

# Análise da acurácia de métodos de descrição 2D para o reconhecimento facial 3D

Jonathan Coutinho Luz de Queiroz, Maurício Pamplona Segundo  
Intelligent Vision Research Lab, Universidade Federal da Bahia, Salvador, Bahia  
E-mail: jonathanqueiroz@dcc.ufba.br, mauricio@dcc.ufba.br

**Abstract**—Em meio à crescente necessidade do controle rígido do acesso a sistemas computacionais, o reconhecimento facial se mostra uma proposta viável e eficaz para uso em sistemas de autenticação. Em particular, o reconhecimento facial baseado em imagens 3D a partir da conversão para imagens 2D vem sendo estudado devido à influência reduzida de fatores como iluminação e pose. Essa abordagem consiste na aplicação de técnicas de projeção para obtenção das imagens 2D, viabilizando assim a aplicação de métodos tradicionais de descrição de imagens bidimensionais para utilização no reconhecimento. O foco deste trabalho é a análise da acurácia desses métodos para o reconhecimento facial 3D. Para isso, foram comparados os resultados obtidos com os métodos de descrição UGS, PCA, HOG, LBP e LDA. A principal contribuição reside na identificação de que descritores robustos como HOG, LBP e PCA apresentam desempenho inferior àquele obtido pelo UGS, método mais simples, quando utilizados para o reconhecimento facial 3D. Isso evidencia a necessidade do desenvolvimento de métodos de descrição específicos para essa finalidade.

**Keywords**—reconhecimento facial; biometria; visão computacional

**Abstract**—With the growing need for strict access control of computational systems, face recognition has shown to be viable and effective in authentication systems. In particular, face recognition based on 3D images by converting them to 2D images has been studied due to the reduced influence of factors such as illumination and pose. This approach consists in the application of projection techniques to obtain 2D images, which allows the application of traditional 2D description methods for recognition. The focus of this work is the analysis of the accuracy achieved by these methods in the 3D face recognition. To this end, we compared the obtained results for UGS, PCA, HOG, LBP and LDA descriptors. The main contribution is the observation that robust methods such as HOG, LBP and PCA yield lower performance than UGS, which is much more simple, when used for 3D face recognition. This demonstrates the necessity of developing description methods specifically for this task.

**Keywords**—face recognition; biometrics; computer vision

## I. INTRODUÇÃO

O controle rígido do acesso a sistemas computacionais está se tornando cada vez mais necessário em diversas áreas para garantir privacidade e confidencialidade. No entanto, os mecanismos tradicionais de controle de acesso (e.g. senhas e cartões magnéticos) não são suficientemente robustos para lidar com essa situação porque estão sujeitos a ataques baseados na captura dos dados/objetos de autenticação de um usuário habilitado. Além disso, esses mecanismos requerem

interação do usuário, o que inviabiliza a autenticação contínua, e possibilitam a transferência de permissões.

Nesse cenário, o reconhecimento facial aparece como uma proposta viável e eficaz para uso em sistemas de autenticação, um dos fatores que tem impulsionado pesquisas na área. Originalmente realizado a partir imagens de textura, o reconhecimento facial passou a ser realizado também com imagens de profundidade (3D) devido à influência reduzida de fatores como iluminação e pose [1], [2].

Uma possível abordagem para o reconhecimento facial em imagens 3D envolve a aplicação de uma técnica de projeção para transformá-las em imagens 2D. Posteriormente, é possível aproveitar métodos de descrição existentes, desenvolvidos originalmente para o reconhecimento de faces em imagens de textura, na imagem de projeção resultante. Uma vantagem dessa abordagem está na grande quantidade de estudos que já foram realizados com esses métodos.

