔パターンを画像サイズ N の各画素の輝度値を要素とする N 次元ベクトル x_{fm} で表す．

ここでクラス f の m 枚目の画像 x_{fm} を N 次元空間でのある軸に射影したときの値を z_{fm} とし， z_{fm} の級間分散 S_B (図 2.1) と級内分散 S_W (図 2.2) を

$$S_B = \frac{1}{M} \sum_{f \in F} M_f (\bar{z}_f - \bar{z})^2 \quad (2.1)$$

$$S_W = \frac{1}{M} \sum_{f \in F} \sum_{m=1}^{M_f} (z_{fm} - \bar{z}_f)^2 \quad (2.2)$$

とする．ただし，

$$\bar{z} = \frac{1}{M} \sum_{f \in F} \sum_{m=1}^{M_f} z_{fm} \quad (2.3)$$

$$\bar{z}_f = \frac{1}{M_f} \sum_{m=1}^{M_f} z_{fm} \quad (2.4)$$

$$M = \sum_{f \in F} M_f \quad (2.5)$$

とする．ここで，図 2.3 のように級内分散に比べて級間分散が大きい軸に顔パターンを射影した方が解析に有利であると考えられる．このような軸を求める手法として EMC と MDA のそれぞれを用いる．

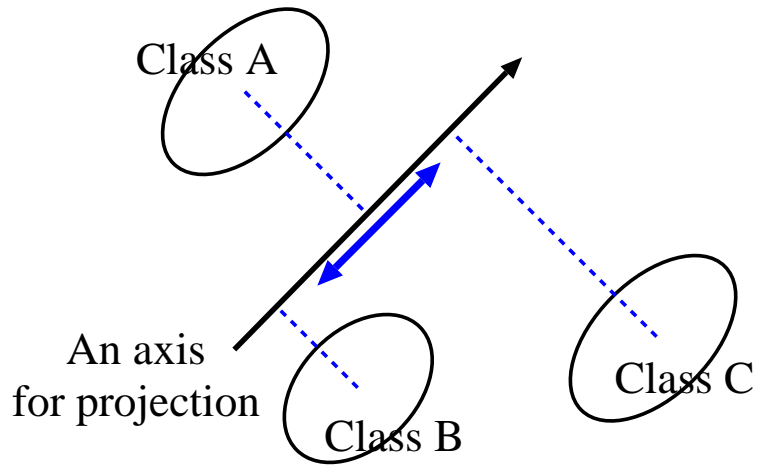


図 2.1: 級間分散

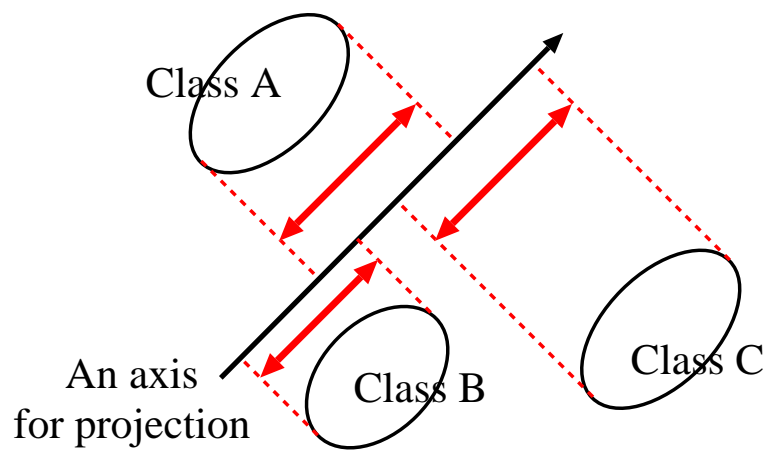


図 2.2: 級内分散

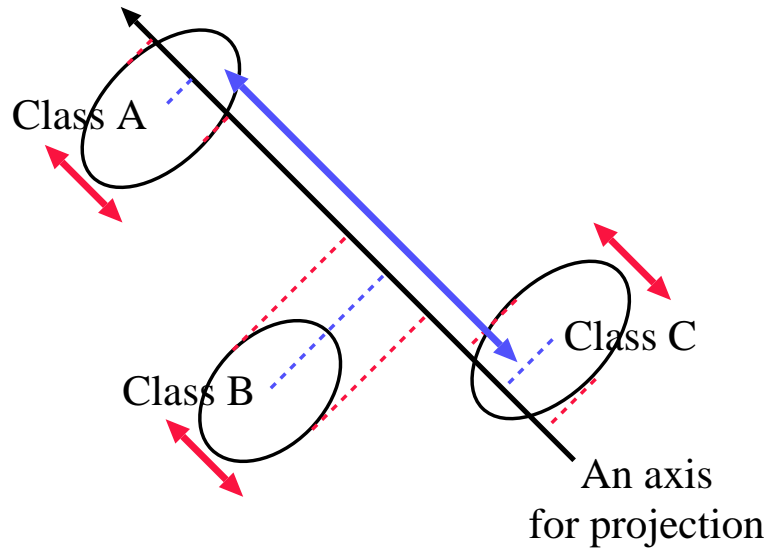


図 2.3: 級内分散に比べて級間分散が大きい軸

2.2 EMC による解析

\mathbf{x}_{fm} を K 個 ($K \leq M - 1$) の正規直交基底 $\phi_k = (\phi_{1k}, \phi_{2k}, \dots, \phi_{Nk})^t$, $k = 1, 2, \dots, K$ により次式で近似することを考える.

$$\tilde{\mathbf{x}}_{fm} = \sum_{k=1}^K z_{kfm} \phi_k + \bar{\mathbf{x}} \quad (2.6)$$

ただし,

$$\bar{\mathbf{x}} = \frac{1}{M} \sum_{f \in F} \sum_{m=1}^{M_f} \mathbf{x}_{fm} \quad (2.7)$$

とする. 従来の固有空間法では, ϕ_k を $\tilde{\mathbf{x}}_{fm}$ と元パターン \mathbf{x}_{fm} との平均 2 乗誤差を最小にするように選ぶが, 提案する EMC では, 理想的な近似パターンを各クラスの平均パターンと考え, ϕ_k を $\tilde{\mathbf{x}}_{fm}$ と各クラスの平均パターン $\bar{\mathbf{x}}_f$ との平均 2 乗誤差 $\varepsilon^2(\phi_k)$ を最小にするように選ぶ.

$$\varepsilon^2(\phi_k) = \frac{1}{M} \sum_{f \in F} \sum_{m=1}^{M_f} \|\bar{\mathbf{x}}_f - \tilde{\mathbf{x}}_{fm}\|^2 \quad (2.8)$$

$$\bar{\mathbf{x}}_f = \frac{1}{M_f} \sum_{m=1}^{M_f} \mathbf{x}_{fm} \quad (2.9)$$

これにより求められた K 個の ϕ_k を使って展開した結果から得られる K 次元ベクトル z_{fm} が解析に用いる次元圧縮された特徴ベクトルとなる．なお， z_{fm} の k 番目の要素は次式から得られる．

$$z_{kfm} = (\mathbf{x}_{fm} - \bar{\mathbf{x}})^t \phi_k \quad (2.10)$$

この ϕ_k は次式の固有値問題を解くことにより求まる (A.1節)．

$$S\phi_k = \lambda_k \phi_k \quad (2.11)$$

ただし，

$$\begin{aligned} S = & \frac{1}{M} \sum_{f \in F} M_f (\bar{\mathbf{x}}_f - \bar{\mathbf{x}})(\bar{\mathbf{x}}_f - \bar{\mathbf{x}})^t \\ & - \frac{1}{M} \sum_{f \in F} \sum_{m=1}^{M_f} (\mathbf{x}_{fm} - \bar{\mathbf{x}}_f)(\mathbf{x}_{fm} - \bar{\mathbf{x}}_f)^t \end{aligned} \quad (2.12)$$

とする．ここで式 (2.11) の左から ϕ_k^t を掛け，式 (2.10) を使うと，

$$\lambda_k = S_{Bk} - S_{Wk} \quad (2.13)$$

が得られる．ここで S_{Bk} と S_{Wk} は全クラス集合 F における z_{kfm} の級間分散と級内分散である．式 (2.13) は固有値 λ_k が級間分散と級内分散の差に等しいことを表している．ここで級間分散と級内分散の差をクラス集合 F の特徴の分離度 (以後，これを分離度 1 と呼ぶ) とみなすと， λ_k が大きいほどそれに対応する ϕ_k は F の特徴を良く表す固有ベクトルと考えられる．

