

## ANÁLISE MULTILINEAR DISCRIMINANTE DE FORMAS FRONTAIS DE IMAGENS 2D DE FACE

ELIANA ZACCHI TENORIO\*, CARLOS EDUARDO THOMAZ\*

\* *Centro Universitário da FEI*

*Av. Humberto de Alencar Castelo Branco, 3972 - Assunção  
São Bernardo do Campo, SP, Brasil*

Emails: [eliana@ultrabit.com.br](mailto:eliana@ultrabit.com.br), [cet@fei.edu.br](mailto:cet@fei.edu.br)

**Abstract**— This paper describes and implements a multilinear shape analysis of 2D frontal face images. Our aim is not only to visualize and understand the information that most varies given the sample data, but also to extract the most discriminant differences related to a specific characteristic of interest, such as changes owing to gender or facial expression. The experiments carried out have showed that the multilinear discriminant analysis, although limited by the number of existing supervised classes, is a promising approach to extend well-known methods of extracting shape properties of 2D objects in general.

**Keywords**— Multilinear discriminant analysis, 2D face shapes.

**Resumo**— Este artigo descreve e implementa uma análise multilinear de formas 2D em imagens frontais de face com o objetivo de entender como essas informações se alteram no espaço original dos dados. Investiga-se não somente as componentes principais que mais variam mas também a direção que melhor representa as diferenças discriminantes de acordo com a característica de interesse como, por exemplo, alterações relativas a gênero ou expressão facial. Os experimentos mostram que a análise multilinear discriminante, embora limitada ao número de classes existentes, é promissora e permite a extensão dos métodos existentes na literatura para extração de propriedades das formas de objetos em geral.

**Keywords**— Análise multilinear discriminante, formas 2D de face.

### 1 Introdução

Muitas atividades humanas e interações com o meio ambiente realizadas por máquinas (computadores ou robôs) são guiadas por análises da informação visual disponível (Costa and Júnior, 2001). Entretanto, além dos recursos computacionais necessários para interpretar automaticamente as imagens obtidas, há dificuldades adicionais na análise da informação visual, como a existência de ruído, oclusão, distorção e perda de informação em mapeamentos de objetos do espaço tridimensional (3D) para espaços bidimensionais (2D).

Na maioria das situações, formas 2D em imagens têm as mesmas características dos objetos originais com exceção fundamentalmente da profundidade e do movimento. Objetos representados por formas 2D podem ser prontamente reconhecidos na maioria dos casos. Por exemplo, a forma de um coração, de uma estrela, de uma nota musical, de uma ferramenta e até mesmo o formato da face de uma pessoa, assunto deste trabalho, são facilmente reconhecidos por nós.

Essencialmente, a análise computacional de forma envolve uma série de tarefas importantes desde a aquisição da imagem até a classificação da mesma. Estas tarefas podem ser divididas em três grandes etapas: pré-processamento, extração de características e classificação (Costa and Júnior, 2001). T. Cootes e colegas (Cootes et al., 1991; Cootes and Taylor, 1992; Ahmad et al., 1995; Edwards et al., 1998), interessados em problemas onde os formatos dos objetos po-

dem variar, desenvolveram um método pioneiro de representação de formas por meio do qual pode-se, automaticamente, extrair as propriedades das formas dos dados e descrever sucintamente os parâmetros que mais variam desses dados (Cootes et al., 1991). Os objetos são representados por um conjunto de pontos de controle e examinando-se a variação estatística das coordenadas desses pontos para um conjunto de treinamento estima-se a posição inicial, o tamanho e o formato de um objeto em uma imagem e, conseqüentemente, os ajustes necessários para melhor adequar esse modelo de forma à imagem correspondente (Cootes and Taylor, 1992). Por exemplo, em (Ahmad et al., 1995) os autores descreveram um procedimento para reconhecer gestos e monitorar em uma seqüência de imagens o movimento de uma mão humana quando opera-se um mouse. Para esta aplicação foram definidos 89 pontos de controle para representar a mão e, após a aplicação do método de Análise de Componentes Principais (PCA) (Fukunaga, 1990), o resultado foi um vetor que representava a forma média de uma mão e uma série de direções no espaço original que descrevia as variações das mãos em torno desta forma média. Resultados semelhantes, utilizando-se um número maior de pontos de controle, também foram implementados com sucesso em um modelo de face estatístico baseado em imagens frontais (Edwards et al., 1998; Lanitis et al., 2005).

