

Filtragem Discriminativa com Análise de Componentes Principais e Alinhamento Adaptativo

Kenny Vinente dos Santos, Wheidima Carneiro de Melo, Waldir Sabino da Silva Júnior e Eddie Batista de Lima Filho

Resumo—Filtragem discriminativa é uma técnica de reconhecimento de padrões que procura maximizar a energia do sinal de saída quando um padrão é encontrado. Procurando melhorar a robustez, incorporou-se a análise de componentes principais nos filtros discriminativos. Neste trabalho, propomos uma nova técnica para o projeto dos filtros discriminativos, denominada alinhamento adaptativo. Para validação, utilizou-se um sistema de detecção de pontos fiduciais faciais com a base de dados *BioID*.

Palavras-Chave—Filtragem Discriminativa, Análise de Componentes Principais, Alinhamento Adaptativo.

Abstract—Discriminative filtering is a pattern recognition technique which seeks to maximize the energy of output signal when a pattern is found. To improve the robustness, Principal Component Analysis was incorporated in discriminative filter design. In this work, we propose a new technique for designing the discriminative filters, called adaptive alignment. In order to validate the technique, it was applied to detect facial fiducial points on images of *BioID* database.

Keywords—Discriminative Filtering, Principal Component Analysis, Adaptive Alignment.

I. INTRODUÇÃO

Nos últimos anos, com o surgimento de novas tecnologias tais como câmeras digitais portáteis, celulares com integração a redes sociais e televisores com suporte a vídeo digital, aumentou o interesse da comunidade científica em estudar métodos que possibilitem detecção/reconhecimento de objetos. Os estudos provenientes da área de reconhecimento de padrões podem ser aplicados na solução destes problemas. Em geral, os objetos de interesse da detecção ou reconhecimento são analisados e retiram-se várias informações dos mesmos para projetar um algoritmo que irá desempenhar a função de detecção/reconhecimento de maneira automática. Uma das características dos estudos desta área é a possibilidade de aplicar as técnicas desenvolvidas para resolver problemas em diversas aplicações da engenharia. Podem ser encontrados na literatura diversas aplicações que utilizam estes sistemas, por exemplo: detecção de pontos fiduciais faciais [1], [4], [16], reconhecimento de faces [3], [12], [17] e localização de falhas em sistemas elétricos [13], [18].

Existem diversas abordagens para implementar estes sistemas. Uma destas é a filtragem discriminativa, que tem como

Kenny Vinente dos Santos e Waldir Sabino da Silva Júnior, Departamento de Petróleo e Gás e Departamento de Eletrônica e Computação, Universidade Federal do Amazonas, Manaus-AM, Brasil. E-mails: kennyvinente@ufam.edu.br, waldirjr@ufam.edu.br. Wheidima Carneiro de Melo, Departamento de Engenharia Elétrica, Universidade do Estado do Amazonas, Manaus-AM, Brasil. E-mail: wheidimawcm@gmail.com. Eddie Batista de Lima Filho, Centro de Ciência, Tecnologia e Inovação do Pólo Industrial de Manaus, Manaus-AM, Brasil. E-mail: eddie@ctpim.org.br.

objetivo projetar filtros utilizando formulações fechadas [10] para detectar padrões de interesse pré-estabelecidos. Uma vantagem deste método é realizar a detecção por filtragem linear, podendo ser combinada com técnicas de processamento digital de sinais. Em [1], encontra-se uma nova classe de filtros discriminativos robustos, projetados com o auxílio da análise de componentes principais. Nesta abordagem, os filtros são projetados para as componentes principais de maior energia do padrão de interesse.

Neste trabalho, propomos uma nova metodologia para o projeto dos filtros discriminativos, utilizando um método denominado alinhamento adaptativo. Inicialmente, percebeu-se que os filtros discriminativos apresentavam problemas na detecção quando os padrões de interesse apresentavam desvios quanto a sua localização e disposição. As consequências apareciam diretamente no resultado da classificação, levando o classificador a tomar decisões incorretas. Com a nossa proposta, pretendemos aumentar o desempenho dos sistemas que contém filtros discriminativos, usando os resultados obtidos da filtragem discriminativa original para reprojeter os filtros e auxiliar o classificador na tomada de decisão. Para validação, será utilizado um sistema de detecção de pontos fiduciais faciais. Pontos fiduciais podem ser entendidos como pontos salientes, para a face, alguns exemplos são o centro dos olhos, cantos da boca e ponta do nariz. Nos experimentos, serão utilizados 11 pontos fiduciais e como base de dados serão utilizados um subconjunto de 503 imagens da base de dados *BioID* [14]. Os resultados das simulações serão avaliados utilizando Taxas de Verdadeiros (TP) e Falsos Positivos (FP).