2.3 MDA による解析

MDA は級間分散と級内分散の比を最大にするような線形変換を求める手法である．しかし，MDA を行うには級内変動行列が正定値対称行列でなければならない．これは MDA を適用するベクトルの次元数を L とすると， $L \leq M - |F|$ を満たすことと同等である．ただし， $|F|$ は F の要素数を表す．そこで L を小さくするために，本研究では PCA を行い次元圧縮された特徴ベクトルに対して MDA を行う．

\mathbf{x}_{fm} の PCA 後の L 次元特徴ベクトルを \mathbf{y}_{fm} とする．なお，本研究では $L = M - |F|$ に設定した．ここで MDA によって I 次元 ($I \leq |F| - 1$) に次元圧縮される特徴ベクトルの

i 番目の要素は，以下のように L 次元係数ベクトル $\mathbf{a}_i = (a_{1i}, a_{2i}, \dots, a_{Li})^t$, $i = 1, 2, \dots, I$ と \mathbf{y}_{fm} との線形結合で表される．

$$z_{ifm} = \mathbf{y}_{fm}^t \mathbf{a}_i \quad (2.14)$$

ここで S_{Bi} と S_{Wi} を z_{ifm} の級間分散と級内分散とする．そして，

$$\nu_i = \frac{S_{Bi}}{S_{Wi}} \quad (2.15)$$

を最大かつ z_{ifm} の各 i 成分が互いに無相関となるように \mathbf{a}_i を選ぶ．そして，式 (2.14) により得られる I 次元ベクトル \mathbf{z}_{fm} を用い解析を行う．

\mathbf{a}_i は次式の一般固有値問題を解くことにより求まる [10] ．

$$B\mathbf{a}_i = \nu_i' W \mathbf{a}_i \quad (2.16)$$

ただし，

$$B = \sum_{f \in F} M_f (\bar{\mathbf{y}}_f - \bar{\mathbf{y}})(\bar{\mathbf{y}}_f - \bar{\mathbf{y}})^t \quad (2.17)$$

$$W = \sum_{f \in F} \sum_{m=1}^{M_f} (\mathbf{y}_{fm} - \bar{\mathbf{y}}_f)(\mathbf{y}_{fm} - \bar{\mathbf{y}}_f)^t \quad (2.18)$$

$$\bar{\mathbf{y}} = \frac{1}{M} \sum_{f \in F} \sum_{m=1}^{M_f} \mathbf{y}_{fm} \quad (2.19)$$

$$\bar{\mathbf{y}}_f = \frac{1}{M_f} \sum_{m=1}^{M_f} \mathbf{y}_{fm} \quad (2.20)$$

とする．この B は級間変動行列， W は級内変動行列を表す．ここで式 (2.16) の左から \mathbf{a}_i^t を掛け，式 (2.14) を使うと， ν_i' は式 (2.15) の ν_i と一致する．この ν_i をクラス集合 F の特徴の分離度（以後，これを分離度 2 と呼ぶ）とみなすと， ν_i が大きいほど対応する \mathbf{a}_i は F の特徴を良く表す固有ベクトルと考えられる．

第 3 章

顔画像のクラス特徴解析

3.1 顔画像データベース

実験用の顔画像データベースとして眼鏡の無い 50 人 (男性 42 人 (内ヒゲを生やした男性 7 人), 女性 8 人) についてそれぞれ 7 表情 (Neutral, Happiness, Sadness, Anger, Disgust, Surprise, Fear) の合計 350 枚を用いた。表情は, 各個人に「7 つの感情を顔で最大限に表現してください。」と指示し, 鏡に向かって練習した後, 7 表情を最大に表現してもらったところを撮影した。尚, 表情の表現の仕方については, 各個人に自由に表現してもらった。以下に, 撮影条件, 正規化方法について示す。

3.1.1 撮影条件

撮影に使用した機材を表 3.1 に, モデルとカメラとの位置関係を図 3.1 に示す。モデルからカメラの距離は椅子の中心からカメラのフィルム面まで, 壁からモデルの距離は椅子の中心から壁までの距離である。モデルの顔の位置は, 床から目までの距離で決定した。カメラの角度は, ファインダをのぞいた時, 中心が鼻の頂点に合うように調整した。アンブレラの角度は, モデルから見て, アンブレラの軸が一点に見えるように調整した。モデルの背景については, 黒にすると背景と髪境界がはっきりしないため, 水色の布を背景とした。

撮影した写真は, フィルムスキャナによりデジタル化を行った。デジタル化する際のパラメータを表 3.2 に示す。また, フィルム毎の明るさ, 色の違いを補正するために, 背景の色が $RGB=(56,92,168)$ の値に近くなるように調整した。

表 3.1: 使用機器

カメラ	35mm 一眼レフ canon EOS5
レンズ	canon EF 100mm f=8
ストロボ	National PE-321SW
アンブレラ	口径 700mm
フィルム	デイトタイプ 35mm カラーリバーサルフィルム PROVIA 400
フィルムスキャナ	FILM SCANNER Nikon Scan LS-1000




図 3.1: モデルとカメラの位置関係

表 3.2: デジタル化のパラメータ

階調	モノクロ 256
スキャン解像度	2700 dpi
画像サイズ	1300 × 1600 pixels
γ 補正	2.2(フィルム特性のデータ標準)

3.1.2 顔画像の正規化

実験の前処理として顔画像の位置合わせをすることを目的に図 3.2 に示すように目と鼻の下を基準に顔の位置，大きさ，傾きの正規化を以下の手順で行なった．また，図 3.2 の各パラメータは表 3.3 のように設定した．正規化前の顔画像の例を図 3.3，正規化後の 7 表情の顔画像の例を図 3.4 に示す．

- (1) 左右の目と鼻の下に対応する領域の代表点を E_r , E_l , N とする．
- (2) E_r , E_l を結ぶ直線に鼻の下 N より垂線 ON を下ろす．
- (3) E_r , E_l が一定の長さ L , ON が E_r , E_l に対し垂直で一定の長さ D となるようにパターン全体をアフィン変換する．
- (4) E_r , E_l 点を基準としてパラメータ A , B , X , Y で定まる方形領域内を照合パターンとする．

また，撮影日によって照明条件が若干異なるため，ある個人で，照明が暗い画像が集中すると，照明の暗さが個人性とみなされてしまう恐れがある．そこで，簡易的に個人間の照明条件の違いの影響を吸収するため，平均値が 0.0，標準偏差が 1.0 となるような輝度値の正規化を行った．

表 3.3: 正規化のパラメータ

$D = 30$ pixels	$A = 25$ pixels	$X = 90$ pixels
$L = 40$ pixels	$B = 29$ pixels	$Y = 96$ pixels

3.2 個人性の解析

3.2.1 個人性の分離度と単一固有ベクトルによる識別率の関係

データベースの全ての顔画像を training data としたときの EMC, MDA, PCA の分離度 1, 分離度 2 を図 3.5, 図 3.6 に示す．尚，変換後のベクトルの成分は固有値の大きい成分から順に並べた．分離度 1 では EMC，分離度 2 では MDA が高い分離度を得た．




図 3.2: 顔の位置, 大きさ, 傾きの正規化




図 3.3: 正規化前の顔画像の例




図 3.4: 正規化後の 7 表情の顔画像の例

次に，単一の固有ベクトルで射影した成分を用いて training data について個人識別を行った．個人識別には入力パターンの射影成分 z_k との距離が最短となる辞書パターンの射影成分 \bar{z}_{kf} (training data の m についての z_{kfm} の平均; $f \in F$) に対応する f を入力顔画像の識別結果とした．距離は次式によって与えられる距離 D_k を使用した．

$$D_k = z_k - \bar{z}_{kf} \quad (3.1)$$

EMC の分離度 1 (EMC の固有値) と識別率の関係，MDA の分離度 2 (MDA の固有値) と識別率の関係を図 3.7，図 3.8 に示す．図 3.7 から，EMC の固有値が正の固有ベクトルでは識別率が高く，負の固有ベクトルでは識別率が低くなっていることがわかる．このため，EMC では固有値が正の固有ベクトルで射影した成分のみを用いて個人識別を行えば，高い識別率が得られると考えられる．一方，図 3.8 から，MDA の固有値と識別率に相関があることがわかる．このため，MDA では固有値が大きい固有ベクトルで射影した成分を用いて識別を行えば，高い識別率が得られると考えられる．