Este artigo investiga os trabalhos recentes de (Kitani et al., 2006; Kitani and Thomaz, 2007; Thomaz et al., 2009) e descreve uma análise

multilinear de formas 2D em imagens frontais de face com o objetivo de entender como essas informações estão se alterando no espaço original. Especificamente, investiga-se não somente as componentes principais que mais variam (Cootes et al., 1991; Cootes and Taylor, 1992; Ahmad et al., 1995; Edwards et al., 1998), mas também a direção que melhor representa as diferenças discriminantes entre os dados dependendo do contexto da análise multivariada em questão. Pretende-se, portanto, extrair a direção mais discriminante de acordo com a característica de interesse, por exemplo, diferenças de gênero e expressão facial, e não as direções mais expressivas (Swets and Weng, 1996) que não necessariamente representam exclusivamente as diferenças discriminantes (Kitani et al., 2006).

## 2 Análise de Componentes Principais

A Análise de Componentes Principais, ou simplesmente PCA (Principal Component Analysis) (Fukunaga, 1990) como é amplamente conhecida, é um método estatístico multivariado de extração de informação, proposto originalmente por Karl Pearson (Pearson, 1901), que transforma um conjunto  $n$  de variáveis originais em um número  $m$  de combinações lineares destas variáveis, onde  $m \leq n$ , por meio da seleção das características que mais variam (ou mais expressivas (Swets and Weng, 1996)) e conseqüente redução de dimensionalidade dos dados.

Seja uma amostra de treinamento contendo  $N$  formas de face representadas por vetores  $n$ -dimensionais que descrevem as coordenadas 2D dos pontos de controle dessas formas. A matriz de covariância desses dados pode ser escrita como:

$$S = \frac{1}{(N-1)} \sum_{i=1}^N (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T, \quad (1)$$

onde  $\mathbf{x}_i$  e  $\bar{\mathbf{x}}$  são, respectivamente, a forma  $i$  e média global dessa amostra de treinamento. É um resultado provado na literatura que o conjunto  $m$  de autovetores de  $S$ , que corresponde aos maiores autovalores, minimiza o erro quadrático médio de reconstrução desses dados para todas as possíveis escolhas de bases  $m$  vetoriais ortonormais (Fukunaga, 1990). Esse conjunto de autovetores que define um novo sistema de coordenadas para a amostra de treinamento é conhecido como componentes principais e pode ser descrito matematicamente como:

$$P^T S P = \Lambda, \quad (2)$$

onde  $P$  e  $\Lambda$  são as matrizes de autovetores e autovalores de  $S$ . No contexto específico de reconhecimento de faces, a matriz  $P_{pca} = [\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_m]$

de componentes principais ordenada decrescentemente ( $\lambda_1 \geq \lambda_2 \dots \geq \lambda_m$ ) é comumente denominada de autofaces (Sirovich and Kirby, 1987; Turk and Pentland, 1991). As  $m$  componentes principais podem então substituir as  $n$  variáveis e a amostra original de dados, que consiste de  $N$  exemplos e  $n$  variáveis, é reduzida para uma amostra de dados contendo  $N$  exemplos e  $m$  componentes principais.

## 3 Análise de Discriminantes Lineares

A Análise de Discriminante Lineares, ou simplesmente LDA (Linear Discriminant Analysis) (Devijver and Kittler, 1982) como é também amplamente conhecida, é um método estatístico multivariado de extração de informação, proposto originalmente por Ronald A. Fisher (Fisher, 1936), que separa em duas ou mais classes de interesse os dados originais. Essa separação em classes ou grupos distintos é feita através de uma transformação linear que maximiza a distância entre as classes e minimiza o espalhamento dentro de cada grupo.