Este trabalho está organizado como segue: Na Seção II, temos a revisão dos conceitos associados a filtragem discriminativa com análise de componentes principais. Na Seção III, apresentamos o método por alinhamento adaptativo. Os experimentos e resultados estão na Seção IV e por fim, as conclusões são comentadas na Seção V.

II. REVISÃO DA LITERATURA

A. Filtragem Discriminativa

A filtragem discriminativa [2] é uma técnica de reconhecimento de padrões cujo objetivo é projetar um filtro linear bidimensional Θ que irá maximizar a energia do sinal $\mathbf{C}_{M \times M}$ na posição de ocorrência do padrão de interesse $\mathbf{U}_{M \times M}$. O sinal \mathbf{C} é obtido pela convolução entre \mathbf{U} e Θ . Para calcular a energia de \mathbf{C} , será utilizado a métrica denominada $DSNR_2$ (Relação Sinal-Ruído Discriminativa Bidimensional).

$$\text{DSNR}_2(m_0, n_0) = \frac{c(m_0, n_0)^2}{\sum_{i=0}^{M-1} \sum_{j=0}^{N-1} c(i, j)^2 - c(m_0, n_0)^2}, \quad (1)$$

sendo $c(m, n)$ o valor da amostra do sinal \mathbf{C} na posição (m, n) .

Em [10], os autores apresentam uma formulação fechada para o projeto do filtro Θ utilizando a abordagem por restauração do impulso [5]. Podemos interpretar este tratamento da seguinte forma: dado uma imagem $g(m, n)$ composta por um padrão de interesse $f(m, n)$ localizado na posição (m_0, n_0) , e o resto da imagem $b(m, n)$, tem-se:

$$g(m, n) = f(m - m_0, n - n_0) + b(m, n). \quad (2)$$

Na Equação (2), o sinal $f(m - m_0, n - n_0)$ é igual a convolução do padrão $f(m, n)$ com um impulso $\delta(m - m_0, n - n_0)$. Nesta abordagem convertemos o problema de localização da posição do padrão (m_0, n_0) em um problema de restauração do impulso, em que a imagem é composta por um padrão $f(m, n)$ localizado na posição do impulso, além de ruído aditivo $b(m, n)$. Utilizando notação matricial, obtem-se:

$$\mathbf{g} = \mathbf{F}\boldsymbol{\delta} + \mathbf{b}, \quad (3)$$

na qual \mathbf{F} é a matriz circulante cuja primeira linha é composta pelo padrão de interesse.

O filtro ótimo Θ será aquele que restaura o impulso $\boldsymbol{\delta}$. Utilizando critério por *Erro Quadrático Médio Mínimo Linear* (LMMSE), a melhor estimativa de $\boldsymbol{\delta}$ igual a $\hat{\boldsymbol{\delta}}$ obtida por este método, considerando um cenário no qual o ruído \mathbf{b} é gaussiano com média zero e matriz de covariância igual a $\frac{1}{N}\mathbf{C}_{bN \times N}$, é expressa por:

$$\hat{\boldsymbol{\delta}} = \mathbf{F}^T [\mathbf{F}\mathbf{F}^T + \mathbf{C}_b]^{-1} \mathbf{g} = \mathbf{A}\mathbf{g}, \quad (4)$$

sendo o superescrito T o Hermitiano. O filtro discriminativo Θ pode ser obtido por inspeção em \mathbf{A} [9].

B. Filtragem Discriminativa com Análise de Componentes Principais (FD-PCA)

Em [1], os autores propõem um método para projeto de filtros discriminativos robustos, denominado filtragem discriminativa com análise de componentes principais. Nesta abordagem, os filtros discriminativos são projetados utilizando as componentes principais [7] do conjunto de matrizes formadas pelas ocorrências dos padrões de interesse. Matematicamente, podemos obter estes filtros da seguinte forma: suponha uma variável aleatória $\mathcal{U}_{N \times 1}$ com M realizações iguais aos vetores $\mathbf{u}_1, \dots, \mathbf{u}_M$. As componentes principais $\Phi = [\phi_1, \phi_2, \dots, \phi_N]$ e respectivos autovalores $\lambda_1, \lambda_2, \dots, \lambda_N$ podem ser determinados pela solução do problema de autovalores descrito por:

$$\Lambda = \Phi^{*T} \Sigma_{\mathcal{U}} \Phi, \quad (5)$$

no qual $\Sigma_{\mathcal{U}}$ é a matriz de covariância de \mathcal{U} .