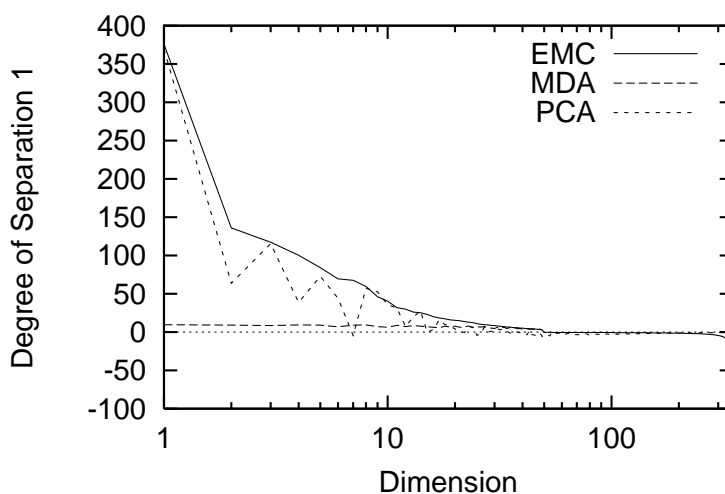


図 3.5: 個人性の分離度 1

3.2.2 個人識別実験

次に 7 表情の内，6 表情を training data，残り 1 表情を test data として複数の固有ベクトルを用いて個人識別を行った．個人識別には入力ベクトル z (test data) との距離が最短となる辞書ベクトル \bar{z}_f (training data の m についての z_{fm} の平均; $f \in F$) に対応する




図 3.6: 個人性の分離度 2

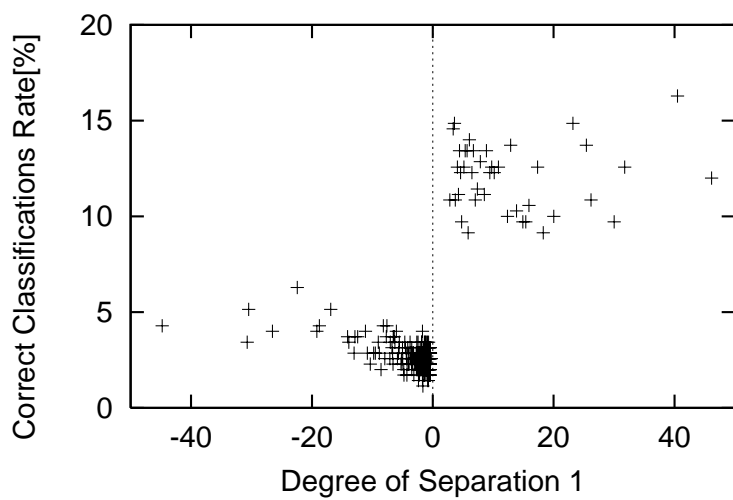


図 3.7: 個人性の分離度 1 と識別率の関係 (EMC)

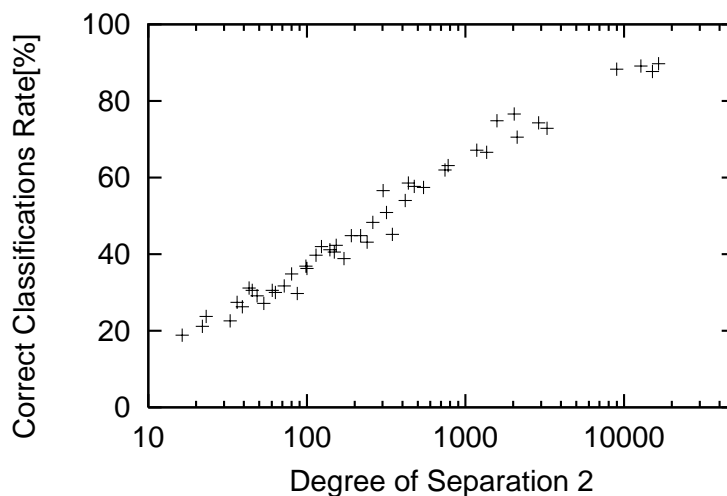


図 3.8: 個人性の分離度 2 と識別率の関係 (MDA)

f を入力顔画像の識別結果とした．距離は次式によって与えられる Euclid 距離 D を使用した．

$$D^2 = (z - \bar{z}_f)^t(z - \bar{z}_f) \quad (3.2)$$

識別に用いた特徴ベクトルの次元数と識別率との関係を図 3.9 に示す．尚，識別率は，training data と test data の全組み合わせ (7 通り) について，test data のみから計算されたものである．また，使用次元数 49 の識別率を表 3.4 にまとめる．PCA に比べ，EMC，MDA 共に少ない使用次元数で高い識別率を得た．特に MDA は少ない使用次元数で識別率が向上している．EMC よりも MDA の方が識別率が良い理由として，MDA の軸が斜交であることより級間分散を大きくするような強調効果が起こることが考えられる．

表 3.4: 使用次元数 49 の識別率

	EMC[%]	MDA[%]	PCA[%]
training data	100.0	100.0	97.9
test data	96.9	99.1	92.3

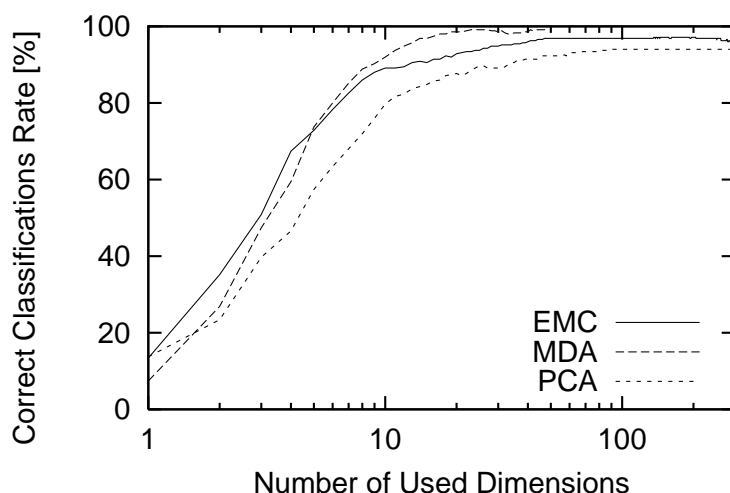


図 3.9: 個人識別率

3.2.3 固有ベクトルの表す顔画像の傾向

データベースの全ての顔画像を training data として EMC を適用し，求められた固有ベクトルのうち k 次の固有ベクトルの方向に，変換出力 z_k の標準偏差 σ_k の定数倍だけ平均顔パターンから変化させたときの顔画像 \tilde{x} を図 3.10 に示す． $k = 1$ の成分は髪の毛の量， $k = 2, 3$ の成分は眉毛と目の特徴を表している傾向がある．また， $k = 348$ の成分は Happiness， $k = 349$ の成分は Surprise を表している傾向がある．このように低次の成分は個人性を表しており，高次の成分は他の要因による成分を表している傾向がある．

同じく全ての顔画像を training data として MDA を適用し，求められた固有ベクトルのうち i 次の固有ベクトルの方向に，変換出力 z_i の標準偏差 σ_i の定数倍だけ平均顔パターンから変化させたときの顔画像 \tilde{x} を図 3.11 に示す．このように，MDA の固有ベクトルの表す顔画像の特徴が明確に現れなかった．この原因として，固有ベクトル a_i の決定に級間分散と級内分散の比の最大化を評価基準とするため，ある画素の全分散が小さくても級間分散と級内分散の比が大きければ， a_i のその画素に対する重みが大きくなることが考えられる．

これらの結果から，MDA よりも EMC の方が個人性の合成に有効であると言える．




図 3.10: 固有ベクトルの表す顔画像の傾向 (EMC)




図 3.11: 固有ベクトルの表す顔画像の傾向 (MDA)

3.3 表情の解析

3.3.1 主観評価実験による顔画像の選び出し

データベースの中から一般性のある画像のみを使用するため，主観評価実験を行った．主観評価実験はデータベースのある表情に属する顔画像を 18 人の評価者に 7 表情のうちのどの表情クラスであるか評価してもらい，データベースの表情クラスと評価者の 6 人以上の評価クラスが一致した画像のみを選び出した．さらに，選び出された画像枚数と 18 人の主観評価者の平均識別率を表 3.5 に示す尚，略記は次のことを意味する．Neutral;Ne., Happiness;Ha., Sadness;Sa., Anger;An., Disgusted;Di., Surprise;Su., Fear;Fe., Correct Classifications Rate;CCR.