Seja a matriz de espalhamento inter-classes  $S_b$  descrita matematicamente por

$$S_b = \sum_{i=1}^g N_i (\bar{\mathbf{x}}_i - \bar{\mathbf{x}})(\bar{\mathbf{x}}_i - \bar{\mathbf{x}})^T \quad (3)$$

e a matriz de espalhamento intra-classes  $S_w$  descrita por

$$S_w = \sum_{i=1}^g \sum_{j=1}^{N_i} (\mathbf{x}_{i,j} - \bar{\mathbf{x}}_i)(\mathbf{x}_{i,j} - \bar{\mathbf{x}}_i)^T \quad (4)$$

onde  $\mathbf{x}_{i,j}$  é a forma  $n$ -dimensional  $j$  da classe  $\pi_i$ ,  $N_i$  é o número de exemplos de treinamento da classe  $\pi_i$ , e  $g$  representa o número total de classes ou grupos. O vetor  $\bar{\mathbf{x}}_i$  é a média amostral da classe  $\pi_i$  (Fukunaga, 1990). O vetor de média global  $\bar{\mathbf{x}}$  pode ser então re-escrito como

$$\bar{\mathbf{x}} = \frac{1}{N} \sum_{i=1}^g N_i \bar{\mathbf{x}}_i = \frac{1}{N} \sum_{i=1}^g \sum_{j=1}^{N_i} \mathbf{x}_{i,j}, \quad (5)$$

onde  $N$  é, como descrito anteriormente, o número total de exemplos de treinamento, ou seja,  $N = N_1 + N_2 + \dots + N_g$ .

O principal objetivo do método LDA é encontrar a matriz de projeção  $W_{lda}$  que maximiza a razão entre o determinante da matriz de espalhamento inter-classes  $S_b$  e o determinante da matriz de espalhamento intra-classes  $S_w$ , conhecido como critério de Fisher e descrito matematicamente por

$$W_{lda} = \arg \max_W \frac{|W^T S_b W|}{|W^T S_w W|}, \quad (6)$$

O critério de Fisher descrito pela equação (6) é satisfeito quando a matriz de projeção  $W_{lda}$  é composta, no máximo, pelos  $(g - 1)$  autovetores de  $S_w^{-1}S_b$ , cujos autovalores correspondentes são não-nulos (Fukunaga, 1990; Devijver and Kittler, 1982). Por exemplo, em problemas envolvendo duas classes somente, a matriz de projeção do LDA contém, na verdade, um único autovetor  $w_{lda}$ , admitindo que  $S_w$  seja não-singular.

No entanto, quando o número total de exemplos  $N$  não é consideravelmente maior que o número de variáveis  $n$ , ocorre uma instabilidade no cálculo da matriz inversa de  $S_w$  (Fukunaga, 1990). A quantidade de exemplos de treinamento para evitar essa instabilidade no cálculo da matriz inversa de  $S_w$  deve ser igual ou superior a 5 vezes a quantidade de variáveis que definem essas amostras (Jain and Chandrasekaran, 1982). Portanto, para o tratamento do problema de instabilidade no cálculo da inversa da matriz  $S_w$ , pode-se utilizar o método denominado MLDA (*Maximum uncertainty Linear Discriminant Analysis*) (Thomaz et al., 2006). Essa técnica consiste em substituir a matriz de espalhamento  $S_w$  por outra matriz regularizada  $S_w^*$ . A nova matriz regularizada  $S_w^*$  pode ser calculada por meio dos seguintes passos:

1. Seleciona-se os autovetores  $\Phi$  e autovalores  $\Lambda$  de  $S_p$ , onde  $S_p = \frac{S_w}{N-g}$ ;
2. Calcula-se a média dos autovalores  $\bar{\lambda}$ , ou seja,

$$\bar{\lambda} = \frac{1}{n} \sum_{j=1}^n \lambda_j = \frac{Tr(S_p)}{n}; \quad (7)$$

