

# Avaliação do Desempenho dos Filtros Discriminativos em um Sistema de Detecção de Pontos Fiduciais

Kenny Vinente dos Santos, Luiz Eduardo Sales e Silva, Waldir Sabino da Silva Júnior

**Resumo**—A filtragem discriminativa é uma técnica de reconhecimento de padrões que procura maximizar a energia do sinal de saída quando um padrão é encontrado. Visando melhorar o desempenho da resposta do filtro, incorporou-se a análise de componentes principais no projeto dos filtros discriminativos. Neste trabalho procuramos investigar a influência da quantidade de componentes principais no desempenho do filtro e consequentemente do classificador aplicado a detecção de pontos fiduciais. Nós mostramos que a quantidade de componentes principais afeta diretamente o desempenho do classificador, tanto em relação a taxa de acerto quanto a taxa de falsos positivos.

**Palavras-Chave**—Reconhecimento de Padrões, Filtragem Discriminativa, Análise de Componentes Principais, Detecção de Pontos Fiduciais.

**Abstract**—Discriminative filtering is a pattern recognition technique which aim maximize the energy of output signal when a pattern is found. Looking improve the performance of filter response, was incorporated the principal component analysis in discriminative filters project. In this work we looking investigate the influence of the amount of principal components in the filter performance and by consequence the classifier applied in fiducial points detection. We showed those amount of principal components affects directly the classifier's performance, both in the true and false positives rate.

**Keywords**—Pattern Recognition, Discriminative Filtering, Principal Component Analysis, Fiducial Points Detection.

## I. INTRODUÇÃO

Nos últimos anos, observou-se um crescimento no interesse da comunidade científica em estudar métodos que proporcionam a detecção/reconhecimento de objetos. Um dos motivos está relacionado com a possibilidade de se aplicar as técnicas pesquisadas para solucionar problemas multidisciplinares. Sendo assim, encontramos na literatura diversas aplicações que utilizam sistemas para detecção/reconhecimento dos mais variados objetos, por exemplo: sistemas para detecção de pontos fiduciais [1], [2], reconhecimento de faces [3], [4] e localização de falhas em linhas de transmissão [5].

K. V dos Santos e L. E. Sales e Silva são mestrandos do Programa de Pós-graduação em Engenharia Elétrica e pesquisadores do Centro de Pesquisa e Desenvolvimento em Tecnologia Eletrônica e da Informação, PPGEE e CETELI, Universidade Federal do Amazonas, UFAM, Av. Gen. Rodrigo Octávio Jordão Ramos, 3000, Manaus - AM, 69077-000, Brasil. (e-mail: kennyvinente@gmail.com; luiz.edu.sales@gmail.com). Este trabalho foi financiado pela Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM) e pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

W. S. da Silva Júnior é professor do Departamento de Eletrônica e Computação, Programa de Pós-graduação em Engenharia Elétrica e pesquisador do Centro de Pesquisa e Desenvolvimento em Tecnologia Eletrônica e da Informação, DTEC, PPGEE e CETELI, Universidade Federal do Amazonas, UFAM, Av. Gen. Rodrigo Octávio Jordão Ramos, 3000, Manaus - AM, 69077-000, Brasil. (e-mail: waldirjr@ufam.edu.br).

A detecção de pontos fiduciais é um problema de interesse da comunidade científica. Uma aplicação de destaque consiste na detecção de pontos fiduciais (pontos salientes) em faces humanas. Atualmente, existem diversas abordagens que procuram resolver este problema, como os sistemas que utilizam *Active Appearance Models* [6], cascata de classificadores *Adaboost* [7], *Template Matching* [8], filtros de correlação [2] e o método estado-da-arte *Support Vector Machines* (SVM) [9]. Cada uma destas abordagens procura resolver o problema da detecção de pontos fiduciais. Em geral, os métodos pesquisados costumam utilizar elevados recursos computacionais, o que dificulta a implementação em aplicações com restrições computacionais.