表 3.5: 各表情の画像枚数と平均識別率

Ne.	Ha.	Sa.	An.	Di.	Su.	Fe.	CCR.
48	49	29	30	26	44	6	70.3

3.3.2 表情の分離度と単一固有ベクトルによる識別率の関係

選び出された顔画像の全てを training data としたときの EMC,MDA,PCA の分離度 1, 分離度 2 を図 3.12, 図 3.13 に示す．個人性の解析 (3.2.1 節) と同様，分離度 1 では EMC, 分離度 2 では MDA が高い分離度を得た．

次に，単一の固有ベクトルで射影した成分を用いて training data について表情識別を行った．EMC の分離度 1 と識別率の関係，MDA の分離度 2 と識別率の関係を図 3.14, 図 3.15 に示す．個人性の解析と同様，図 3.14 から，EMC の固有値が正の固有ベクトルでは識別率が高く，負の固有ベクトルでは識別率が低くなっていることがわかる．このため，EMC では固有値が正の固有ベクトルで射影した成分のみを用いて表情識別を行えば，高い識別率が得られると考えられる．一方，図 3.15 から，MDA の固有値と識別率に相関があることがわかる．このため，MDA では固有値が大きい固有ベクトルで射影した成分を用いて表情識別を行えば，高い識別率が得られると考えられる．




図 3.12: 表情の分離度 1

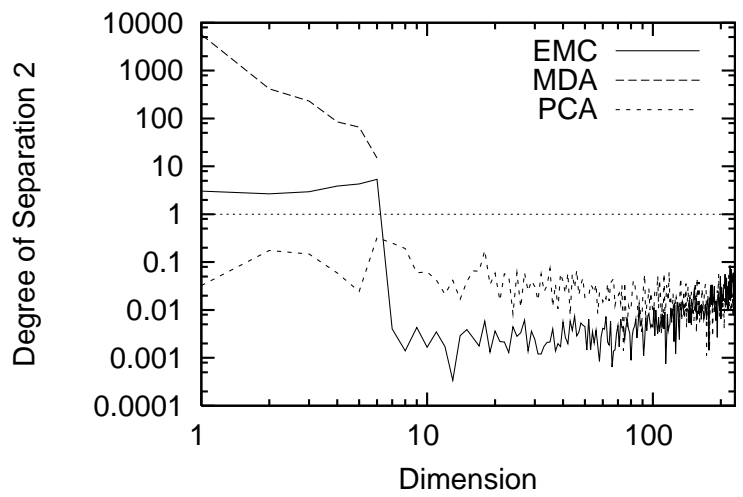


図 3.13: 表情の分離度 2




図 3.14: 表情の分離度 1 と識別率の関係 (EMC)




図 3.15: 表情の分離度 2 と識別率の関係 (MDA)

3.3.3 表情識別実験

次に 50 人の内, 49 人を training data, 残り 1 人を test data として複数の固有ベクトルを用いて表情識別を行った。識別に用いた特徴ベクトルの次元数と識別率との関係を図 3.16 に示す。尚, 識別率は, training data と test data の全組み合わせ (50 通り) について, test data のみから計算されたものである。また, 使用次元数 6 のときの識別率を表 3.6 にまとめる。PCA に比べ, EMC, MDA 共に少ない使用次元数で高い識別率を得た。特に EMC は少ない使用次元数で高い識別率を得た。EMC, MDA で使用次元数 6 のときの識別結果を表 3.7, 表 3.8 に示す。EMC よりも MDA の方が識別率が低い原因として, MDA の無相関性により級内分散の各次元間の偏りが軸の決定に大きく影響しているのではないかと考えている。

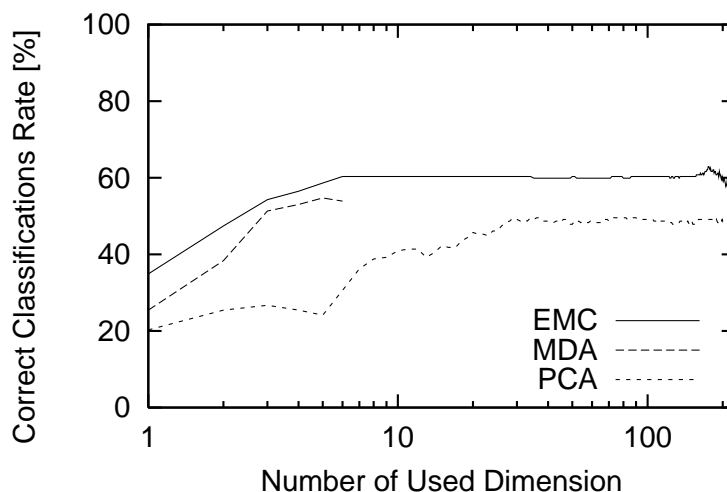


図 3.16: 表情識別率

表 3.6: 使用次元数 6 の識別率

	EMC[%]	MDA[%]	PCA[%]
training data	95.8	100.0	33.9
test data	60.3	53.9	30.6

表 3.7: EMC の識別結果

in \ out	Ne.	Ha.	Sa.	An.	De.	Su.	Fe.	CCR.
Ne.	38	0	1	4	3	2	0	79.2
Ha.	6	39	1	1	1	1	0	79.6
Sa.	3	1	15	5	5	0	0	51.7
An.	4	4	1	15	6	0	0	50.0
Di.	5	3	4	8	5	1	0	19.2
Su.	10	0	0	4	2	28	0	63.6
Fe.	1	0	1	1	2	1	0	0.0

表 3.8: MDA の識別結果

in \ out	Ne.	Ha.	Sa.	An.	De.	Su.	Fe.	CCR.
Ne.	35	1	3	2	4	3	0	72.9
Ha.	5	41	1	0	1	1	0	83.7
Sa.	6	2	12	3	6	0	0	41.4
An.	9	4	1	10	5	1	0	33.3
Di.	4	3	7	8	1	3	0	3.8
Su.	11	0	0	5	2	26	0	59.1
Fe.	1	0	2	2	1	0	0	0.0

3.3.4 固有ベクトルの表す顔画像の傾向

主観評価により選び出された顔画像の全てを training data として EMC を適用し、求められた固有ベクトルのうち k 次の固有ベクトルの方向に、変換出力 z_k の標準偏差 σ_k の定数倍だけ平均顔パターンから変化させたときの顔画像 \tilde{x} を図 3.17 に示す。 $k = 1$ の成分は Happiness, $k = 2$ の成分は Surprise, Disgust, $k = 3$ の成分は Anger, Sadness を表している傾向がある。また、 $k = 230$ は鼻の形や眉毛の位置の特徴、 $k = 231$ は髪の毛の量を表している傾向がある。このように低次の成分は表情を表しており、高次の成分は他の要因による成分を表している傾向がある。

同じく選び出された顔画像の全てを training data として MDA を適用し、求められた固有ベクトルのうち i 次の固有ベクトルの方向に、変換出力 z_i の標準偏差 σ_i の定数倍だけ平均顔パターンから変化させたときの顔画像 \tilde{x} を図 3.18 に示す。個人性の解析 (3.2.3 節) と同様、MDA の固有ベクトルの表す顔画像の特徴が明確に現れなかった。

これらの結果から、MDA よりも EMC の方が表情の合成に有効であると言える。

3.4 顔画像の正規化と主観評価の影響

3.4.1 輝度値の正規化の有効性

顔画像の輝度値の正規化の効果を調べるために、

- 輝度値の正規化を行わなかったもの
- 平均値を 0 にしたもの
- 平均値を 0, 分散を 1 にしたもの

の 3 種類の画像データベースで比較実験を行った。輝度値の正規化と個人識別率の関係、輝度値の正規化と表情識別率の関係を表 3.9, 表 3.10 に示す。training data, test data の選び方は、3.2.2 節, 3.3.2 節と同様である。尚、使用次元数は個人識別では 49, 表情識別では 6 とした。

PCA では、正規化をするに従い識別率が向上している。PCA は照明による影響が低次に現れるため、輝度値の正規化が特に有効である。EMC, MDA では、クラスの特徴が低次の成分に集められているので、正規化の効果は見られなかった。




図 3.17: 固有ベクトルの表す顔画像の傾向 (EMC)