3. Constrói-se uma nova matriz de autovalores baseada na dispersão dos maiores autovalores, isto é,

$$\Lambda^* = diag[max(\lambda_1, \bar{\lambda}), \dots, max(\lambda_n, \bar{\lambda})]; \quad (8)$$

4. Calcula-se a matriz de espalhamento intraclasses regularizada

$$S_w^* = S_p^*(N - g) = (\Phi \Lambda^* \Phi^T)(N - g). \quad (9)$$

Com a matriz  $S_w^*$  calculada, substitui-se  $S_w$  da equação (6) por  $S_w^*$  e regulariza-se o critério de Fisher para problemas onde o número total de exemplos de treinamento é limitado e equivalente a dimensionalidade dos dados.

## 4 Experimentos e Resultados

Os experimentos foram desenvolvidos com o objetivo de distinguir gênero e expressão facial em imagens de faces a partir apenas dos formatos das mesmas, sem levar em consideração cor ou textura. Para isto, utilizou-se duas bases de dados disponíveis publicamente para pesquisa: AR

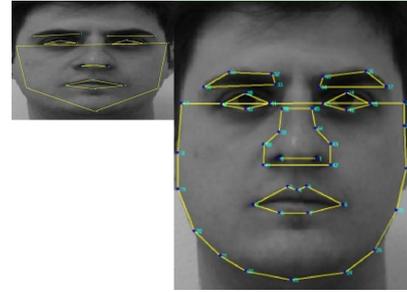


Figura 1: Ilustração da localização dos pontos de controle: 22 pontos da base AR (esquerda); 46 pontos da base FEI (direita).

(Martinez and Benavente, 1998) e FEI (Thomaz and Giraldo, 2010).

Da base AR, utilizou-se 238 imagens frontais, todas com expressão facial sorrindo e não-sorrindo, sendo 148 masculinas e 90 femininas. Os formatos dessas imagens foram descritos por 22 pontos de controle previamente marcados<sup>1</sup>, conforme o exemplo ilustrado na Figura 1.

Para a base de faces da FEI, utilizou-se 400 imagens frontais, todas com expressão facial sorrindo e não-sorrindo, sendo 200 masculinas e 200 femininas. Os formatos dessas imagens foram descritos por 46 pontos de controle, dentre eles 19 dos 20 pontos mais relevantes de características frontais de acordo com (Vukadinovic and Pantic, 2005) e mais 27 pontos dos 152 sugeridos por (Lanitis et al., 2005). Estes 27 pontos foram adicionados para permitir que a ferramenta de referência na literatura (Lanitis et al., 2005) tivesse uma quantidade de pontos suficiente para gerar uma representação da face por meio de linhas, conforme o exemplo ilustrado na Figura 1.

### 4.1 Reconstrução das Componentes Principais

De forma análoga aos experimentos de (Ahmad et al., 1995; Edwards et al., 1998; Lanitis et al., 2005), pode-se utilizar a forma média global  $\bar{x}$  representada pelo vetor  $n$ -dimensional para interpretar as alterações mais expressivas capturadas pelas componentes principais. Matematicamente, essa navegação nas componentes principais pode ser descrita por

$$\mathbf{y} = \bar{\mathbf{x}} + j\sqrt{\lambda_i} \cdot \mathbf{p}_i, \quad (10)$$

onde  $j \in \{-3, -2, -1, 0, 1, 2, 3\}$  e  $\mathbf{p}_i$  são as  $m$  componentes principais ordenadas decrescentemente pelos seus autovalores correspondentes, isto é,  $\lambda_1 \geq \lambda_2 \dots \geq \lambda_m$ .

As Figuras 2 e 3 mostram essas transformações lineares para as 3 primeiras componentes principais das bases de faces AR e FEI, respectivamente. Devido à característica não-supervisionada da análise de componentes prin-

<sup>1</sup><http://personalpages.manchester.ac.uk/staff/timothy.f.cootes>

cipais, não é possível prever ou garantir qual componente principal irá distinguir as diferenças relativas a gênero ou expressão facial exclusivamente. Navegando nas primeiras componentes, percebe-se as alterações mais expressivas que descrevem, em ambas bases de faces, fundamentalmente diferenças associadas ao tamanho, formato e posição dos rostos. No entanto, informações mais sutis, como diferenças de expressão facial, podem ser capturadas nas componentes principais cujos autovalores não são máximos, conforme pode-se observar na reconstrução da 3a. componente principal da base de faces da FEI, ilustrada na Figura 3.