Recentemente [10], [11], surgiram métodos que utilizam filtragem linear para detecção de pontos fiduciais. Nestes métodos, podemos utilizar técnicas consolidadas de Processamento Digital de Sinais para melhorar o desempenho de detecção. Em [1], os autores apresentam um filtro robusto, denominado por filtro discriminativo, para detecção de pontos fiduciais. Neste trabalho, os filtros discriminativos são projetados utilizando a consolidada teoria de Análise de Componentes Principais [12]. Nessa abordagem, os filtros são projetados para detectar as componentes principais de maior variância associadas aos padrões de interesse. Uma das vantagens em se utilizar esta abordagem é que pequenas mudanças nos padrões de interesse não impactam significativamente a forma das componentes principais de maior variância. Dessa forma, os filtros possuem robustez à pequenas variações que podem estar contidas nos padrões de interesse. A determinação correta da quantidade de componentes principais é crucial para o desempenho adequado dos filtros discriminativos. Um aspecto não explorado na literatura consiste em avaliar a influência da quantidade de componentes principais na detecção individual de cada ponto fiducial.

Neste trabalho, propomos investigar a influência da quantidade de componentes principais no projeto dos filtros discriminativos de um sistema de detecção de pontos fiduciais. O objetivo principal é verificar o desempenho do classificador projetado a partir da filtragem discriminativa utilizando componentes principais e sua relação com o número de componentes. O procedimento experimental será realizado utilizando 11 pontos fiduciais de um subconjunto de 503 imagens da base de dados *BioID* [17]. Os resultados obtidos comprovam a eficácia do método proposto.

Este artigo está organizado da seguinte forma: na Seção II, realizamos uma revisão dos conceitos associados a filtragem discriminativa com análise de componentes principais. Na Seção III, apresentamos a proposta deste trabalho composta pelo sistema de detecção de pontos fiduciais, a influência da quantidade de componentes e os experimentos e resultados.

Por fim, as conclusões são discutidas na Seção IV.

## II. FILTRAGEM DISCRIMINATIVA

### A. Filtragem Discriminativa

O método por Filtragem Discriminativa [8] surgiu na década de 90, tendo como primeira aplicação a detecção de quinas em imagens. Nesta técnica, o objetivo é projetar um filtro linear ótimo  $\Theta$  que detecte um padrão de interesse  $\mathbf{U}$  presente em um sinal de avaliação  $\mathbf{G}$ . Para encontrar esse padrão, geramos um sinal  $\mathbf{C}$  que é resultado da convolução circular entre  $\Theta$  e  $\mathbf{G}$ . Se o sinal convoluído  $\mathbf{G}$  é constituído pelo padrão de interesse, então  $\mathbf{C}$  será um impulso localizado nas coordenadas em que o padrão ocorre. Uma característica importante deste método reside no fato de utilizar filtragem de sinais para detecção. A métrica utilizada para avaliar o sinal  $\mathbf{C}$  é a  $\text{DSNR}_2$  (*Two-Dimensional Discriminative Signal to Noise Ratio*). Matematicamente, a  $\text{DSNR}_2$  é expressa por:

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

Observando a Equação (1) podemos concluir que se o sinal  $\mathbf{C}$  for um impulso, a  $\text{DSNR}_2$  é infinita na localização do impulso, e zero nas outras posições. Dessa forma, podemos apresentar o problema da Filtragem Discriminativa da seguinte maneira: precisamos encontrar um detector  $\Theta$  que ao ser convoluído com um padrão de interesse  $\mathbf{U}$  resulte em um sinal  $\mathbf{C}$  que possui  $\text{DSNR}_2$  maximizada na posição  $(m_0, n_0)$ . Em [11], os autores encontram uma formulação fechada para este problema através da abordagem por Restauração do Impulso que pode ser obtida da seguinte maneira: seja uma matriz  $g(m, n)$  que contém o padrão de interesse  $u(m - m_0, n - n_0)$  localizado na posição  $(m_0, n_0)$ , além de outros sinais que podem ser interpretados como ruído aditivo  $b(m, n)$ . Desta forma, temos:

$$g(m, n) = u(m, n) * \delta(m - m_0, n - n_0) + b(m, n) \quad (2)$$

Desenvolvendo a Equação (2) e utilizando a notação matricial para a convolução circular, geramos a formulação do problema da restauração do impulso da seguinte maneira: dado o sinal  $\mathbf{g}$  e uma matriz  $\mathbf{F}$ , com dimensões  $N \times N$ , que é formada por deslocamentos circulantes por blocos do padrão de interesse  $\mathbf{U}$ , devemos encontrar a melhor estimativa linear do vetor  $\hat{\mathbf{d}} = \mathbf{A}\mathbf{g}$  que irá determinar a posição do padrão, levando em consideração que não se conhece a priori o ruído  $\mathbf{b}$ . Considerando o caso em que o ruído  $\mathbf{b}$  é gaussiano, com média zero e matriz de covariância igual a  $\frac{1}{N}\mathbf{C}_b$  com dimensões  $N \times N$ , o vetor  $\hat{\mathbf{d}}$  é expresso por:

$$\hat{\mathbf{d}} = \mathbf{F}^H [\mathbf{F}\mathbf{F}^H + \mathbf{C}_b]^{-1} \mathbf{g} \quad (3)$$

onde o super-escrito  $^H$  é o Hermitiano. O filtro discriminativo  $\Theta$  pode ser obtido por uma inspeção no estimador linear  $\mathbf{A}$  [11].

### B. Filtragem Discriminativa com Análise de Componentes Principais

Em [1], os autores sugeriram o projeto de filtros discriminativos robustos. Nesta abordagem, os filtros discriminativos

são projetados utilizando-se as componentes principais [12] do conjunto de matrizes formado por ocorrências do padrão de interesse. Matematicamente, podemos obter os filtros discriminativos da seguinte maneira: suponha uma variável aleatória  $\mathbf{U}_{N \times 1}$  com  $M$  realizações iguais aos vetores  $\mathbf{u}_1, \dots, \mathbf{u}_M$ . Cada vetor é obtido concatenando-se as colunas do bloco. As componentes principais  $\Phi = [\phi_1, \dots, \phi_N]$  e seus autovalores  $\lambda_1, \dots, \lambda_N$  podem ser obtidos utilizando a solução do problema de autovalores [12] descrito a seguir:

$$\Lambda = \Phi^H \Sigma_{\mathbf{U}} \Phi,$$

onde  $\Sigma_{\mathbf{U}}$  a matriz de covariância de  $\mathbf{U}$ .

Os filtros discriminativos bidimensionais  $\Theta_{\phi_1}, \dots, \Theta_{\phi_S}$  serão projetados para  $S$  componentes principais  $\phi_1, \dots, \phi_S$  com autovalores associados iguais à  $\lambda_1, \dots, \lambda_S$ , segundo a Equação (3). Assim, a equação do estimador é dada por:

$$\mathbf{A}_{\phi_i} = \mathbf{F}_{\phi_i}^H [\mathbf{F}_{\phi_i} \mathbf{F}_{\phi_i}^H + \mathbf{C}_{b_i}]^{-1}. \quad (4)$$

Por fim, os autores interpretam que  $\mathbf{C}_{b_i}$  pode ser obtido pelo subespaço ortogonal à componente principal de interesse. Assim, a matriz de covariância  $\mathbf{C}_{b_i}$  associada a componente de interesse  $\phi_i$  poderá ser escrita como:

$$\mathbf{C}_{b_i} = \sum_{\substack{j=1 \\ j \neq i}}^N \psi_j \mathbf{F}_{\phi_j} \mathbf{F}_{\phi_j}^H, \quad (5)$$

onde  $\psi_j$  são constantes que indicam a estatística do ruído, e  $\mathbf{F}_{\phi_j}$  é a matriz circulante por blocos obtida a partir da componente  $\phi_j$ .