O foco deste trabalho é a análise da acurácia dos principais descritores 2D para o reconhecimento de faces 3D. O primeiro passo consistiu na realização de experimentos com os métodos de descrição *uniform grid sampling* (UGS), histograma de gradientes orientados (HOG, *histogram of oriented gradients*), padrões binários locais (LBP, *local binary patterns*), análise de componentes principais (PCA, *principal component analysis*) e análise discriminante linear (LDA, *linear discriminant analysis*) visando a descoberta dos parâmetros que produzem os melhores resultados. Em seguida, foi feita uma comparação entre os resultados obtidos com a melhor parametrização de cada descritor. Esses descritores foram escolhidos devido à existência de estudos em que eles foram usados para o reconhecimento facial 3D. Por exemplo, Yuan et. al [3] e Huang et. al [4] utilizaram, respectivamente, o PCA e o LBP para o reconhecimento facial com imagens de textura e de profundidade, e Pamplona Segundo et. al [5] apresentaram um sistema de autenticação contínua baseado na aplicação do HOG em imagens de profundidade.

O restante do artigo está dividido da seguinte maneira: na seção II, descrevemos os processos de detecção e normalização facial, de obtenção dos descritores e de comparação entre eles para cálculo do nível de similaridade; na seção III, descrevemos e analisamos os resultados obtidos; na seção IV, apresentamos nossas conclusões e trabalhos futuros.

## II. DESCRIÇÃO DAS ETAPAS

### A. Base de imagens

Este estudo foi realizado a partir das imagens de profundidade da base de imagens Face Recognition Grand Challenge (FRGC, versão 2) [6], as quais estão divididas em três conjuntos de acordo com o período de coleta: Spring-2003 (943 imagens), Fall-2003 (1893 imagens) e Spring-2004 (2114 imagens). O primeiro conjunto apresenta pouca variação de expressão facial e pose, o que facilita o reconhecimento. Os dois últimos são mais afetados por essas variações, e consequentemente são mais desafiadores em termos de reconhecimento. Todas as imagens da base apresentam resolução 640x480. Exemplos de imagens de cada conjunto são mostrados na Fig. 1.




Fig. 1. Exemplos de imagens de textura (cima) e de profundidade (baixo) da base FRGC correspondentes aos conjuntos Spring-2003 (esquerda), Fall-2003 (centro) e Spring-2004 (direita).

### B. Pré-processamento

O primeiro passo realizado consiste na transformação das imagens de profundidade em imagens de projeção ortogonal (*orthogonal projection images*) [7], as quais não apresentam distorção de perspectiva, para utilização na detecção facial. Em seguida, essas imagens passam para a normalização facial, que consiste no alinhamento da face a um modelo de referência, conforme descrito por Pamplona Segundo et. al [7], porém utilizando uma área facial diferente. O resultado é ilustrado na Fig. 2.




Fig. 2. Resultados da etapa de pré-processamento.

Os produtos dessa etapa de pré-processamento são imagens de intensidade de resolução 113x113, correspondentes às faces normalizadas. Apenas as imagens corretamente normalizadas

foram consideradas nas etapas seguintes. A Tabela I apresenta a distribuição das imagens descartadas entre os três conjuntos do banco. Como a etapa de normalização não é o foco desse trabalho, não houve preocupação em melhorá-la.

TABLE I  
DESCARTE DE IMAGENS DEVIDO A FALHAS DURANTE A NORMALIZAÇÃO.

Base	Imagens	Normalizadas	Descartadas
Spring-2003	943	847	96
Fall-2003	1893	1567	326
Spring-2004	2114	1788	326
Total	4950	4202	748

### C. Descrição

A etapa de descrição corresponde à aplicação de métodos que recebem como entrada a face normalizada, produto final da etapa de pré-processamento, e geram como resultado um descritor. Descritores gerados a partir de duas imagens diferentes são posteriormente comparados para decidir se elas correspondem à mesma pessoa ou não.

Neste estudo, foram considerados tanto métodos clássicos de descrição de imagens 2D (eg. LBP, HOG, PCA, LDA) quanto métodos simples de descrição (eg. imagem como descritor, UGS) para fins comparativos. Os métodos analisados são brevemente descritos a seguir.

1) *Imagem como descritor*: O vetor descritor é gerado simplesmente a partir da concatenação dos valores de intensidade da imagem em cada posição. A Fig. 3 ilustra o processo.