Os filtros discriminativos bidimensionais $\Theta_{\phi_1, \dots, \phi_S}$ são projetados para as S componentes principais ϕ_1, \dots, ϕ_S com autovalores associados $\lambda_1, \dots, \lambda_S$, de acordo com a Equação (5). Desta forma, a equação do novo estimador é dada por:

$$\mathbf{A}_{\phi_i} = \mathbf{F}_{\phi_i}^T [\mathbf{F}_{\phi_i} \mathbf{F}_{\phi_i}^T + \mathbf{C}_{b_i}]^{-1}. \quad (6)$$

E finalmente, os autores interpretam \mathbf{C}_{b_i} como o subespaço composto pelas componentes principais de interesse. Neste cenário, a matriz de covariância \mathbf{C}_{b_i} associada à ϕ_i possui expressão:

$$\mathbf{C}_{b_i} = \sum_{\substack{j=1 \\ j \neq i}}^N \psi_j \mathbf{F}_{\phi_j} \mathbf{F}_{\phi_j}^T, \quad (7)$$

sendo ψ_j as constantes que indicam a estatística do ruído e \mathbf{F}_{ϕ_j} é a matriz circular formada pelos blocos obtidos da componente ϕ_j .

III. FILTRAGEM DISCRIMINATIVA COM ANÁLISE DE COMPONENTES PRINCIPAIS E ALINHAMENTO ADAPTATIVO (FD-PCA-AA)

Uma das vantagens introduzidas na incorporação da análise de componentes principais no projeto dos filtros discriminativos é a possibilidade de projetar filtros Θ_{ϕ_1} para detectar padrões representados por uma variável aleatória \mathcal{U} . A formulação apresentada pelo autor utilizou como base o modelo da variável aleatória sendo gaussiana. Desta forma, observa-se que caso o padrão de análise se aproxime de uma variável aleatória gaussiana, devemos obter resultados satisfatórios no cálculo da DSNR_2 .

Considerando um cenário com M realizações $\mathbf{u}_1, \dots, \mathbf{u}_M$ da variável aleatória, para o filtro Θ_{ϕ_1} , cada realização \mathbf{u}_i irá possuir um valor definido de DSNR_2 . Idealmente, espera-se estes valores maximizados na posição em que o padrão ocorreu (Seção II), porém, em muitos casos isto não ocorre. Para cada realização M de \mathcal{U} , podemos ter três possíveis situações para a DSNR_2 :

- 1) A DSNR_2 está maximizada na localização do padrão. O sinal resultante \mathbf{C} é aproximadamente um impulso localizado na posição de ocorrência do padrão.
- 2) A DSNR_2 não possui o comportamento esperado. O sinal resultante \mathbf{C} possui baixa correlação com o impulso.
- 3) A DSNR_2 está maximizada em uma localização diferente da que o padrão ocorre.

Idealmente, espera-se que a situação 1 ocorra para todas as M realizações de \mathcal{U} , porém os casos 2 e 3 também acontecem. Os motivos que levam a ocorrência da situação 2 e 3 são diversos, porém um dos maiores influenciadores para a ocorrência destas situações surge da derivação do FD-PCA, que considera estarmos trabalhando com uma variável aleatória gaussiana e portanto, a avaliação da DSNR_2 irá depender do quão próximo a variável aleatória que representa o padrão se aproxima de um modelo gaussiano. Dependendo do conjunto de imagens utilizadas no sistema, esta representação