## III. AVALIAÇÃO DO DESEMPENHO DOS FILTROS DISCRIMINATIVOS UTILIZANDO COMPONENTES PRINCIPAIS EM UM SISTEMA DE DETECÇÃO DE PONTOS FIDUCIAIS

### A. Sistema de Detecção de Pontos Fiduciais de Faces Humanas

A avaliação de desempenho dos filtros discriminativos robustos foi realizada utilizando um sistema supervisionado de detecção de pontos fiduciais das faces humanas. O sistema possui uma etapa de treinamento e outra de teste (observar as Figuras 1 e 2). Em ambas, utilizamos um bloco para pré-processamento das imagens, conforme [1], que é formado por três partes: primeiramente, realizamos um enquadramento da face da imagem de entrada utilizando um detector de faces humanas *Viola-Jones* [13]. A seguir fazemos um escalonamento da imagem para uma resolução igual a  $220 \times 220$  e realizamos a correção de iluminação [14]. Por último selecionamos a região elíptica de interesse utilizando um *Modelo Gaussiano à Priori*.

A etapa de treinamento (Figura 1) pode ser descrita como segue: primeiramente, realizamos o pré-processamento da imagem. A seguir, os  $S$  filtros discriminativos  $\Theta_{\phi_i}$  serão projetados para cada uma das componentes principais. Através de uma janela deslizante, cada bloco  $B_z$ , pertence à região elíptica de interesse, é filtrado por todos os  $S$  filtros  $\Theta_{\phi_i}$  gerando  $S$  matrizes  $C_{\phi_i}(B_z)$ . Utilizando a Equação (1) obtemos os valores de  $\text{DSNR}_2$  das matrizes  $C_{\phi_i}(B_z)$ . Assim, cada bloco  $B_z$  terá um vetor  $\text{DSNR}_2$  associado denominado  $\mathbf{d}_{B_z}$  com dimensões  $1 \times S$ . Os vetores  $\mathbf{d}_{B_z}$  serão utilizados para

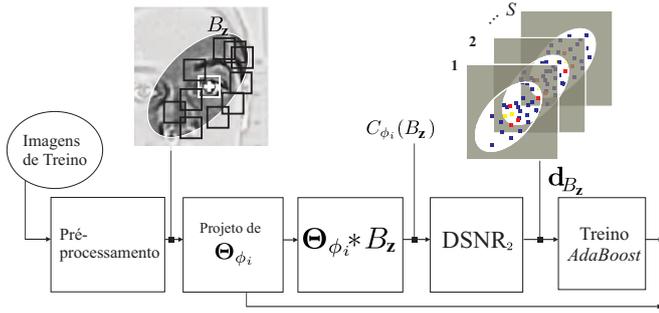


Fig. 1. Diagrama em blocos para treinamento do sistema de detecção de pontos fiduciais.

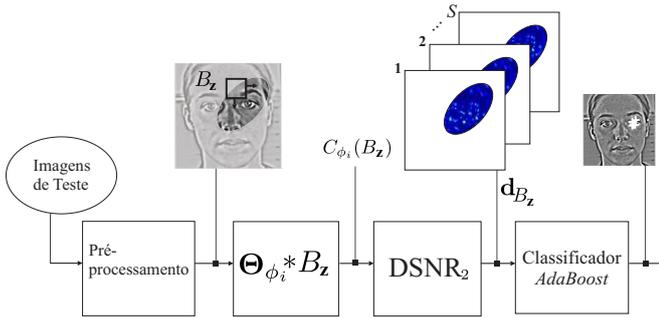


Fig. 2. Diagrama em blocos para teste do sistema de detecção de pontos fiduciais.

treinamento do classificador *AdaBoost* utilizando a *toolbox* GML *AdaBoost* [18]. A saída do diagrama de treinamento consiste nos filtros  $\Theta_{\phi_i}$ , o classificador *AdaBoost* e o bloco médio dos padrões de interesse, denominado por  $\mu_U$ .