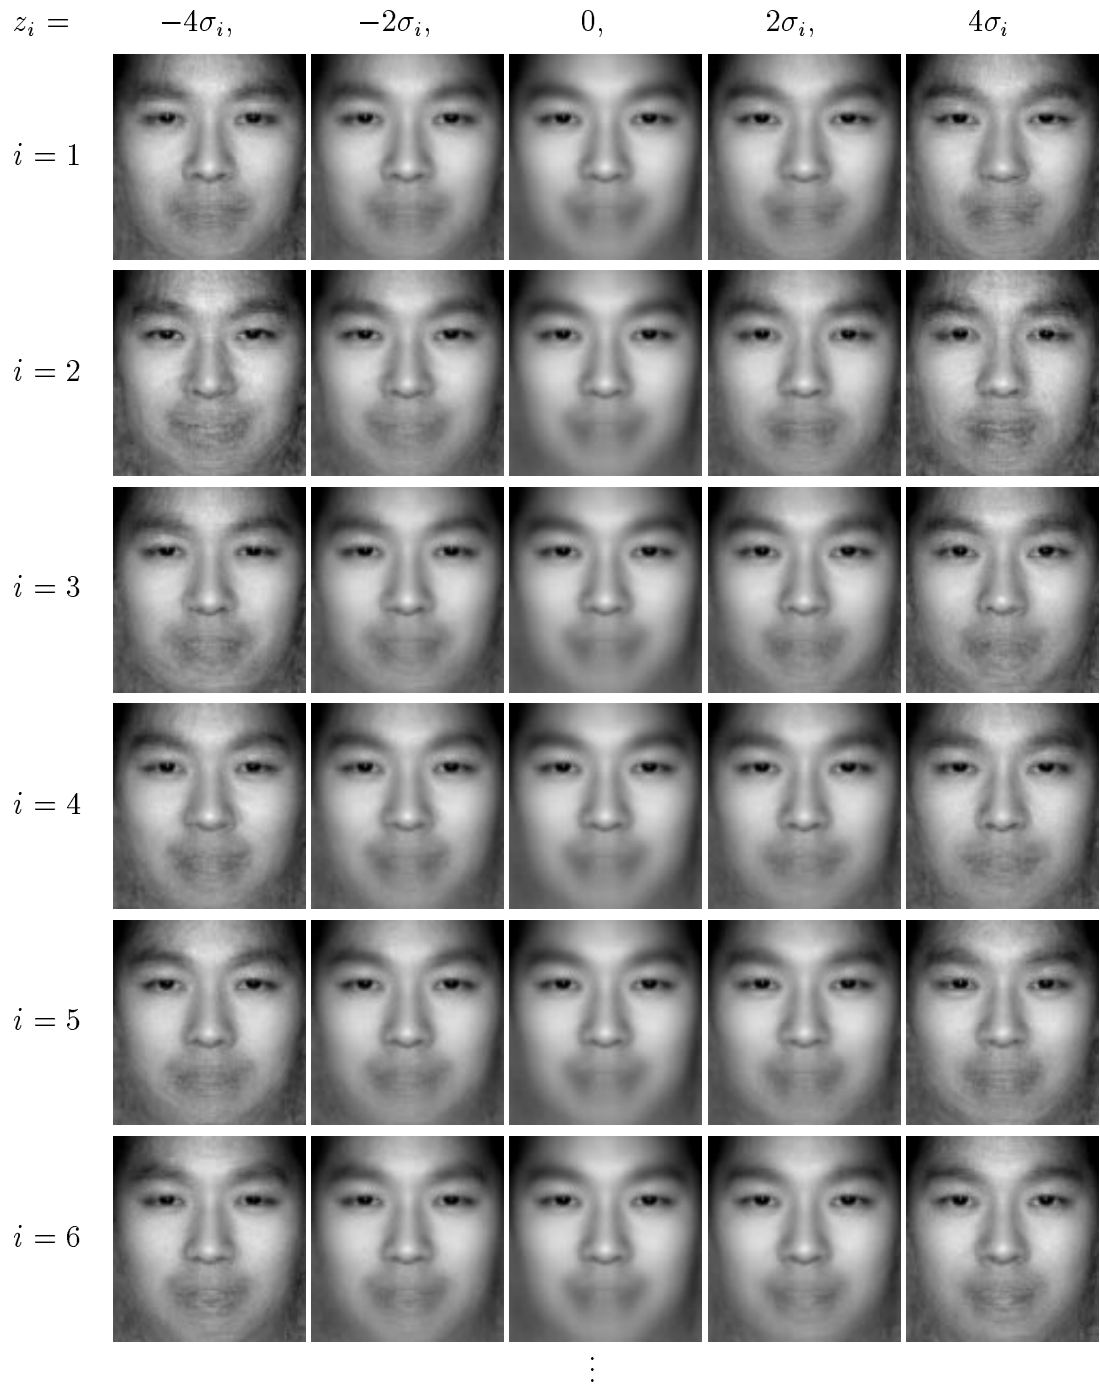


図 3.18: 固有ベクトルの表す顔画像の傾向 (MDA)

表 3.9: 輝度値の正規化と個人識別率の関係

	unnormalized	mean = 0.0	mean = 0.0, sd = 1.0
EMC	95.1	96.9	96.9
MDA	99.4	99.7	99.1
PCA	91.1	93.4	92.3

表 3.10: 輝度値の正規化と表情識別率の関係

	unnormalized	mean = 0.0	mean = 0.0, sd = 1.0
EMC	61.6	62.5	60.3
MDA	55.6	55.6	53.9
PCA	21.6	28.9	30.6

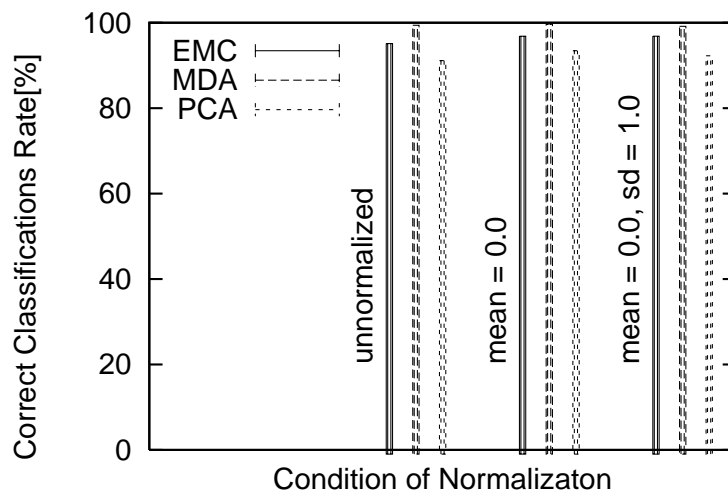


図 3.19: 輝度値の正規化と個人識別率の関係

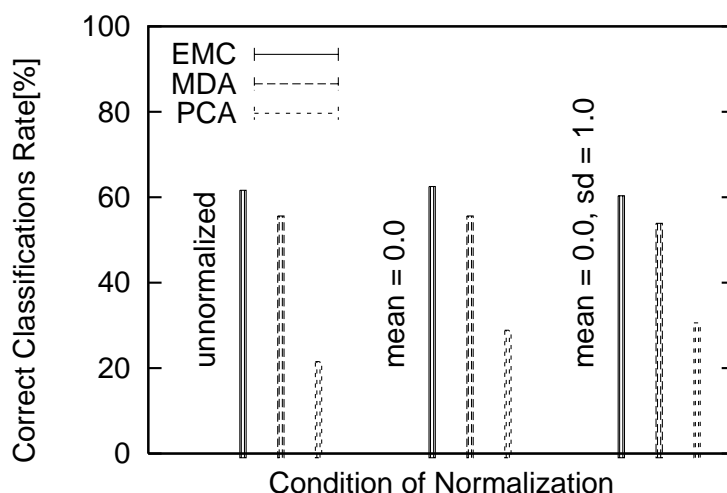


図 3.20: 輝度値の正規化と表情識別率の関係

3.4.2 顔領域の切り出し範囲の影響

顔画像の正規化において顔領域の切り出し範囲を変動させて比較実験を行った。3.1.2節の正規化のパラメータにおいて、 L, D を固定し、 X, Y, A, B を定数倍した。ここでは、crop size ratio C を 3.1節で正規化した画像の幅との比として定義し、正規化のパラメータを表 3.11のように与えた。 C を 60/90, 75/90, 90/90, 105/90, 120/90 と変動させたときの顔領域の切り出し範囲と個人識別率の関係、顔領域の切り出し範囲と表情識別率の関係を図 3.21, 図 3.22に示す。training data, test data の選び方は、3.2.2節, 3.3.2節と同様である。尚、使用次元数は個人識別では 49, 表情識別では 6 に固定した。

個人識別では切り出し範囲が小さいときに識別率が低下するという結果が得られた。これは背景が写っていても、級内の分散が充分小さいため影響は小さいが、切り出し範囲が小さいと顎や髪の毛の情報が使えないために識別率が下がると考えられる。

表情識別では切り出し範囲が大きいときに識別率が低下するという結果が得られた。これは表情の情報が、顔領域の中央部に多く存在し、顎や髪の毛に表情情報が無いことによるものと考えられる。