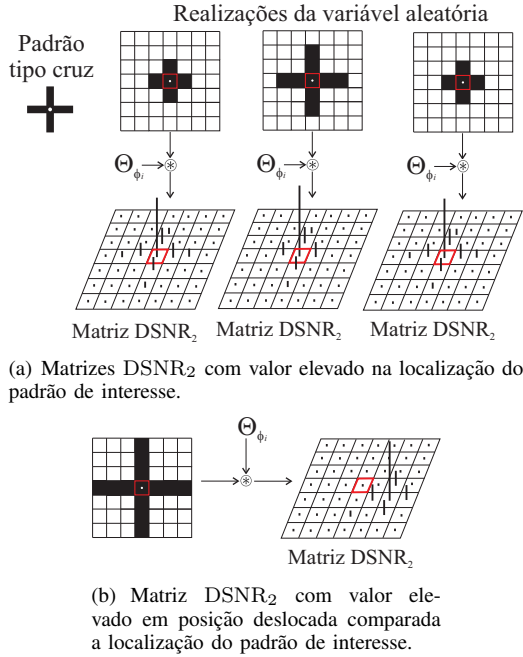


Fig. 1. Exemplos de matrizes DSNR₂ obtidas pelo método FD-PCA. Em (a), o valor elevado da DSNR₂ na posição central indica que o padrão de interesse foi localizado corretamente. Em (b), apesar de termos uma realização do padrão de interesse, obtemos uma matriz DSNR₂ com impulso localizado em uma posição diferente do padrão.

por modelo gaussiano poderá apresentar um erro considerável. Outro fator de influencia está em imagens que são diferentes da maioria do conjunto de imagens, por exemplo, em um grupo de imagens de fotografias de rostos, podemos ter um pequeno grupo de imagens na qual os indivíduos bateram fotos com o olho fechado. Estas imagens possuirão comportamento diferente das demais, levando a resultados imprevisíveis.

Analisando o caso 3, na grande maioria das suas ocorrências podemos interpretá-lo como uma detecção correta do padrão, porém em uma localização diferente da original (a Fig. 1 ilustra este entendimento). Atraves dessa idéia, surgiu o método FD-PCA-AA, com o objetivo de procurar corrigir o erro da localização do padrão detectado no projeto dos filtros discriminativos para as componentes principais, através do projeto de novos filtros discriminativos $(\Theta_{\phi_i})^j$, em que o superescrito j indica o j -ésimo filtro discriminativo Θ_{ϕ_i} projetado. Matematicamente, podemos apresentar o novo método como um problema de otimização com restrições, enunciado a seguir: considere um subconjunto $N \in M$ das realizações de \mathcal{U} estando na situação 3 e que a realização \mathbf{u}_k contém o padrão de interesse. Desta forma, temos:

$$\begin{aligned} & \max \mathbf{u}_k \otimes (\Theta_{\phi_i})^j, \forall \mathbf{u}_k \in N \\ & \text{sujeito a } \mathbf{u}_l \otimes (\Theta_{\phi_i})^j = c_l \pm \epsilon, \forall \mathbf{u}_l \in M - N, \end{aligned} \quad (8)$$

no qual $c_l = \mathbf{u}_l \otimes (\Theta_{\phi_i})^{j-1}$ representa o sinal resultante da filtragem discriminativa realizada antes do alinhamento e $M - N$ é o conjunto de realizações resultantes quando se remove as N realizações que serão alteradas pelo alinhamento adaptativo e o termo ϵ é uma tolerância. É importante observar que se nenhuma otimização for realizada, os filtros projetados

com alinhamento adaptativo serão iguais aos filtros sem alinhamento. Neste trabalho, para resolver esta expressão, utilizamos uma solução por algoritmo com rotina iterativa.

IV. EXPERIMENTOS E RESULTADOS

A. Sistema de Detecção de Pontos Fiduciais Faciais

Para avaliar o desempenho dos filtros discriminativos com alinhamento adaptativo utilizou-se um sistema supervisionado de detecção de pontos fiduciais faciais. Este sistema possui dois estágios: treinamento e teste (Figuras 2 and 3). Em ambos os casos, existe um bloco de pré-processamento para as imagens [1], constituído por: detector de faces Viola-Jones [11], bloco de escalonamento para resolução 220×220 e etapa de correção de iluminação [8] e Modelo Gaussiano *a Priori* [1]. Esta etapa é necessária para o sistema, pois além de realizar a segmentação da face e da região de interesse, a normalização para uma única resolução padroniza o sistema. Além disso, a correção de iluminação salienta as diferenças existentes na imagem e diminui os efeitos de iluminação.