A etapa de teste, apresentada no diagrama em blocos da Figura 2, pode ser descrita da seguinte maneira: primeiramente, a imagem é pré-processada. A seguir, utilizando uma janela deslizante, processamos cada bloco  $B_z$ . As matrizes  $C_{\phi_i}(B_z)$  são obtidas através da filtragem entre  $B_z$ , subtraído por  $\mu_U$  (bloco médio dos padrões de interesse, determinado no treinamento), com cada um dos  $S$  filtros  $\Theta_{\phi_i}$  (obtidos no treinamento). Após, calculamos a  $DSNR_2$  para cada  $C_{\phi_i}(B_z)$  resultando em um vetor  $DSNR_2$  associado denominado  $d_{B_z}$ . O classificador *AdaBoost* irá categorizar  $d_{B_z}$  como positivo (o centro de  $B_z$  é ponto fiducial) ou negativo (o centro de  $B_z$  não é ponto fiducial).

### B. Influência da Quantidade de Componentes Principais no Projeto dos Filtros Discriminativos

Conforme comentado, o sucesso do projeto dos filtros discriminativos robustos depende intrinsecamente da quantidade de componentes principais. Na Seção II-B, verificamos que os filtros discriminativos  $\Theta_{\phi_1}, \dots, \Theta_{\phi_S}$  são projetados para  $S$  componentes principais  $\phi_1, \dots, \phi_S$  com autovalores associados iguais à  $\lambda_1, \dots, \lambda_S$ . A componente de maior energia  $\phi_1$  certamente terá um filtro  $\Theta_{\phi_1}$ , porém não é trivial encontrarmos o conjunto de  $S$  filtros discriminativos que possua um desempenho satisfatório. Vale salientar que, para cada padrão de interesse, é provável que o total de filtros discriminativos seja modificado. Por exemplo, caso os padrões de interesse sejam iguais aos pontos fiduciais da face humana, então, para

cada ponto fiducial, é provável que o desempenho em termos de detecção seja influenciado diretamente pelo total de filtros discriminativos utilizados no projeto.

Assim, é necessário encontrarmos um número satisfatório de componentes principais para que se possa projetar um conjunto de filtros discriminativos que sejam eficientes quando utilizados em um sistema de detecção de pontos fiduciais. Para atingirmos esse objetivo, utilizamos o seguinte procedimento experimental: primeiramente, determinamos a quantidade  $S$  de componentes principais que serão utilizadas no sistema de detecção de pontos fiduciais descrito na Seção III-A. A quantidade  $S$  de componentes principais variou discretamente obedecendo a seguinte formação:  $S = [8, 13, 23, 33, 43, 53, 63, 73, 83, 93, 100]$ . Todos os blocos das etapas de treinamento e de teste do sistema descrito na Seção III-A foram implementados e o desempenho do sistema foi avaliado para cada um dos valores  $S$  de um conjunto de pontos fiduciais da face humana.

### C. Experimentos e Resultados

Para validar a influência da quantidade de componentes principais no projeto dos filtros discriminativos, utilizamos um total de 11 pontos fiduciais num conjunto de 503 imagens da base de dados BioID [17]. Os pontos fiduciais e sua numeração estão apresentados na Figura 3. Em todos os experimentos, utilizamos validação cruzada com 7 partições (valor comumente encontrado na literatura [16]), ou seja, em cada experimento temos dois conjuntos diferentes para treino e para teste. No conjunto de treinamento utilizamos 6/7 do total de imagens da base de dados para treinamento e verificação de parâmetros e no conjunto de teste utilizamos 1/7 do total de imagens para validar o desempenho do sistema de detecção de pontos fiduciais.

O desempenho do sistema é medido utilizando-se a distância entre as pupilas. Esta distância, denominada  $\tilde{d}_o$ , é obtida da seguinte maneira:

$$\tilde{d}_o = \|\widetilde{\mathbf{OE}} - \widetilde{\mathbf{OD}}\|,$$

onde:  $\widetilde{\mathbf{OE}}$  corresponde às coordenadas do rótulo manual da pupila esquerda e  $\widetilde{\mathbf{OD}}$  são as coordenadas do rótulo manual da pupila direita. Supondo um candidato  $\mathbf{x}$  e as coordenadas manuais do ponto fiducial (PF) igual a  $\widetilde{\mathbf{PF}}$ , então define-se  $d_{PF}$  como:

$$d_{PF} = \|\mathbf{x} - \widetilde{\mathbf{PF}}\|$$

O desempenho do classificador é medido através das taxas de Verdadeiros Positivos (TP) e Falsos Positivos (FP) conforme as expressões:

$$TP = 100 \frac{\text{Total de faces em que } d_{PF} \leq 0,1 \tilde{d}_o}{\text{Total de faces}}, \quad (6)$$

$$FP = 100 \frac{\text{Total de candidatos a PF com } d_{PF} > 0,1 \tilde{d}_o}{\text{Total de negativos}}. \quad (7)$$

