

Análise da ação da idade em processos de reconhecimento de faces

Daniel da Silva Diogo Lara
Universidade Federal de Minas Gerais - UFMG
Núcleo de Processamento Digital de Imagens - NPDI
Belo Horizonte, Minas Gerais, Brasil
daniels@dcc.ufmg.br

Abstract

The issue of aging on face recognition systems is an area not well explored so far. Face Recognition (FR) systems has had a great improvement on the last 20 years. One of the biggest challenge on these systems is the fact of low recognition rates when face images were trained as young and tested after the aging process. In this work we propose a simple way to understand how aging acts on PCA based FR systems. The results are based on the ORL and FGNET data base.

Index Terms: face recognition, aging, PCA, 2DPCA, craniofacial aging.

1. Introdução

Um sistema de reconhecimento de face é um sistema biométrico que identifica ou verifica seres humanos através de uma característica exclusiva, a face. Para isso podem ser usadas características como medições de perfil, frontal, forma, distâncias de formas, etc. Sistemas para reconhecimento automático de faces têm tido grande atenção nos últimos anos. Um dos maiores desafios encontrados no processo de reconhecimento automático de faces é a ação da idade. Com o passar dos anos, as faces sofrem alterações que dificultam bastante para um sistema treinado no reconhecimento das mesmas. Muitos esforços estão sendo direcionados para quantização de sinais de idade em faces baseado em modelos de envelhecimento [2]. Entretanto o tema envelhecimento de face ainda não foi focado explicitamente em pesquisa de sistemas de Reconhecimento de Faces (FR)[1]. O reconhecimento de faces, a partir de imagens estáticas ou dinâmicas, vem emergindo, há décadas, como uma atividade de pesquisa com numerosas aplicações comerciais, industriais e de imposição de lei. Junyan Wang, Yan Shang, Guangda Su e Xinggang Lin [3] propõem um modelo de simulação de aumento de sinais de idade e

em seguida usam PCA para reconhecimento de faces. Jian Yang, David Zhang, Alejandro F. Frangi e Jing-yu Yang [4] propõem um modelo para reconhecimento de imagens que apresenta melhores resultados que PCA - O 2DPCA. Este trabalho propõe uma análise e comparação do impacto do processo de envelhecimento craniofacial na performance de um dos métodos mais usados para reconhecimento de faces - O PCA - e outro mais recente que tem se apresentado mais eficiente - O 2DPCA.

2. Métodos de reconhecimento

2.1. PCA

A análise de componentes principais é um dos métodos tidos como mais bem sucedidos ao longo de anos na área de reconhecimento de faces e compressão de imagens. A idéia principal do PCA é a redução da dimensão do espaço de imagens usando uma representação sem grandes perdas de informação mas com muito menos dimensões.

2.1.1. Matemática do PCA Uma imagem de face 2-D pode ser representada como um vetor em um espaço $X(m * n)$ dimensional, onde m é o número de linhas e n o número de colunas da imagem. Seja M um conjunto de vetores representando imagens no espaço X . Assim cada imagem pode ser representada por:

$$x_i = [p_1 \dots p_N]^T, i = 1, \dots, M \quad (1)$$

É calculada a média das imagens, e subtraída de cada:

$$m = \frac{1}{M} \sum_{i=1}^M x_i \quad (2)$$

$$w_i = x_i - m \quad (3)$$

Nosso objetivo é encontrar um conjunto de autovetores que tenham a maior projeção possível em cada uma das imagens w'_i s. Assim sendo deve-se encontrar um conjunto M

de vetores ortonormais e_i para que a equação

$$\lambda_i = \frac{1}{M} \sum_{n=1}^M (e_i^T w_n)^2 \quad (4)$$

seja maximizada com a restrição de ortonormalidade. Para tanto

$$e_i^T e_k = \sigma_{ik} \quad (5)$$

É resultado da álgebra linear que e_i^T s e λ_i s são os autovetores e autovalores da matriz de covariância:

$$C = WW^T \quad (6)$$

Onde W é uma matriz composta pelos vetores w_i lado a lado. Os autovetores correspondendo a autovalores não-negativos da matriz de covariância produzem uma base ortonormal para o novo subespaço onde os dados podem ser representados com uma pequena quantidade de erro. Assim sendo a nova imagem representada no espaço dos autovetores e_i pode ser representada por:

$$\Omega = [v_1 v_2 \dots v_{M'}]^T \quad (7)$$

onde $v_i = e_i^T w_i$.

2.2. 2DPCA

2DPCA é também um método para extração de características da imagem, entretanto, ao contrário do PCA convencional, 2DPCA é baseado em matrizes 2D ao invés de vetores 1D. Assim sendo, não há necessidade de converter a imagem em um vetor. A matriz de covariância pode ser construída diretamente a partir das matrizes de imagem. 2DPCA possui duas grandes vantagens com relação ao PCA, a primeira delas é o tamanho menor da matriz de covariância e a segunda é a facilidade para o cálculo dos autovetores e autovalores.