#### 4.2 Reconstrução dos Discriminantes Lineares

Antes da reconstrução dos discriminantes lineares, estimou-se a habilidade de generalização dos vetores  $\mathbf{w}_{mlda}$  para discriminar gênero e expressão facial dos exemplos de treinamento das bases de dados AR e FEI por meio do método cross-validation e do classificador de distancia Euclideana (Fukunaga, 1990). A Tabela 1 mostra as taxas de classificação obtidas pelos vetores discriminantes correspondentes. Pode-se verificar que em todos os experimentos realizados a taxa de acurácia foi alta, atingindo valores superiores a 85% para ambas características de interesse e ambas bases de dados.

Tabela 1: Taxas de classificação (%) para as características gênero (homem versus mulher) e expressão facial (sorrindo versus não-sorrindo).

Base de Faces	Gênero		Exp. F.	
	h	m	s	n
AR	86.8	87.2	97.5	96.4
FEI	87.9	91.9	92.2	97.1

Para a análise multilinear discriminante, calculou-se o vetor  $\mathbf{w}_{mlda}$  de projeção considerando todos os exemplos de treinamento e as separações dos formatos das faces com relação a gênero e expressão facial. Admitindo que o espalhamento das classes no vetor  $\mathbf{w}_{mlda}$  discriminante seja descrito por uma distribuição Gaussiana e impondo limites para a variação de cada classe, como por exemplo  $\pm 3\sigma_i$  (ou 99.73%), onde  $\sigma_i$  é o desvio padrão de cada classe  $i \in \{1, 2\}$ , a navegação nos discriminantes lineares pode ser calculada matematicamente por

$$\mathbf{y} = \bar{\mathbf{x}} + j\sigma_i \cdot \mathbf{w}_{mlda}, \quad (11)$$

onde  $j \in \{-3, -2, -1, 0, 1, 2, 3\}$ .

As Figuras 4 e 5 apresentam, de cima para baixo, as navegações nos vetores discriminantes de gênero e expressão facial para as bases de dados AR e FEI, respectivamente. Pode-se observar, claramente, que os rostos das imagens femininas

da base AR são menores e mais sorridentes do que os rostos masculinos, e as sobrancelhas possuem simetrias distintas dependendo do gênero. Além disso, a Figura 4 mostra que independentemente do gênero, há diferenças relevantes associadas exclusivamente a expressão facial. Para a base de faces da FEI, os rostos masculinos parecem ser mais finos ou alongados e conter sobrancelhas mais grossas que os rostos femininos, mas tão sorridentes quanto, independentemente do gênero. A reconstrução das alterações mais discriminantes relativas a expressão facial da base de faces da FEI ilustra diferenças somente no formato da boca e na abertura dos olhos, representando exclusivamente as mudanças fundamentais dessa característica de interesse.

## 5 Conclusão

Os modelos descritos e implementados neste trabalho estão baseados em transformações lineares e descrevem no espaço original dos dados as diferenças nas formas frontais de imagens 2D de face. Constatou-se, no entanto, que não é possível prever qual componente principal irá descrever as características discriminantes de interesse, pois essas características podem ser representadas tanto pela primeira como pela última componente principal e de maneira não necessariamente exclusiva. Uma alternativa para essa limitação inerente a métodos não-supervisionados é realizar uma análise discriminante multilinear dos dados, utilizando exemplos já classificados e disponíveis. Os experimentos desse trabalho mostram que tal análise, embora limitada ao número de classes existentes, é promissora e permite a extensão dos métodos existentes na literatura para extração de propriedades das formas de objetos em geral.