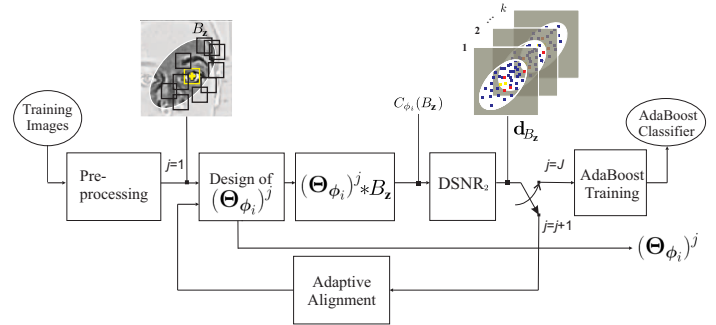


Fig. 2. Rotina de treinamento para o sistema de detecção de pontos fiduciais utilizando FD-PCA-AA.

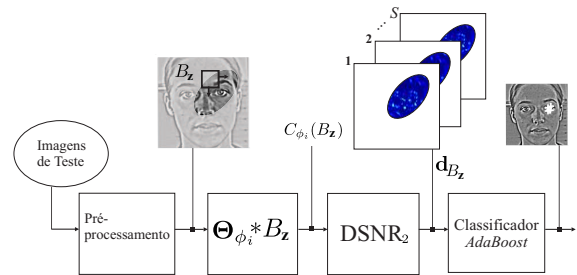


Fig. 3. Rotina de teste para o sistema de detecção de pontos fiduciais utilizando FD-PCA-AA.

A rotina de treinamento (Figure 2) pode ser entendida a seguir: primeiro, realizamos o pré-processamento das imagens. Em seguida, os S filtros discriminativos Θ_{ϕ_i} serão projetados para cada componente principal. Utilizando uma janela deslizante, cada bloco B_z (blocos pertencentes a imagem, escolhidos de maneira aleatória) pertencente a região elíptica de interesse é filtrado por todos os S filtros Θ_{ϕ_i} , gerando S matrizes $C_{\phi_i}(B_z)$. Utilizando a Equação (1) obtemos os valores de DSNR₂ para as matrizes $C_{\phi_i}(B_z)$. Então, cada bloco B_z terá um vetor de DSNR₂ associado, denominado \mathbf{d}_{B_z} com dimensões $1 \times S$.

Após realizar o projeto dos filtros, para cada imagem de treino será analisada a $DSNR_2$ e seu comportamento, utilizando como referência as situações descritas na Seção III. Se o subconjunto N possuir um número elevado de elementos, então a variável j é incrementada em 1 e realizamos o processo de alinhamento adaptativo. Esta rotina poderá ser repetida até o momento da condição de parada $j = J$ ser atendida. Esta condição J pode ser definida utilizando algum critério geral, por exemplo, podemos condicionar J como o momento no qual maximizou-se todas as matrizes $DSNR_2$ das imagens pertencentes ao subconjunto N . Para adaptar o algoritmo ao problema de otimização apresentado, utilizamos a seguinte idéia: melhorar os valores de $DSNR_2$ de todos os elementos que estão na situação (3) (descrito na Seção III), tentando manter os resultados obtidos para o resto das imagens. Nos experimentos conduzidos neste trabalho, realizamos uma iteração no algoritmo.

Dando sequência, após o processo de alinhamento, os vetores finais \mathbf{d}_{B_z} serão utilizados no treinamento do classificador AdaBoost utilizando a *toolbox* GML AdaBoost [15]. A saída do estágio de treinamento consiste nos filtros $(\Theta_{\phi_i})^j$, o classificador AdaBoost projetado e o bloco contendo o valor médio dos padrões de interesse μ_U .

O procedimento de teste, apresentado na Fig. 3, pode ser descrito como: inicialmente, a imagem de entrada é pré-processada. Em seguida, utilizando uma janela deslizante, processamos cada bloco B_z obtido. As matrizes $C_{\phi_i}(B_z)$ serão obtidas pela filtragem entre $B_z - \mu_U$ e cada um dos S filtros $(\Theta_{\phi_i})^j$. Depois, calculamos a $DSNR_2$ para cada $C_{\phi_i}(B_z)$, resultando em um vetor denominado \mathbf{d}_{B_z} . O classificador AdaBoost irá categorizar \mathbf{d}_{B_z} como positivo (o centro de B_z contem o ponto fiducial de interesse) ou negativo (caso contrário).