Os resultados obtidos para alguns pontos fiduciais podem ser visualizados nas Figuras de 4 à 9. Cada gráfico possui duas curvas. A curva em azul representa a taxa de Verdadeiros Positivos (TP) em função da quantidade de componentes principais. A escala do gráfico está do lado esquerdo do gráfico na cor azul. A curva em vermelho representa a taxa de Falsos Positivos (FP) em função da quantidade de componentes

principais. Sua escala está do lado direito do gráfico na cor vermelho. Em ambas as curvas apresentamos o desvio padrão obtido. Devido a simetria da face, apresentamos somente as curvas referentes aos pontos fiduciais que estão do lado esquerdo da face. Os melhores resultados do método proposto e também dos métodos estado-da-arte SVM linear e SVM polinomial [1] estão apresentados na Tabela I.

Em relação aos gráficos apresentados nas Figuras 4 à 9, podemos observar pelos resultados obtidos que a quantidade de componentes principais influencia diretamente no classificador projetado. Em todos os experimentos realizados, quando utilizamos um número baixo de componentes, obtemos elevadas taxas de falsos positivos e para um número elevado de componentes, obtemos boas taxas em relação aos verdadeiros e falsos positivos com bons valores de desvio padrão. Isto enfatiza que o desempenho do classificador projetado depende de forma acentuada da quantidade de componentes principais utilizadas. Em relação a Tabela I, podemos observar uma comparação direta entre os resultados da pesquisa proposta em relação aos dos métodos SVM linear e SVM polinomial. Podemos observar que o método SVM polinomial obtém excelentes resultados, porém o método proposto possui os melhores resultados para o ponto fiducial 2. O método proposto supera o desempenho do SVM linear para os pontos fiduciais 0, 2, 4 e 7. Resumidamente, podemos salientar que os resultados do método proposto são promissores em frente aos de métodos estado-da-arte.

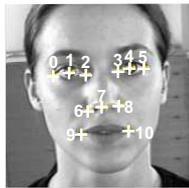


Fig. 3. Pontos Fiduciais utilizados neste trabalho

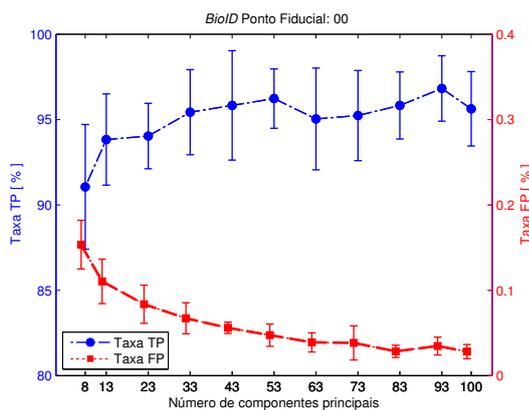


Fig. 4. Resultados obtidos para o ponto fiducial 0

#### IV. CONCLUSÕES

Neste trabalho investigamos a influência da quantidade de componentes principais e o desempenho do classificador projetado em sistemas de Reconhecimento de Padrões que utilizam filtros discriminativos com análise de componentes principais.