3.4.3 画像解像度の影響

顔画像の正規化において画像解像度を変動させて比較実験を行った。3.1.2節の正規化のパラメータにおいて、 L, D, X, Y, A, B の全てを定数倍した。ここでは、image resolution

表 3.11: crop size ratio = C のときの正規化のパラメータ

$D = 30$ pixels	$A = 25 \times C$ pixels	$X = 90 \times C$ pixels
$L = 40$ pixels	$B = 29 \times C$ pixels	$Y = 96 \times C$ pixels

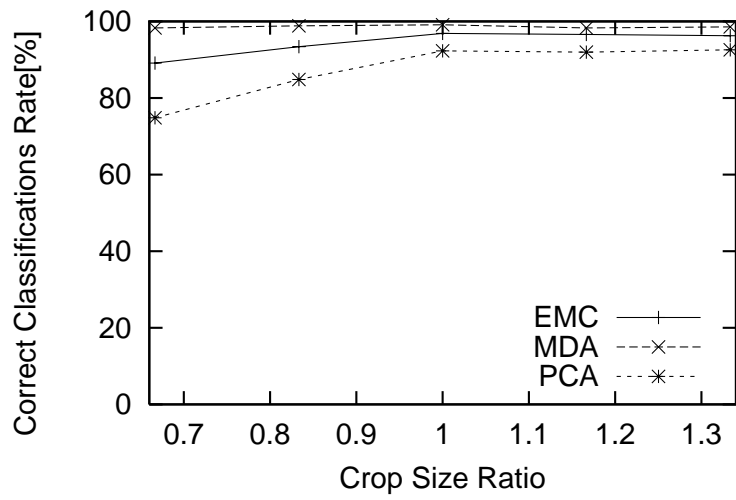


図 3.21: 顔領域の切り出し範囲と個人識別率の関係

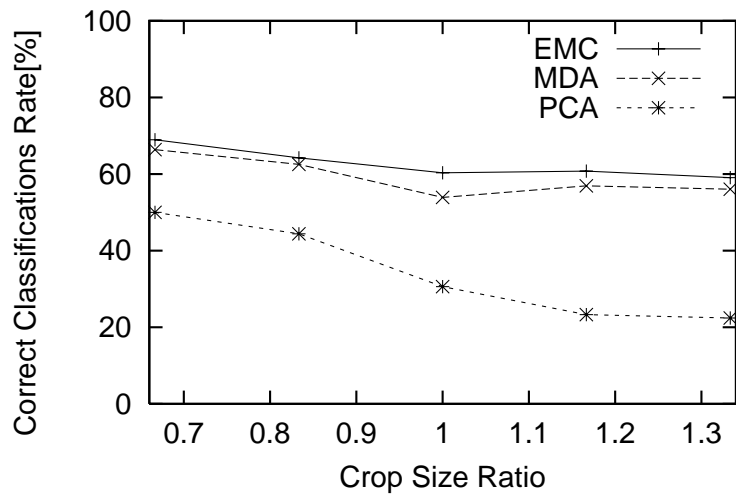


図 3.22: 顔領域の切り出し範囲と表情識別率の関係

ratio R を 3.1 節で正規化した画像の幅との比として定義し，正規化のパラメータを表 3.12 のように与えた． R を 15/90, 30/90, 45/90, 60/90, 75/90, 90/90 と変動させたときの画像解像度と個人識別率の関係，画像解像度と表情識別率の関係を図 3.23，図 3.24 に示す．training data, test data の選び方は，3.2.2 節，3.3.2 節と同様である．尚，使用次元数は個人識別では 49，表情識別では 6 とした．

図 3.23，図 3.24 が示すように，本実験の画像解像度の変動範囲では識別率への影響が考察しがたい結果となった．画像解像度を更に細かく変動させた時の影響について今後検討したい．

表 3.12: image resolution ratio = R のときの正規化のパラメータ

$D = 30 \times R$ pixels	$A = 25 \times R$ pixels	$X = 90 \times R$ pixels
$L = 40 \times R$ pixels	$B = 29 \times R$ pixels	$Y = 96 \times R$ pixels

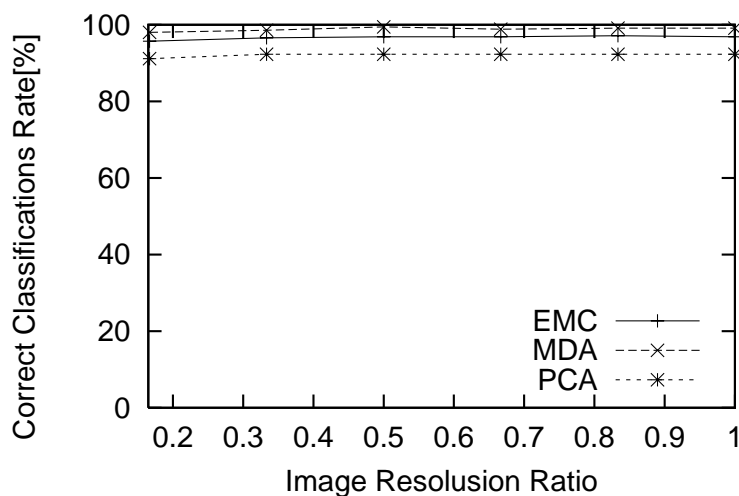


図 3.23: 画像解像度と個人識別率の関係

3.4.4 目・鼻の特徴抽出精度の影響

3.1.2 節では目と鼻の下の基準点を手作業により抽出したが，応用上基準点の抽出は自動化することが望ましい．ここで，本手法が目と鼻の特徴抽出精度によって，どの程度影

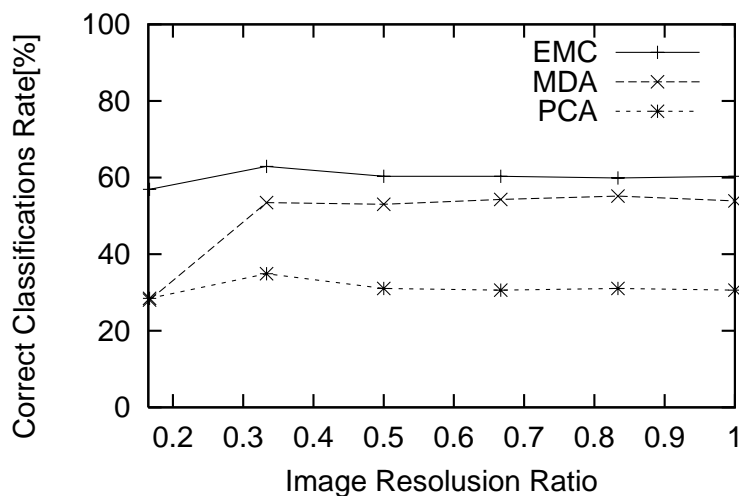


図 3.24: 画像解像度と表情識別率の関係

響を受けるか検討する。

位置・大きさ・傾きの正規化前の顔画像（データベースの顔画像は 1300×1600 pixels のサイズで 両目の間隔が 386.2 ± 29.0 pixels 程度）から目と鼻の基準点の抽出において、抽出位置誤差を標準偏差が σ の正規分布でばらつかせて正規化をした。目と鼻の特徴抽出における誤差の標準偏差と個人識別率の関係、標準偏差と表情識別率の関係を図 3.25、図 3.26 に示す。training data, test data の選び方は、3.2.2 節、3.3.2 節と同様である。尚、使用次元数は個人識別では 49、表情識別では 6 とした。

基準点の抽出の小さなずれで、著しく識別率が低下した。EMC, MDA を適応して、個人識別で識別率 90% 程度、表情識別で識別率 50% 程度を得るには、誤差が 10pixels 以下の精度の特徴抽出手法が要求される。

3.4.5 主観評価との関係

3.3.1 節では、顔画像を 18 人の評価者に 7 表情の内どの表情であるか主観評価してもらい、データベースの表情クラスと評価者の 6 人以上の評価クラスが一致した画像のみを選び出した。ここでは、画像の選び出しの条件としてデータベースの表情クラスと評価クラスが一致する評価者の最低人数を 0 人、6 人、12 人、18 人と変動させた。データベースの表情クラスと評価クラスが一致する評価者の最低人数と表情識別率の関係を図 3.27 に示す。training data, test data の選び方は、3.2.2 節、3.3.2 節と同様である。尚、データ