2.2.1. Matemática do 2DPCA Seja X um vetor n -dimensional. A idéia principal do algoritmo é projetar a matriz de imagem A , uma matriz $m \times n$ aleatória, sobre X da seguinte forma:

$$Y = AX \quad (8)$$

Desta forma Y será um vetor m -dimensional que pode ser chamado de vetor de características da imagem A . Uma boa projeção para X pode ser caracterizada pelo traço da matriz de covariância dos vetores de características projetados. Seja

$$J(X) = \text{tr}(S_x), \quad (9)$$

onde S_x denota a matriz de covariância dos vetores de características projetados e $\text{tr}(S_x)$ denota o traço de S_x . O objetivo é encontrar uma direção de projeção X , sobre a

qual todas as amostras são projetadas, maximizando a distribuição de todas as amostras projetadas. A covariância de S_x pode ser denotada por:

$$S_x = E(Y - EY)(Y - EY)^T \quad (10)$$

$$= E[AX - E(AX)][AX - E(AX)]^T \quad (11)$$

$$= E[(A - EA)X][(A - EA)X]^T. \quad (12)$$

então

$$\text{tr}(S_x) = X^T [E(A - EA)^T (A - EA)] X. \quad (13)$$

Definindo

$$G_t = E[(A - EA)^T (A - EA)] \quad (14)$$

como sendo a matriz de covariância do espalhamento. Supondo que existem M imagens de treinamento disponíveis, que a j -ésima imagem é denotada por uma matriz $m \times n$, A_j ($j = 1, 2, \dots, M$) e que a imagem média das amostras de treinamento seja $\bar{A}$. Então

$$G_t = \frac{1}{M} \sum_{j=1}^M (A_j - \bar{A})^T (A_j - \bar{A}). \quad (15)$$

Assim temos:

$$J(X) = X^T G_t X. \quad (16)$$

Logo o valor ótimo de projeção para X é o vetor unitário que maximiza $J(X)$, ou seja, o auto vetor de G_t correspondente ao maior autovalor de G_t .

3. Metodologia

A metodologia consiste em implementar os dois métodos de reconhecimento automático de faces propostos em [5] e [4], obter uma base de dados com fotografias de faces das mesmas pessoas em diferentes idades, realizar alterações nas respectivas componentes de cada método e a partir daí gerar uma massa de dados para comparação dos resultados.

4. Experimentos e resultados

Devido à grande complexidade para o cálculo de autovetores e autovalores da matriz de covariância do PCA, as imagens de amostra para treinamento foram reduzidas para 90 x 60 pixels enquanto para o 2DPCA foi possível trabalhar com 300 x 200 pixels. A partir dos dois métodos implementados e usando a base ORL e FGNET, foi organizado um conjunto de imagens mistas com faces jovens e velhas. No domínio dos componentes foi obtida a imagem média de todas essas faces e a partir daí os componentes obtidos foram alterados na tentativa de encontrar um ou mais que poderia afetar diretamente as características que mais identificam o aumento de idade. A partir das variações de alguns componentes empiricamente, foram obtidas as seguintes imagens.

4.1. Base de Dados

Base de faces usadas para média no 2DPCA.




Figure 1. Treinamento do sistema

Essas imagens foram representadas nos domínios PCA e 2DPCA e após a média foram obtidas as seguintes:



Figure 2. Média no domínio PCA



Figure 3. Média no domínio 2DPCA

Variando o componente 4 no PCA, 3 e 6 no 2DPCA foram obtidas as seguintes imagens:



Figure 4. resultado PCA



Figure 5. resultado 2DPCA




Figure 6. resultado 2DPCA

Levando em consideração as características crânio-faciais, há quem diga que as imagens mais à esquerda acima apresentam características de uma face humana mais jovem que as imagens mais à direita.

5. Conclusões

É possível dizer que alguns componentes principais armazenam mais informações referentes ao envelhecimento crânio-facial que outros. No caso do PCA foi possível identificar isso em maior escala no componente 4 para as imagens na resolução apresentada acima. No caso do 2DPCA essas informações estiveram mais presentes nos vetores principais 3 e 6. Entretanto tais componentes estão diretamente ligadas à etnia da face, à resolução da imagem e à eficiência do processo de geração da nova base para o domínio dos componentes principais.

6. Trabalhos Futuros

Após esse esforço no sentido de identificar possíveis componentes que representassem características de idade, resta

a pergunta: Seria possível concluir algo parecido para sexo ou etnia? Tudo indica que sim, mas neste caso o ideal seria procurar isolar cada um separadamente, neste primeiro trabalho não procurou-se separar etnia ou sexo no processo de identificação da variação de idade nas imagens.

7. Referências

[1] The Effect of Normal Adult Aging on Standard PCA Face Recognition Accuracy Rates, Karl Ricanek, Jr. , Edward Boone, Proceedings of International Joint Conference on Neural Networks, Montreal, Canada, July 31 - August 4, 2005.

[2] Modeling Age Progression in Young Faces. Narayanan Ramanathanand RamaChellappa, (accepted in CVPR 2006, New York)

[3] Age simulation for face recognition. Junyan Wang, Yan Shang, Guangda Su, Xinggang Lin. The 18th International Conference on Pattern Recognition

[4] Two-Dimensional PCA: A New Approach to Appearance-Based Face Representation and Recognition. Jian Yang, David Zhang, Senior Member, IEEE, Alejandro F. Frangi, and Jing-yu Yang. IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE, VOL. 26, NO. 1, JANUARY 2004 131

[5] Eigenfaces for Recognition. M Turk and A. Pentland. J. Cognitive Neuroscience, vol. 3, no. 1, pp. 71-86, 1991.