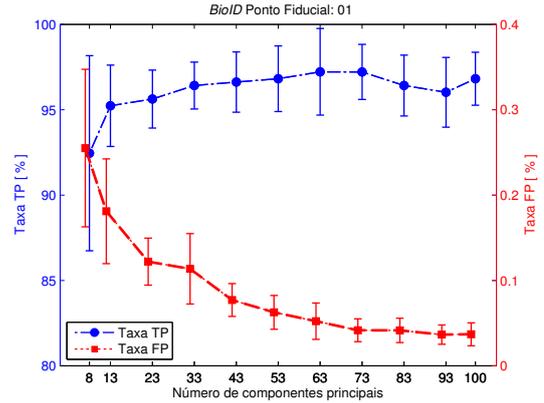


Fig. 5. Resultados obtidos para o ponto fiducial 1

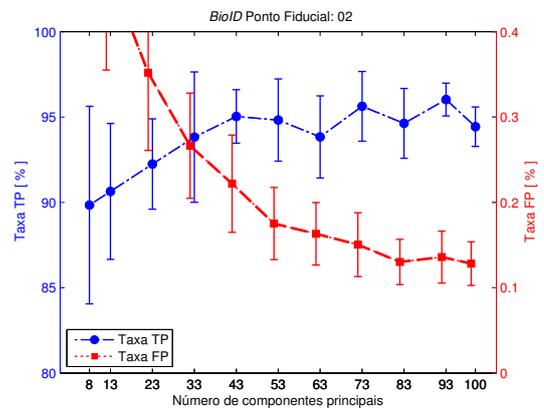


Fig. 6. Resultados obtidos para o ponto fiducial 2

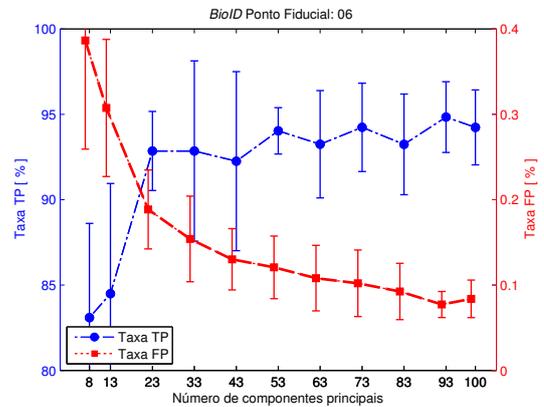


Fig. 7. Resultados obtidos para o ponto fiducial 6

Realizamos os experimentos na base de dados *BioID*, utilizando validação cruzada e dividindo o total de imagens em dois segmentos: imagens de treino (6/7 do total) e imagens de teste (1/7 do total). Neste experimento, variamos a quantidade de componentes principais de maneira discreta e estudamos a influência do número de componentes no desempenho do classificador, tanto em relação a taxa de verdadeiros positivos como a de falsos positivos. Os resultados evidenciaram que a quantidade de componentes principais utilizadas determinam o desempenho do classificador, sendo que um número baixo de componentes gera classificadores insatisfatórios. Observamos