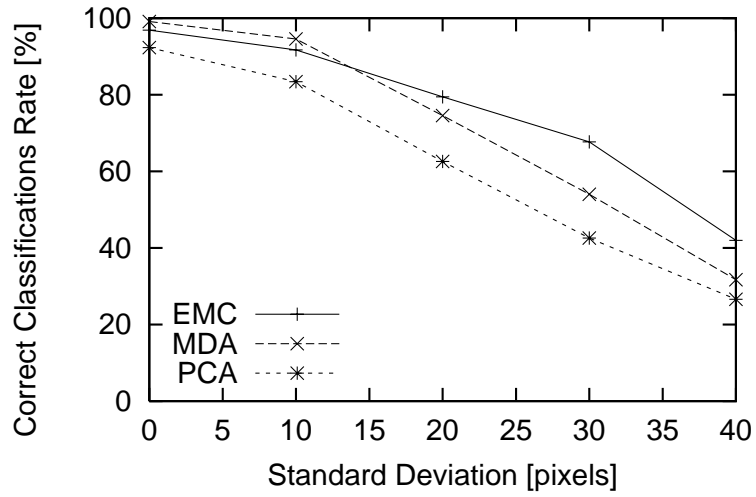


図 3.25: 目・鼻の特徴抽出精度と個人識別率の関係

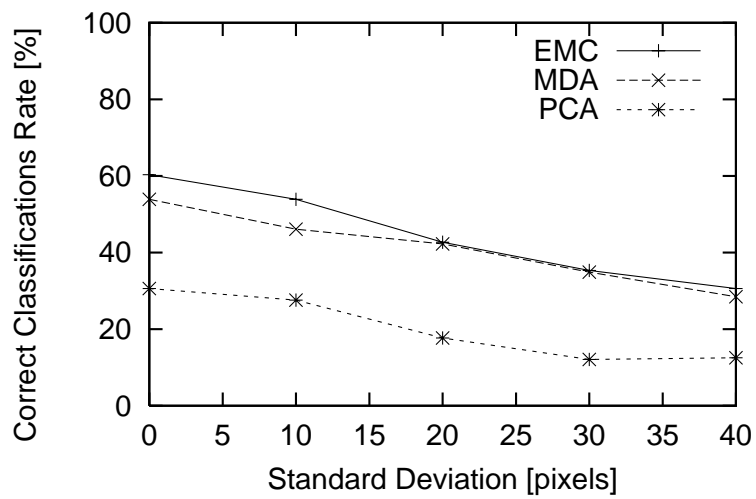


図 3.26: 目・鼻の特徴抽出精度と表情識別率の関係

ベースの表情クラスと評価クラスが一致する評価者の最低人数が 18 人のときに選び出された画像の表情クラス数が 4 となるため、識別に使用する次元数を 3 とした。

識別率は表情クラスと評価クラスが一致する評価者の最低人数との相関が高い。これは、データベースの表情クラス内の画像が、評価者によって絞り込まれるために級内分散が小さくなったと考えられる。

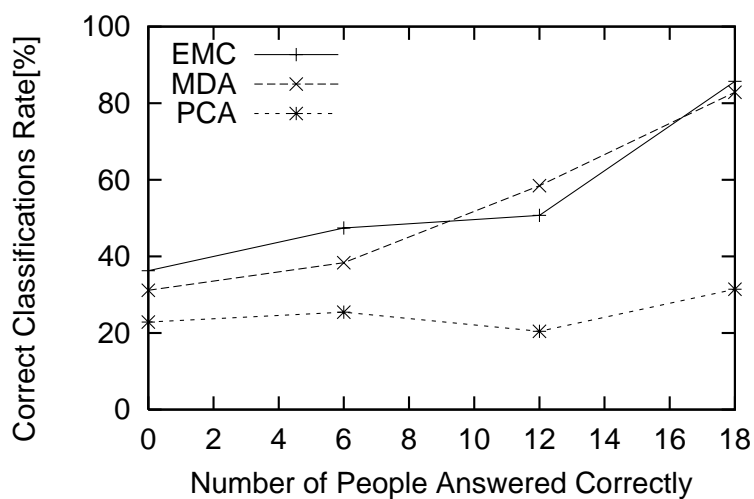


図 3.27: 主観評価結果と表情識別率の関係

第 4 章

まとめ

4.1 結果・考察

EMC と MDA により顔画像から個人性と表情の解析を行った．その結果・考察を以下に要約する．

- 個人性の解析

- 個人性の分離度と識別率の関係

- * 分離度 1 では EMC，分離度 2 では MDA が高い分離度を得た．
- * EMC の固有値が正の固有ベクトルでは識別率が高く，負の固有ベクトルでは識別率が低くなった．このため，EMC では固有値が正の固有ベクトルで射影した成分のみを用いて個人識別を行えば，高い識別率が得られると考えられる．
- * MDA の固有値と識別率に相関があった．このため，MDA では固有値が大きい固有ベクトルで射影した成分を用いて識別を行えば，高い識別率が得られると考えられる．

- 個人識別実験

- * PCA に比べ，EMC，MDA 共に少ない使用次元数で高い識別率を得た．
- * 特に MDA は少ない使用次元数で識別率が向上している．
- * EMC よりも MDA の方が識別率が良い理由として，MDA の軸が斜交であることより級間分散を大きくするような強調効果が起こることが考えられる．

– 固有ベクトルの表す顔画像の傾向

- * EMC の低次の成分は個人性を表しており，高次の成分は他の要因による成分を表している傾向があった．
- * MDA の固有ベクトルの表す顔画像の特徴が明確に現れなかった．この原因として，固有ベクトル a_i の決定に級間分散と級内分散の比の最大化を評価基準とするため，ある画素の全分散が小さくても級間分散と級内分散の比が大きければ， a_i のその画素に対する重みが大きくなることが考えられる．

● 表情の解析

– 表情の分離度と単一固有ベクトルによる識別率の関係

- * 分離度 1 では EMC，分離度 2 では MDA が高い分離度を得た．
- * EMC の固有値が正の固有ベクトルでは識別率が高く，負の固有ベクトルでは識別率が低くなった．このため，EMC では固有値が正の固有ベクトルで射影した成分のみを用いて表情識別を行えば，高い識別率が得られると考えられる．
- * MDA の固有値と識別率に相関があった．このため，MDA では固有値が大きい固有ベクトルで射影した成分を用いて表情識別を行えば，高い識別率が得られると考えられる．

– 表情識別実験

- * PCA に比べ，EMC，MDA 共に少ない使用次元数で高い識別率を得た．
- * 特に EMC は少ない使用次元数で高い識別率を得た．
- * EMC よりも MDA の方が識別率が低い原因として，MDA の無相関性により級内分散の各次元間の偏りが軸の決定に大きく影響しているのではないかと考えている．

– 固有ベクトルの表す顔画像の傾向

- * EMC の低次の成分は表情を表しており，高次の成分は他の要因による成分を表している傾向があった．
- * MDA の固有ベクトルの表す顔画像の特徴が明確に現れなかった．この原因として，固有ベクトル a_i の決定に級間分散と級内分散の比の最大化を評価基準とするため，ある画素の全分散が小さくても級間分散と級内分散

の比が大きければ、 a_i のその画素に対する重みが大きくなることが考えられる。

- 顔画像の正規化の影響

- 輝度値の正規化の有効性

- * PCA では、正規化をするに従い識別率が向上している。PCA は照明による影響が低次に現れるため、輝度値の正規化が特に有効である。
- * EMC, MDA では、クラスの特徴が低次の成分に集められているので、正規化の効果は見られなかった。

- 顔領域の切り出し範囲の影響

- * 個人識別では切り出し範囲が小さいときに識別率が低下するという結果が得られた。これは背景が写っていても、級内の分散が充分小さいため影響は小さいが、切り出し範囲が小さいと顎や髪の毛の情報が使えないために識別率が下がると考えられる。
- * 表情識別では切り出し範囲が大きいときに識別率が低下するという結果が得られた。これは表情の情報が、顔領域の中央部に多く存在し、顎や髪の毛に表情情報が無いことによるものと考えられる。

- 画像解像度の影響

- * 本実験の画像解像度の変動範囲では識別率への影響が考察しがたい結果となった。画像解像度を更に細かく変動させた時の影響について今後検討したい。

- 目・鼻の特徴抽出精度の影響

- * 基準点の抽出の小さなずれで、著しく識別率が低下した。EMC, MDA を適応して、個人識別で識別率 90%程度、表情識別で識別率 50%程度を得るには、誤差が 10 pixels 以下の精度の特徴抽出手法が要求される。

- 主観評価との関係

- * 識別率は表情クラスと評価クラスが一致する評価者の最低人数との相関が高い。これは、データベースの表情クラス内の画像が、評価者によって絞り込まれるために級内分散が小さくなったと考えられる。