B. Resultados das Simulações

Para avaliar o método proposto, utilizamos um total de 11 pontos fiduciais de um subconjunto de 503 imagens da base de dados *BioID* [14]. Os pontos fiduciais e sua numeração podem ser visualizados na Fig. 4. Em todos os experimentos, realizamos validação cruzada utilizando 7 partições, respeitando a relação 6/7 do total de imagens para o conjunto de treinamento e 1/7 para o conjunto de teste. O critério utilizado para verificar o desempenho do sistema são as taxas de TP e FP. Um candidato é considerado verdadeiro positivo quando a distância entre ele e a marcação verdadeira (anotada manualmente) for menor ou igual a 10 % da distância intra-ocular (distância entre pupilas) para a face sob avaliação [1].

Os resultados obtidos pelo método proposto (FD-PCA-AA) para cada ponto fiducial estão sumarizados na Tabela I. Para comparação, incluímos os resultados obtidos pelo método por Filtragem Discriminativa com Análise de Componentes Principais (FD-PCA) além do método Máquinas de Vetores Suporte (SVM) linear e polinomial de ordem 2, utilizando uma configuração semelhante ao sistema de detecção de pontos fiduciais proposto, sob as mesmas condições utilizadas para o treinamento e teste [6]. A partir desta tabela, podemos verificar que o método proposto apresenta bons resultados se



Fig. 4. Face com pontos fiduciais.

comparados ao FD-PCA e SVM (utilizou-se um sistema com SVM em cascata e dois estágios). Observa-se ainda que a taxa de FP obtida pelo FD-PCA-AA em geral é menor em relação ao FD-PCA. A motivação deste resultado pode ser observada na Fig. 5. Nesta figura, comparamos os resultados obtidos para ponto fiducial 0 em duas imagens. Observa-se uma maior quantidade de candidatos a ponto fiducial no método FD-PCA, resultando em uma maior taxa de FP. Uma das justificativas da diminuição do FP surge da rotina de iteração, uma vez que o alinhamento adaptativo procura consertar os casos em que a $DSNR_2$ apresenta valores elevados numa posição diferente de onde está localizado o ponto fiducial. Ainda podemos entender que a abordagem proposta compete com métodos baseados em SVM para todos os pontos fiduciais, superando nos pontos 0, 2, 4, 5, 6, 7, 9 e 10. Um ponto negativo neste algoritmo é a rotina de iteração, que claramente aumenta o tempo de projeto dos filtros (etapa de treinamento).

TABELA I

RESULTADOS OBTIDOS PELO MÉTODO FD-PCA-AA, UTILIZANDO VALIDAÇÃO CRUZADA, PARA O SUBCONJUNTO DA BASE DE DADOS *BioID*.

Ponto Fiducial	FD-PCA		SVM		FD-PCA-AA (proposto)	
	TP	FP	TP	FP	TP	FP
0	97,0	0,05	80,5	0,21	96,8	0,03
1	96,8	0,05	99,6	0,02	96,4	0,04
2	95,4	0,15	85,0	0,08	96,0	0,13
3	95,4	0,13	98,6	0,03	97,8	0,03
4	96,0	0,05	95,2	0,05	97,8	0,03
5	96,8	0,03	90,2	0,12	96,6	0,03
6	92,6	0,08	92,2	0,06	94,8	0,08
7	89,4	0,10	47,1	0,03	94,2	0,09
8	93,6	0,09	95,2	0,07	94,2	0,09
9	91,0	0,14	88,4	0,14	88,8	0,13
10	85,8	0,07	68,5	0,06	86,4	0,07

V. CONCLUSÕES

Neste trabalho apresentamos uma nova metodologia para projeto dos filtros discriminativos denominada filtragem discriminativa com análise de componentes principais e alinhamento adaptativo. Foram realizados experimentos em um sistema de detecção de pontos fiduciais faciais utilizando um subconjunto de 503 imagens da base de dados *BioID*, com validação cruzada, dividindo o total de imagens em dois segmentos: 6/7 do total de imagens para o conjunto de treinamento e 1/7 do total de imagens para o conjunto de teste.




Fig. 5. Marcações obtidas: método original (esquerda) × método proposto (direita).

total para conjunto de teste. Os resultados obtidos mostram que o método proposto pode competir com os métodos similares baseados em filtragem discriminativa com PCA e também com métodos por SVM. Uma vantagem nesta nova abordagem está na taxa de FP, que apresentou uma redução na maioria dos experimentos resultados, comparado FD-PCA original. Em relação à taxa de TP, os resultados do FD-PCA-AA competem com ambos os métodos FD-PCA e SVM para a maioria dos pontos fiduciais em análise.