## Referências

- Ahmad, T., Taylor, C. J. and Cootes, T. F. (1995). Tracking and recognising hand gestures using statistical shape models, *Proceedings of the British Machine Vision Conference (BMVC)*, pp. 403–412.
- Cootes, T. F., Cooper, D., Taylor, C. J. and Graham, J. (1991). A trainable method of parametric shape description, *Proceedings of the British Machine Vision Conference (BMVC)*, pp. 54–61.
- Cootes, T. F. and Taylor, C. J. (1992). Active shape models, *Proceedings of the British Machine Vision Conference (BMVC)*, pp. 266–275.
- Costa, L. D. and Júnior, R. M. (2001). *Shape Analysis and Classification: Theory and Practice*, CRC Press.

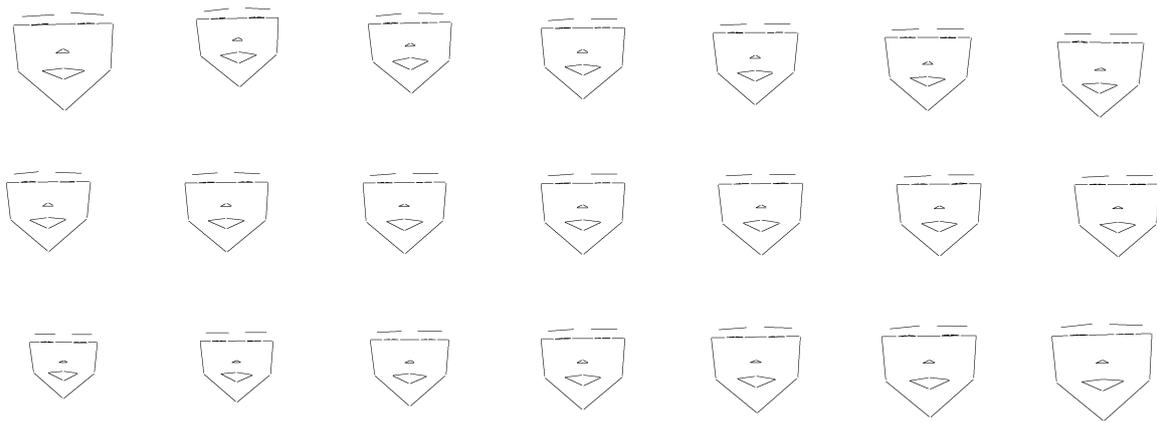


Figura 2: Reconstrução das alterações mais expressivas da base de faces AR. Da esquerda para direita:  $[-3\sqrt{\lambda_i}, -2\sqrt{\lambda_i}, -1\sqrt{\lambda_i}, \bar{x}, +1\sqrt{\lambda_i}, +2\sqrt{\lambda_i}, +3\sqrt{\lambda_i}]$ , onde  $i = \{1, 2, 3\}$  de cima para baixo.