4.2 結論

結論を以下にまとめる．

- 個人識別には，EMC よりも MDA の解析結果を用いると高い識別率が得られる．
- 表情識別には，MDA よりも EMC の解析結果を用いると高い識別率が得られる．
- 固有ベクトルの表す顔画像は，MDA よりも EMC の方がクラスの特徴を良く表している．

4.3 今後の課題

今後の課題を以下に挙げる．

- 画像解像度の影響を示す実験において，画像解像度の変動範囲が不十分であったために，識別率への影響が考察しがたい結果となった．画像解像度を更に細かく変動させた時の影響について検討する必要がある．
- 一般的に眼鏡をかけて生活をする人が多く，顔画像解析は眼鏡をかけた場合でも適応できることが望ましい．今回は眼鏡等のオクルージョンについて検討しなかったが，オクルージョンによる影響を示す必要がある．
- 今回は顔画像の輝度成分と形状成分を分離せずに解析を行ったため，個人性，表情の EMC における固有ベクトルによる合成顔画像は若干不自然である．より自然な顔画像の合成を目的として，顔形状のワイヤースケルトンモデルにより，顔の輝度と形状に分離を行った後，EMC を適応し顔画像を合成する．
- 更なる識別率の向上を目的として，本手法の非線形への拡張を検討する．

謝辞

本研究を進めるにあたり日頃から熱心に御指導して頂きました本学 小谷 一孔 助教授，
剣持 雪子 助手に深く感謝致します。終始貴重な御意見，御鞭撻を頂きました本学 宮原
誠 教授，赤木 正人 助教授，下平 博 助教授，亀田 昌志 助手に深く感謝致します。また，
日頃から御助言，激励頂いた斎藤康之氏を始めとする本学 像情報処理学講座の学生諸氏，
顔画像データベースの作成に協力して下さいました本学学生，職員の皆様に深く感謝致します。

参考文献

- [1] Albert Mehrabian(西田 司, ほか訳). “非言語コミュニケーション”. 聖文社, 1986.
- [2] M. Kirby and L. Sirovich. “Application of the Karhunen-Loève Procedure for the Characterization of Human Faces”. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 12(1):103–108, January 1990.
- [3] M. Turk and A. Pentland. “Face Recognition Using Eigenfaces”. *Proc. IEEE Conf. on Computer Vision and Pattern Recognition*, pages 586–591, 1991.
- [4] Andreas Lanitis, Chris J. Taylor and Timothy F. Cootes. “Automatic Interpretation and Coding of Face Images Using Flexible Models”. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 19(7):743–756, July 1997.
- [5] 赤松 茂, 佐々木 努, 深町 映夫, 末永 康仁. “濃淡画像マッチングによるロバストな正面顔の識別法—フーリエスペクトルの KL 展開の応用—”. *信学論 (D-II)*, J76-D-II(7):1363–1373, July 1993.
- [6] 松野 勝弘, 李 七雨, 辻 三朗. “ポテンシャルネットと KL 展開を用いた顔表情の認識”. *信学論 (D-II)*, J77-D-II(8):1591–1600, August 1994.
- [7] 永田 明德, 岡崎 透, 崔 昌石, 原島 博. “主成分分析による顔画像の基底生成と空間記述”. *信学論 (D-II)*, J79-D-II(7):1230–1235, July 1996.
- [8] ズデネク プロハースカ, 伊藤 崇之, 岡本 敏雄. “動き情報を用いた表情特徴の自動抽出手法”. *信学論 (D-II)*, J81-D-II(6):1150–1159, June 1998.
- [9] Peter N. Belhumeur, João P. Hespanha and David J. Kriegman. “Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection”. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 19(7):711–720, July 1997.

- [10] 大津 展之. “パターン認識における特徴抽出に関する数理的研究”. Technical Report 818, 電子技術総合研究所研究報告, July 1981.
- [11] 黒住 隆行, 斎藤 康之, 剣持 雪子, 小谷 一孔. “固有空間法と重判別分析を用いた顔画像の表情解析”. *IMPS98*, pages 13–14, October 1998.
- [12] 黒住 隆行, 新座 良和, 剣持 雪子, 小谷 一孔. “固有空間法と重判別分析による顔画像の個人性と表情の解析”. 信学技報 (*CS*), CS98-122, IE98-101:57–64, December 1998.

第 A 章

定理の証明

A.1 定理 1 の証明

定理 1 式 (2.8) を最小にする正規直交基底 ϕ_k は, 式 (2.11) を満たす.

(証明)

式 (2.8) に式 (2.6) を代入すると,

$$\begin{aligned}\varepsilon^2(\phi_k) &= \frac{1}{M} \sum_{f \in F} \sum_{m=1}^{M_f} \left\| \bar{\mathbf{x}}_f - \sum_{k=1}^K z_{kfm} \phi_k - \bar{\mathbf{x}} \right\|^2 \\ &= \frac{1}{M} \sum_{f \in F} \sum_{m=1}^{M_f} \left\{ \|\bar{\mathbf{x}}_f - \bar{\mathbf{x}}\|^2 - 2 \sum_{k=1}^K z_{kfm} \bar{z}_{kf} + \left\| \sum_{k=1}^K z_{kfm} \phi_k \right\|^2 \right\}\end{aligned}\quad (\text{A.1})$$

を得る. ただし,

$$\bar{z}_{kf} = (\bar{\mathbf{x}}_f - \bar{\mathbf{x}})^t \phi_k \quad (\text{A.2})$$

とする. ここで, 正規直交条件より,

$$\begin{aligned}\varepsilon^2(\phi_k) &= \frac{1}{M} \sum_{f \in F} \sum_{m=1}^{M_f} \left\{ \|\bar{\mathbf{x}}_f - \bar{\mathbf{x}}\|^2 - 2 \sum_{k=1}^K z_{kfm} \bar{z}_{kf} + \sum_{k=1}^K z_{kfm}^2 \right\} \\ &= \frac{1}{M} \sum_{f \in F} \sum_{m=1}^{M_f} \left\{ \|\bar{\mathbf{x}}_f - \bar{\mathbf{x}}\|^2 - \sum_{k=1}^K \bar{z}_{kf}^2 + \sum_{k=1}^K (z_{kfm} - \bar{z}_{kf})^2 \right\}\end{aligned}\quad (\text{A.3})$$

を得る. ここで, 式 (2.10)(2.12)(A.2) より,

$$\varepsilon^2(\phi_k) = \frac{1}{M} \sum_{f \in F} \sum_{m=1}^{M_f} \|\bar{\mathbf{x}}_f - \bar{\mathbf{x}}\|^2 - \sum_{k=1}^K \phi_k^t S \phi_k \quad (\text{A.4})$$

を得る．式 (A.4) の第一項は ϕ_k の選び方に独立であるから，式 (2.8) を最小にする問題は次の制約条件つき最適化問題と同等である．

Find ϕ_k that maximizes

$$\sum_{k=1}^K \phi_k^t S \phi_k \quad (\text{A.5})$$

subject to the constraints

$$\begin{aligned} \phi_i^t \phi_j &= I_{ij} \\ I_{ij} &= \begin{cases} 1 & \text{if } i = j \\ 0 & \text{otherwise} \end{cases} \end{aligned} \quad (\text{A.6})$$

さらに，Lagrange の未定係数法よりこの制約条件つき最適化問題は次の最適化問題と同等である．

Find ϕ_k, Λ_{ij} that maximizes

$$L(\phi_k, \Lambda_{ij}) = \sum_{k=1}^K \phi_k^t S \phi_k - \sum_{i=1}^K \sum_{j=1}^K \Lambda_{ij} (\phi_i^t \phi_j - I_{ij}) \quad (\text{A.7})$$

ただし，Lagrange 係数を $\Lambda_{ij}; i = 1, \dots, K; j = 1, \dots, K$ とする．ここで式 (A.7) の極値では，

$$\frac{\partial L(\phi_k, \Lambda_{ij})}{\partial \phi_k} = (S + S^t) \phi_k - 2\lambda_k \phi_k = 0 \quad (\text{A.8})$$

が成り立つ．ただし，

$$\lambda_k = \Lambda_{kk} + \frac{1}{2} \sum_{i \neq k} \sum_{j \neq k} \Lambda_{ij} \quad (\text{A.9})$$

とする．ここで， S は実対称行列なので，式 (A.8) より式 (2.11) の固有値問題を得る．また，式 (A.7) を最大にするには， λ_k を大きい順に K 個選ぶこととなる．□