Fig. 3. Imagem como descritor.

2) *Uniform Grid Sampling*: Primeiramente, a imagem é dividida em regiões quadradas de mesmo tamanho. Depois, o vetor descritor é gerado a partir da concatenação dos valores de intensidade situados em uma posição fixa de cada região. Pequenas variações, tais como tomar o valor mínimo/máximo/médio/mediano de cada região, foram também testadas, porém produziram resultados similares. A Fig. 4 ilustra o processo.




Fig. 4. Uniform Grid Sampling.

Neste trabalho, consideramos o descritor UGS<sup>N</sup> como o resultado da aplicação do *uniform grid sampling* mediante divisão da imagem em regiões quadradas de tamanho  $N \times N$ . O uso da própria imagem como descritor corresponde ao caso especial UGS<sup>1</sup>.

3) *Histogram of Oriented Gradients*: O HOG, proposto por N. Dalal e B. Triggs [8], se baseia na ideia de que a aparência e a forma de um objeto podem ser descritas a partir da distribuição de seus gradientes de intensidade. O primeiro passo consiste em dividir a imagem em células, sobre as quais são computados histogramas de gradientes. Depois, as células são agrupadas em blocos, a partir dos quais ocorre a normalização dos histogramas. Finalmente, os histogramas individuais são concatenados formando o descritor.

Neste trabalho, consideramos o descritor HOG<sup>C,B,H</sup> como o resultado da aplicação do histograma de gradientes orientados com células de tamanho  $C \times C$ , blocos de tamanho  $B \times B$  e histograma com  $H$  posições. Antes da aplicação do método, a imagem foi redimensionada para resolução  $64 \times 64$  para torná-la compatível com os parâmetros utilizados.

4) *Local Binary Patterns*: A técnica LBP se fundamenta na ideia de que a estrutura local de uma imagem pode ser descrita pelo resultado da comparação dos seus valores de intensidade em cada posição com aqueles de posições vizinhas. Neste trabalho, foi adotado o LBP circular: como vizinhos do ponto  $(r, c)$  foram considerados  $P$  pontos uniformemente distribuídos da circunferência de raio  $R$  centrada em  $(r, c)$ , isto é,  $(r - R \sin \frac{2k\pi}{P}, c + R \cos \frac{2k\pi}{P})$  para  $0 \leq k < P$ . A partir dos valores de intensidade de cada um desses pontos, obtidos por interpolação, foi computado para cada pixel da imagem um valor inteiro no intervalo  $[0, P+1]$  correspondente ao resultado da aplicação do operador LBP<sup>riu2</sup><sub>P,R</sub> descrito por Ojala et. al [9].

Em seguida, a imagem foi dividida em regiões quadradas de tamanho  $A \times A$ , sobre as quais foram computados histogramas de  $P+2$  posições, uma para cada valor possível do operador. Por fim, os histogramas de cada região foram concatenados formando o descritor, que denotamos LBP<sup>P,R,A</sup>.

5) *Principal Component Analysis*: O PCA, proposto originalmente por Pearson [10], consiste na aplicação de uma transformação linear visando a redução da dimensionalidade de um conjunto de dados. Isso é atingido através da reescrita dos vetores de entrada em um novo sistema de coordenadas cujos eixos correspondem às direções em que ocorre maior variação nos dados. Essa ideia pode ser aproveitada para o reconhecimento facial, conforme proposto por Turk et. al [11], tomando como descritores os pesos para os vetores resultantes da aplicação do PCA.

Neste trabalho, o primeiro passo para a geração do descritor consistiu na reescrita da imagem de entrada em um sistema de coordenadas formado pelos  $K$  eixos de maior variação nas 847 imagens da base Spring-2003, a qual foi usada para treino. Em seguida, o vetor resultante  $u = (u_1, \dots, u_K)$  foi normalizado, produzindo como resultado o vetor  $v = (v_1, \dots, v_K)$ , onde

$$v_i = \frac{u_i - m}{M - m}$$

com  $M = \max\{u_1, \dots, u_K\}$  e  $m = \min\{u_1, \dots, u_K\}$ . Consideramos o descritor PCA<sup>K</sup> como esse vetor  $v$ .