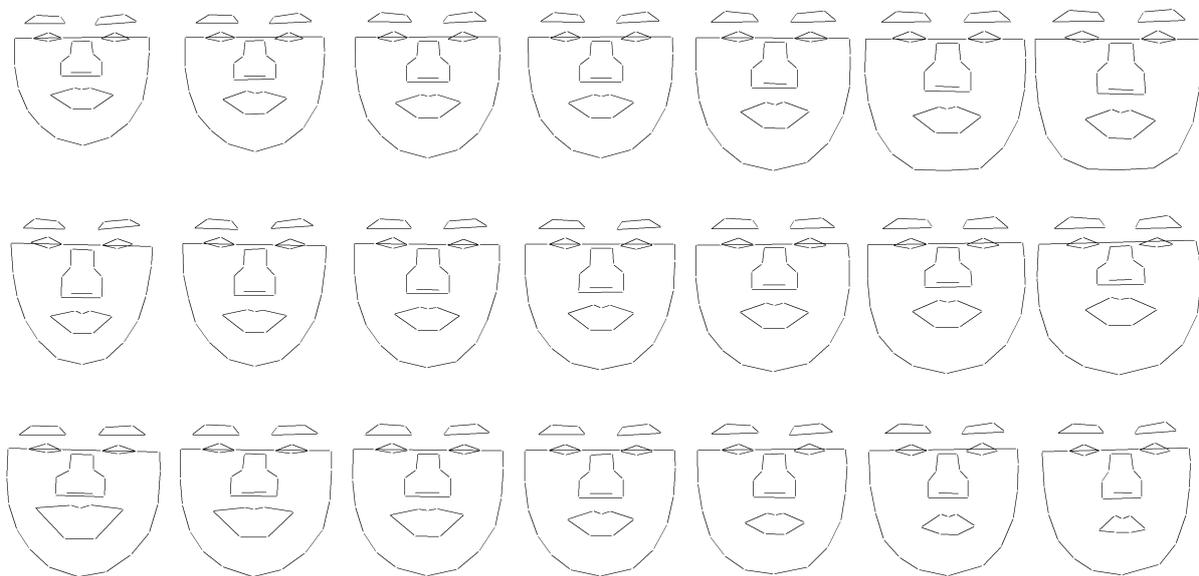


Figura 3: Reconstrução das alterações mais expressivas da base de faces da FEI. Da esquerda para direita:  $[-3\sqrt{\lambda_i}, -2\sqrt{\lambda_i}, -1\sqrt{\lambda_i}, \bar{x}, +1\sqrt{\lambda_i}, +2\sqrt{\lambda_i}, +3\sqrt{\lambda_i}]$ , onde  $i = \{1, 2, 3\}$  de cima para baixo.

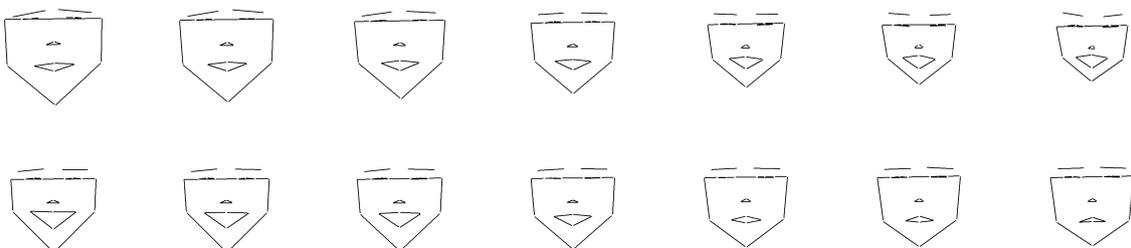


Figura 4: Reconstrução das alterações mais discriminantes relativas a gênero (em cima) e expressão facial (embaixo) da base de faces AR. Da esquerda (classe 1 de exemplos de 'homem' ou 'sorrindo') para direita (classe 2 de exemplos de 'mulher' ou 'não-sorrindo'):  $[-3\sigma_1, -2\sigma_1, -1\sigma_1, \bar{x}, +1\sigma_2, +2\sigma_2, +3\sigma_2]$ .