REFERÊNCIAS

- [1] W. S. S. Júnior e G. M. Araújo e E. A. B. Silva e S. K. Goldenstein, "Facial Fiducial Points Detection Using Discriminative Filtering on Principal Components". Em: *Proceedings of 2010 IEEE 17th International Conference on Image Processing*, Setembro 2010, Honk Kong.
- [2] A. Mendonca e E. A. B. Silva, "Two-Dimensional Discriminative Filters for Image Template Detection". Em: *Proceedings of the International Conference on Image Processing*, pp. 680–683, Setembro 2001, Thessaloniki, Grécia.
- [3] G. Guo e S. Z. Li e K. Chan, "Face Recognition by Support Vector Machines". Em: *Proceedings of the Fourth IEEE International Conference on Automatic Face and Gesture Recognition*, pp. 196–201, 2000.
- [4] G. M. Araújo e W. S. S. Júnior e E. A. B. Silva e S. K. Goldenstein, "Facial LandMark Detection Based on Correlation Filters". Em: *Proceedings of International Telecommunications Symposium*, 2010, Manaus, Brazil.
- [5] A. Abu-Naser e N. P. Galatsanos e M. N. Wernick, "Impulse Restoration-based Template-matching Using the Expectation-maximization Algorithm". Em: *Proceedings of the 1997 International Conference on Image Processing (ICIP '97)*, v. 3, pp. 158–, 1997.
- [6] K. V. Santos e L. E. S. Silva e W. S. S. Júnior, "Influence of Quantity of Principal Component in Discriminative Filtering". Em: *Second International Conference on Computational Science and Engineering (CSE-2014)*, Abril 2014, Dubai, UAE.
- [7] M. Kirby e L. Sirovich, "Application of the Karhunen-Loève Procedure for the Characterization of Human Faces". *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 12, n. 1, pp. 103–108, Janeiro 1990.
- [8] T. Xiaoyang e B. Triggs, "Enhanced Local Texture Feature Sets for Face Recognition Under Difficult Lighting Conditions". *IEEE Transactions on Image Processing*, v. 19, n. 6, pp. 1635–1650, Janeiro 2010.
- [9] A. Mendonca e E. A. B. Silva, "Multiple Template Detection using Impulse Restoration and Discriminative Filters". *IEEE Electronics Letters*, v. 36, n. 16, pp. 1172–1174, Agosto 2003.
- [10] A. Mendonca e E. A. B. Silva, "Closed-Form Solutions for Discriminative Filtering using Impulse Restoration Techniques". *IEEE Electronics Letters*, v. 38, n. 22, pp. 1332–1333, Outubro 2002.
- [11] P. Viola e M. Jones, "Robust real-time object detection". *International Journal of Computer Vision*, v. 57, n. 2, pp. 137–154, Julho 2001.
- [12] P. Campadelli e R. Lanzarotti e G. Lipori, "Automatic Facial Feature Extraction for Face Recognition". *Face Recognition*. I-Tech Education and Publishing, 2007, Vienna, Austria.
- [13] Y. Zhang et al., "Fault Pattern Recognition in Power System Engineering". Em: *International Conference on Industrial Mechatronics and Automation*, pp. 109–112, 2009.
- [14] The BioID Database. Disponível em: <http://www.bioid.com/>. Acesso em: 01 de Fevereiro de 2015.
- [15] The GML AdaBoost Matlab toolbox. Disponível em: <http://graphics.cs.msu.ru/en/science/research/machinelearning/>. Acesso em: 04 de Fevereiro de 2015.
- [16] H. Cevikalp e B. Triggs e V. Franc, "Face and landmark detection by using cascade of classifiers". Em: *10th IEEE International Conference and Workshops on Automatic Face and Gesture Recognition (FG)*, pp. 1–7, Abril 2013, Shanghai.
- [17] A. Jain e J. Bharti e M. K. Gupta, "Improvements in OpenCV's Viola Jones Algorithm in Face Detection - Tilted Face Detection". *International Journal on Signal and Image Processing*, v. 5, pp. 21–28, Maio 2014.
- [18] B. M. Ebrahimi et al., "Advanced Eccentricity Fault Recognition in Permanent Magnet Synchronous Motors Using Stator Current Signature Analysis". Em: *IEEE Transactions on Industrial Electronics*, v. 61, n. 4, pp. 2041–2052, Junho 2013.