6) *Linear Discriminant Analysis*: O LDA, proposto por Fisher [12], assim como o PCA, envolve a aplicação de uma transformação linear visando a reescrita dos dados de entrada. No entanto, ao invés de tomar como eixos do novo sistema de coordenadas aqueles em que ocorre maior variação no conjunto de dados, ela utiliza os eixos que são mais discriminativos para a separação do conjunto em classes. Essa ideia pode ser aproveitada para o reconhecimento facial, conforme proposto por Belhumeur et. al [13], tomando como descritores os pesos para os vetores resultantes da aplicação do LDA.

Neste trabalho, foram usadas para treino  $N = 847$  imagens de  $C = 261$  pessoas da base Spring-2003. O primeiro passo para a geração do descritor consistiu na compressão da imagem de entrada mediante aplicação da análise de componentes principais, conforme descrito anteriormente, que produziu como resultado um vetor de dimensão  $N - C$ . Em seguida, foi aplicada a análise discriminante linear sobre esse vetor para reescrevê-lo em um sistema de coordenadas composto pelos  $K$  eixos mais discriminativos. Por fim, o vetor resultante foi normalizado, produzindo como resultado o vetor  $v = (v_1, \dots, v_K)$ , onde

$$v_i = \frac{u_i - m}{M - m}$$

com  $M = \max\{u_1, \dots, u_K\}$  e  $m = \min\{u_1, \dots, u_K\}$ . Consideramos o descritor LDA<sup>K</sup> como esse vetor  $v$ .

#### D. Comparação

A etapa de comparação corresponde à execução de rotinas que recebem como entrada dois vetores descritores  $u, v \in \mathbb{R}^n$  e retornam um valor numérico indicativo do nível de similaridade entre eles. Neste trabalho, foram consideradas as distâncias de Manhattan ( $d_M$ ) e de Euclides ( $d_E$ ), mostradas respectivamente nas Equações 1 e 2.

$$d_M(u, v) = \sum_{i=1}^{i=n} |u_i - v_i| \quad (1)$$

$$d_E(u, v) = \sum_{i=1}^{i=n} u_i^2 + v_i^2 \quad (2)$$

### III. RESULTADOS

Foram realizados experimentos com os descritores mencionados usando diferentes parâmetros e métodos de comparação. O subconjunto Spring-2003 foi usado apenas para treino, quando necessário, enquanto os subconjuntos Fall-2003 e Spring-2004 foram usados para o cálculo da acurácia de cada abordagem. A análise dos resultados foi feita a partir da curva de características operacionais do receptor (ROC, *receiver operating characteristic*), que apresenta a taxa de positivos verdadeiros (TPR, *true positive rate*) em função da taxa de positivos falsos (FPR, *false positive rate*).

A Fig. 5 mostra que o UGS apresentou melhores resultados com a distância de Manhattan do que com a distância de Euclides. Com a distância de Manhattan, a melhor parametrização foi  $N = 18$  tanto na base Fall-2003 quanto na base Spring-2004. Com a distância de Euclides, a melhor parametrização foi  $N = 4$  nas duas bases. A proximidade dos resultados obtidos com os descritores UGS<sup>1</sup>, UGS<sup>4</sup>, UGS<sup>8</sup>, UGS<sup>12</sup> e UGS<sup>18</sup>, aliada ao bom desempenho relativo do UGS<sup>18</sup>, é um indicativo de que a perda de informações resultante da aplicação desses métodos não foi significativa, e conseqüentemente de que há uma grande quantidade de informações redundantes na imagem original de resolução  $113 \times 113$ .