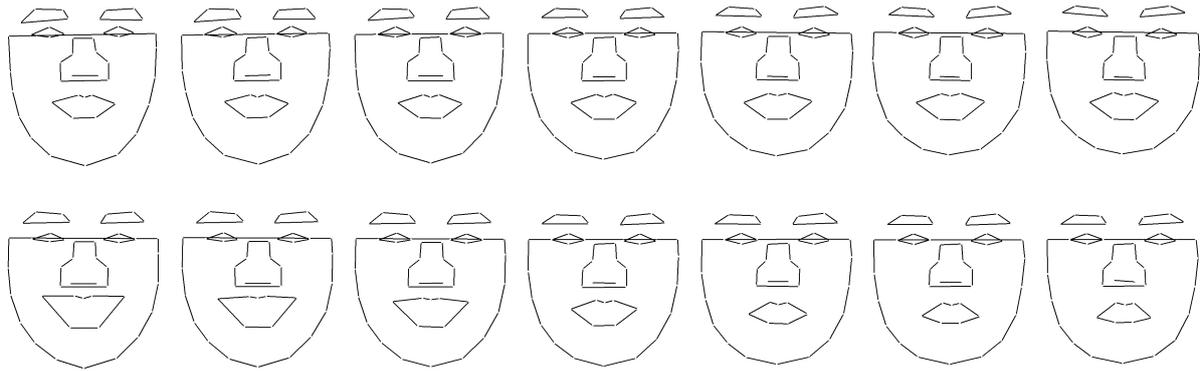


Figura 5: Reconstrução das alterações mais discriminantes relativas a gênero (em cima) e expressão facial (embaixo) da base de faces da FEI. Da esquerda (classe 1 de exemplos de 'homem' ou 'sorrindo') para direita (classe 2 de exemplos de 'mulher' ou 'não-sorrindo'):  $[-3\sigma_1, -2\sigma_1, -1\sigma_1, \bar{x}, +1\sigma_2, +2\sigma_2, +3\sigma_2]$ .

- Devijver, P. and Kittler, J. (1982). *Pattern Classification: A Statistical Approach*, Prentice-Hall.
- Edwards, G. J., Cootes, T. F. and Taylor, C. J. (1998). Face recognition using active appearance models, *Proceedings of the European Conference on Computer Vision (ECCV)*, pp. 581–698.
- Fisher, R. A. (1936). The use of multiple measurements in taxonomic problems, *Annals of Eugenics* **7**: 179–188.
- Fukunaga, K. (1990). *Introduction to Statistical Pattern Recognition*, Morgan Kaufmann.
- Jain, A. K. and Chandrasekaran, B. (1982). Dimensionality and sample size considerations in pattern recognition practice, *Handbook of Statistics* **2**: 835–855.
- Kitani, E. C. and Thomaz, C. E. (2007). Análise de discriminantes lineares para modelagem e reconstrução de imagens de face, *Proceedings of the Encontro Nacional de Inteligência Artificial (ENIA)*, pp. 962–971.
- Kitani, E. C., Thomaz, C. E. and Gillies, D. F. (2006). A statistical discriminant model for face interpretation and reconstruction, *Proceedings of the Brazilian Symposium on Computer Graphics and Image Processing (SIBGRAPI)*, pp. 247–254.
- Lanitis, A., Taylor, C. J. and Cootes, T. F. (2005). An automatic identification system using flexible appearance models, *Image and Vision Computing* **13**: 393–401.
- Martinez, A. and Benavente, R. (1998). The ar face database. CVC Technical Report no. 24.
- Pearson, K. (1901). On lines and planes of closest fit to system of point in space, *Philosophical Magazine* **2**: 559–572.
- Sirovich, L. and Kirby, M. (1987). Low-dimensional procedure for the characterization of human faces, *Journal of Optical Society of America* **4**: 519–524.
- Swets, D. and Weng, J. (1996). Using discriminants eigenfeatures for image retrieval, *IEEE Trans. Pattern Anal. Mach. Intell.* **18(8)**: 831–836.
- Thomaz, C. E., Amaral, V., Giraldo, G. A., Kitani, E. C., Sato, J. R. and Gillies, D. F. (2009). A multi-linear discriminant analysis of 2d frontal face images, *Proceedings of the Brazilian Symposium on Computer Graphics and Image Processing (SIBGRAPI)*, pp. 216–223.
- Thomaz, C. E. and Giraldo, G. A. (2010). A new ranking method for principal components analysis and its application to face image analysis, *Image and Vision Computing* **28(6)**: 902–913.
- Thomaz, C., Kitani, E. and Gillies, D. (2006). A maximum uncertainty lda-based approach for limited sample size problems - with application to face recognition, *Journal of the Brazilian Computer Society* **12(2)**: 7–18.
- Turk, M. and Pentland, A. (1991). Eigenfaces for recognition, *Journal of Cognitive Neuroscience* **3**: 71–86.
- Vukadinovic, D. and Pantic, M. (2005). Fully automatic facial feature point detection using gabor feature based boosted classifiers, *Proceedings of the International Conference on Systems, Man and Cybernetics*, pp. 1692–1698.