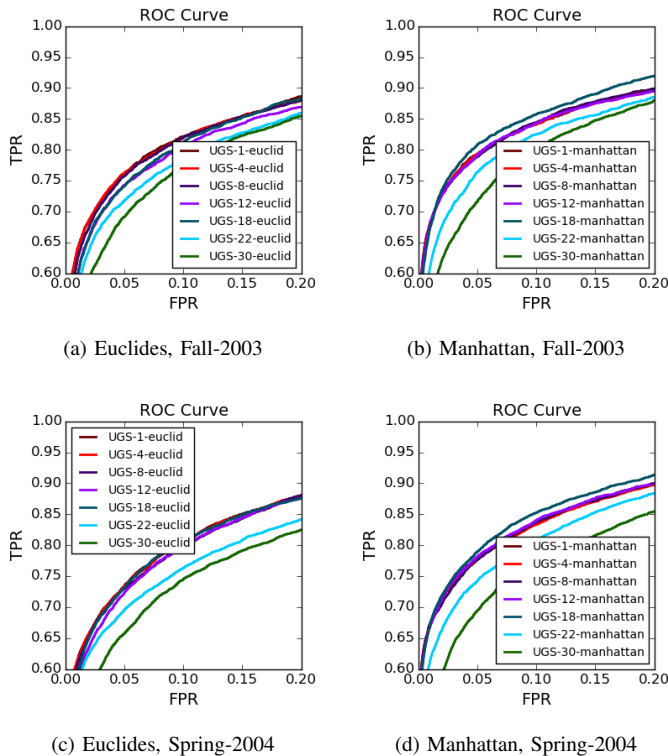


Fig. 5. Comparação da acurácia do reconhecimento facial utilizando *Uniform Grid Sampling* com diferentes parâmetros nos subconjuntos Fall-2003 e Spring-2004 da base FRGC.

A Fig. 6 mostra que o PCA apresentou melhores resultados com a distância de Euclides do que com a distância de Manhattan. Além disso, com ambas as distâncias, o PCA<sup>9</sup> foi o descritor que apresentou o melhor resultado tanto na base Fall-2003 quanto na base Spring-2004. O consistente decréscimo da performance apresentada pelo PCA com o aumento de sua dimensionalidade a partir de  $N = 9$  é um indicativo de que as dimensões adicionais são desnecessárias, e corrobora com a conjectura de que há muita informação redundante na imagem original. Finalmente, a grande diferença entre o desempenho do PCA e o desempenho do UGS indica que, no contexto do reconhecimento facial em imagens de profundidade, o uso dos eixos em que ocorre maior variação nos dados não é um bom

caminho para a compressão das imagens.

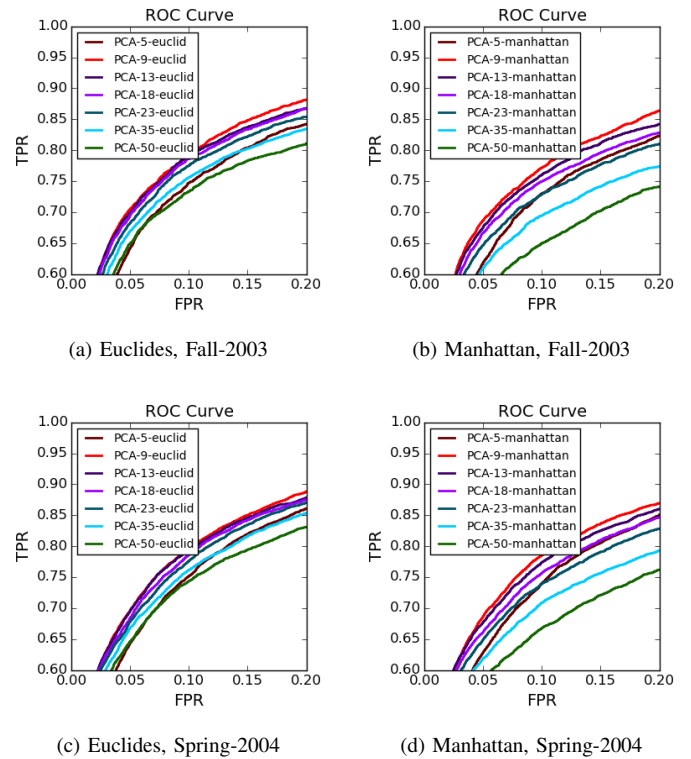



Fig. 6. Comparação da acurácia do reconhecimento facial utilizando *Principal Component Analysis* com diferentes parâmetros nos subconjuntos Fall-2003 e Spring-2004 da base FRGC.


A Fig. 7 mostra que o HOG apresentou resultados similares com a distância de Manhattan e com a distância de Euclides. Considerando os resultados obtidos usando ambas as distâncias nas bases Fall-2003 e Spring-2004, o descritor que apresentou bons resultados de forma mais consistente foi o HOG<sup>8,16,9</sup>, bastante utilizado na literatura, seguido do HOG<sup>4,8,9</sup>. O fato de ambos apresentarem tamanho da célula diferente do tamanho do bloco é um indicativo de que a normalização sobre o bloco foi importante para a melhoria do desempenho. Finalmente, o desempenho ruim do HOG quando comparado ao UGS indica que, diferentemente do que ocorre com imagens de textura, a aplicação do HOG em imagens de profundidade resulta na perda de informações discriminativas, o que degrada a acurácia do reconhecimento.

Devido à grande quantidade de possíveis parametrizações para o LBP<sup>P,R,A</sup>, o primeiro passo para a análise desse descritor foi a construção de um gráfico para cada valor  $P \in \{4, 5, 6, 7, 9, 11\}$  visando à obtenção dos valores  $R, A$  que produzem os melhores resultados em cada caso. Em seguida, foi construído o gráfico da Fig. 8, que mostra a melhor parametrização do descritor para cada valor  $P$  estudado. Ele mostra que o LBP apresentou melhores resultados com a distância de Euclides do que com a distância de Manhattan. Além disso, considerando os resultados obtidos com ambas as distâncias nas bases Fall-2003 e Spring-2004, os descritores que apresentaram bons resultados de forma mais consistente




(a) Euclides, Fall-2003

(b) Manhattan, Fall-2003




(a) Euclides, Fall-2003

(b) Manhattan, Fall-2003



(c) Euclides, Spring-2004

(d) Manhattan, Spring-2004



(c) Euclides, Spring-2004

(d) Manhattan, Spring-2004

Fig. 7. Comparação da acurácia do reconhecimento facial utilizando *Histogram of Oriented Gradients* com diferentes parâmetros nos subconjuntos Fall-2003 e Spring-2004 da base FRGC.

Fig. 8. Comparação da acurácia do reconhecimento facial utilizando *Local Binary Patterns* com diferentes parâmetros nos subconjuntos Fall-2003 e Spring-2004 da base FRGC.

foram o LBP<sup>5,2,6</sup> e o LBP<sup>7,3,7</sup>. Assim como no caso do HOG, o desempenho inferior do LBP em relação ao UGS indica que a utilização do LBP em imagens de profundidade resulta na perda de informações discriminativas e conseqüentemente reduz a qualidade do reconhecimento.

A Fig. 9 mostra que o LDA apresentou melhores resultados com a distância de Euclides do que com a distância de Manhattan. Além disso, com ambas as distâncias, o LDA<sup>50</sup> foi o descritor que apresentou o melhor resultado tanto na base Fall-2003 quanto na base Spring-2004. Nesse caso, o aumento da performance apresentada pelo LDA em função do aumento de sua dimensionalidade pode ser explicado pelo fato de que esse descritor incorpora as características discriminativas do conjunto de dados durante a etapa de treinamento, e portanto é menos afetado negativamente pela presença de informações adicionais. Por outro lado, a proximidade entre os resultados apresentados pelo LDA<sup>35</sup> e pelo LDA<sup>50</sup> é um indicativo de que a saturação desse descritor foi atingida: o acréscimo de novas dimensões a partir desse ponto resulta em um ganho de performance cada vez menos significativo. Finalmente, o LDA apresentou o melhor resultado dentre todos os descritores considerados, conforme evidenciado pela Fig. 10, que apresenta uma comparação entre os resultados obtidos pela melhor parametrização de cada descritor. O segundo melhor método foi o UGS, seguido do LBP e do HOG, nessa ordem. O PCA ficou em último lugar, com uma distância considerável dos

demais métodos.

#### IV. CONCLUSÃO

Os gráficos apresentados neste trabalho mostram que métodos robustos como LBP, HOG e PCA exibem resultados inferiores àqueles do UGS, um método consideravelmente mais simples, quando utilizados para o reconhecimento de faces em imagens 3D. Isso indica que, apesar da existência de estudos realizados com esses descritores para o reconhecimento facial 3D [4], [5], [3], eles não são a melhor alternativa para essa finalidade. Conseqüentemente, fica evidenciada a necessidade de buscar métodos de descrição específicos para uso no reconhecimento facial a partir de imagens de profundidade.

Além disso, o bom desempenho do LDA aplicado sobre o PCA, que utilizado individualmente apresentou o pior resultado dentre os métodos estudados, revela que a combinação do LDA com melhores descritores 3D a serem explorados pode ser um bom caminho para a melhoria da acurácia do reconhecimento facial 3D. Vale ressaltar, no entanto, que o LDA está em vantagem por ser o único que realiza um treinamento discriminativo.

Finalmente, um descritor que, aplicado individualmente e sem etapa de treinamento, apresenta resultados comparáveis àqueles do LDA está sendo aperfeiçoado e sua combinação com o LDA será estudada. No futuro, pretende-se também realizar experimentos com métodos mais robustos de comparação do que as distâncias de Manhattan e de Euclides.



## REFERENCES

- [1] K. Bowyer, K. Chang, and P. Flynn, "A survey of approaches to three-dimensional face recognition," in *Pattern Recognition, 2004. ICPR 2004. Proceedings of the 17th International Conference on*, vol. 1, Aug 2004, pp. 358–361 Vol.1.
- [2] T. Russ, M. Koch, and C. Little, "3d facial recognition: a quantitative analysis," in *Security Technology, 2004. 38th Annual 2004 International Carnahan Conference on*, Oct 2004, pp. 338–344.
- [3] X. Yuan, J. Lu, and T. Yahagi, "A method of 3d face recognition based on principal component analysis algorithm," in *Circuits and Systems, 2005. ISCAS 2005. IEEE International Symposium on*, May 2005, pp. 3211–3214 Vol. 4.
- [4] D. Huang, M. Ardabilian, Y. Wang, and L. Chen, "Asymmetric 3d/2d face recognition based on lbp facial representation and canonical correlation analysis," in *Image Processing (ICIP), 2009 16th IEEE International Conference on*, Nov 2009, pp. 3325–3328.
- [5] M. Pamplona Segundo, S. Sarkar, D. Goldgof, L. Silva, and O. Bellon, "Continuous 3d face authentication using rgb-d cameras," in *Computer Vision and Pattern Recognition Workshops (CVPRW), 2013 IEEE Conference on*, June 2013, pp. 64–69.
- [6] P. J. Phillips, P. J. Flynn, T. Scruggs, K. W. Bowyer, J. Chang, K. Hoffman, J. Marques, J. Min, and W. Worek, "Overview of the face recognition grand challenge," in *Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05) - Volume 1 - Volume 01*, ser. CVPR '05. Washington, DC, USA: IEEE Computer Society, 2005, pp. 947–954. [Online]. Available: <http://dx.doi.org/10.1109/CVPR.2005.268>
- [7] M. P. Segundo, L. Silva, O. R. P. Bellon, and S. Sarkar, "Orthogonal projection images for 3d face detection," *Pattern Recognition Letters*, 2013.
- [8] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," in *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, vol. 1, June 2005, pp. 886–893 vol. 1.
- [9] M. P. T. Ojala and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *Pattern Analysis and Machine Intelligence*, vol. 24, pp. 971–987, 2001.
- [10] K. Pearson, "On lines and planes of closest fit to systems of points in space," *Philosophical Magazine*, pp. 559–572, 1901.
- [11] M. Turk and A. Pentland, "Eigenfaces for recognition," *J. Cognitive Neuroscience*, vol. 3, no. 1, pp. 71–86, Jan. 1991. [Online]. Available: <http://dx.doi.org/10.1162/jocn.1991.3.1.71>
- [12] R. A. Fisher, "The use of multiple measurements in taxonomic problems," *Annals of Eugenics*, vol. 7, no. 2, pp. 179–188, 1936. [Online]. Available: <http://dx.doi.org/10.1111/j.1469-1809.1936.tb02137.x>
- [13] P. Belhumeur, J. Hespanha, and D. Kriegman, "Eigenfaces vs. fisherfaces: recognition using class specific linear projection," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 19, no. 7, pp. 711–720, Jul 1997.

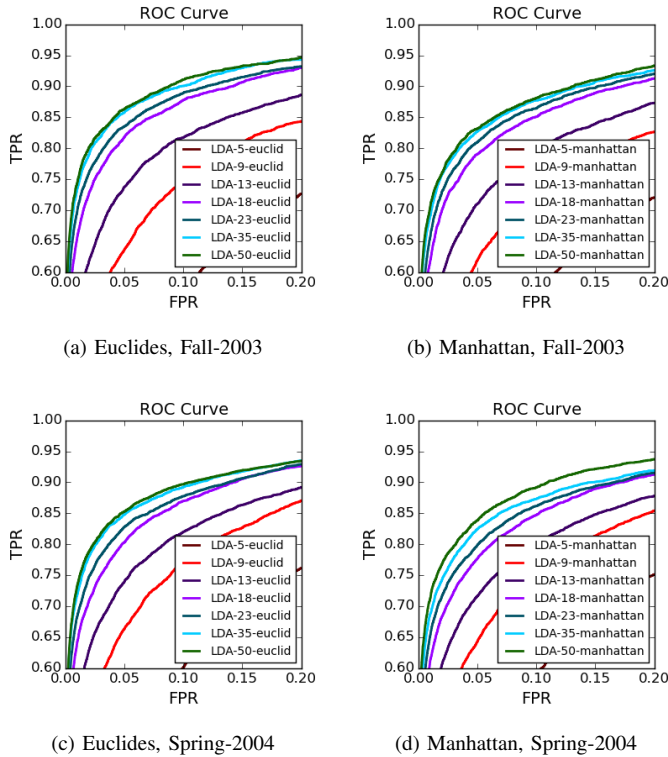


Fig. 9. Comparação da acurácia do reconhecimento facial utilizando *Linear Discriminant Analysis* com diferentes parâmetros nos subconjuntos Fall-2003 e Spring-2004 da base FRGC.

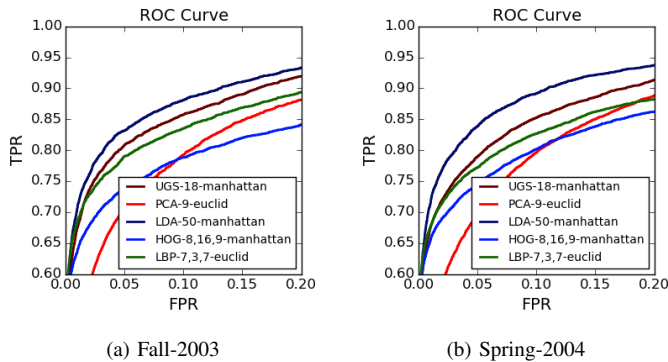


Fig. 10. Comparação da acurácia do reconhecimento facial utilizando a melhor parametrização de cada descritor estudado nos subconjuntos Fall-2003 e Spring-2004 da base FRGC.

## AGRADECIMENTOS

Os autores gostariam de agradecer à UFBA e ao CNPq pelo suporte financeiro.