TABELA I  
PRINCIPAIS RESULTADOS OBTIDOS PARA OS 11 PONTOS FIDUCIAIS DA BASE DE DADOS BIOID

| Ponto Fiducial | FD-PCA (proposto) |          |      |          |     | SVM-L |          |      |          | SVM-P |          |      |          |
|----------------|-------------------|----------|------|----------|-----|-------|----------|------|----------|-------|----------|------|----------|
|                | TP                | $\sigma$ | FP   | $\sigma$ | NC  | TP    | $\sigma$ | FP   | $\sigma$ | TP    | $\sigma$ | FP   | $\sigma$ |
| 0              | 95,8              | 1,96     | 0,03 | 0,01     | 83  | 92,4  | 9,8      | 1,09 | 0,74     | 99,6  | 0,7      | 0,39 | 0,07     |
| 1              | 97,2              | 1,61     | 0,04 | 0,01     | 73  | 99,6  | 1,0      | 0,32 | 0,09     | 98,8  | 1,2      | 0,04 | 0,02     |
| 2              | 96,0              | 0,96     | 0,13 | 0,03     | 93  | 93,0  | 14,3     | 1,58 | 0,59     | 94,2  | 2,7      | 0,15 | 0,03     |
| 3              | 93,4              | 2,51     | 0,15 | 0,02     | 100 | 96,0  | 1,7      | 0,46 | 0,21     | 99,8  | 0,5      | 0,33 | 0,09     |
| 4              | 98,1              | 2,87     | 0,04 | 0,01     | 100 | 97,2  | 4,2      | 2,49 | 4,76     | 98,8  | 1,5      | 0,08 | 0,05     |
| 5              | 96,6              | 2,09     | 0,03 | 0,01     | 100 | 98,8  | 3,1      | 2,27 | 0,62     | 99,6  | 0,7      | 0,42 | 0,09     |
| 6              | 94,8              | 2,07     | 0,08 | 0,01     | 93  | 99,6  | 1,0      | 1,40 | 1,44     | 99,6  | 0,7      | 0,31 | 0,05     |
| 7              | 94,2              | 2,17     | 0,08 | 0,02     | 93  | 47,1  | 9,6      | 0,06 | 0,03     | 99,6  | 0,7      | 0,60 | 0,05     |
| 8              | 94,2              | 1,68     | 0,09 | 0,01     | 93  | 95,4  | 3,9      | 0,40 | 0,09     | 99,0  | 1,1      | 0,24 | 0,03     |
| 9              | 88,8              | 2,92     | 0,13 | 0,02     | 83  | 96,8  | 5,5      | 2,91 | 5,12     | 98,8  | 1,7      | 0,39 | 0,06     |
| 10             | 86,4              | 4,68     | 0,07 | 0,03     | 83  | 98,6  | 1,9      | 1,47 | 0,49     | 99,6  | 0,7      | 0,35 | 0,04     |

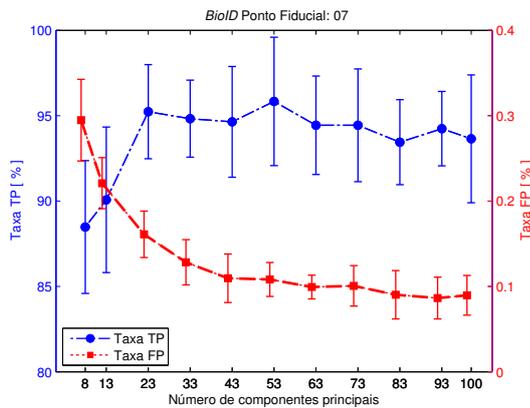


Fig. 8. Resultados obtidos para o ponto fiducial 7

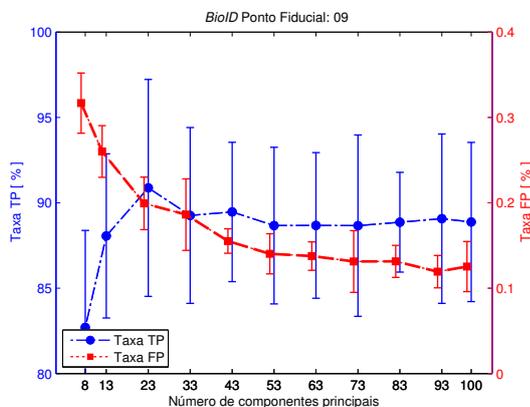


Fig. 9. Resultados obtidos para o ponto fiducial 9

ainda que a partir de 43 componentes principais temos classificadores com bom desempenho. Percebemos que embora o método proposto possua um desempenho pouco inferior aos métodos SVM em relação a taxa de verdadeiros positivos, o sistema proposto é superior aos métodos que utilizam SVM em relação a taxa de falsos positivos. E finalmente, percebemos que para a grande maioria dos pontos fiduciais utilizados, a partir de 73 componentes a taxa de falsos positivos estabiliza.

#### AGRADECIMENTOS

Agradecemos à Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM) e a Coordenação de

Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro.

#### REFERÊNCIAS

- [1] W. S. S. Junior, G. M. Araujo, E. A. B. Silva and S. K. Goldenstein, "Facial Fiducial Points Detection Using Discriminative Filtering on Principal Components". In: *Proceedings of the International Conference on Image Processing*, September, pp. 2681-2684, 2010.
- [2] G. M. Araujo, W. S. S. Junior, E. A. B. Silva and S. K. Goldenstein, "Facial Landmark Detection Based on Correlation Filters". In: *Proceedings of the International Telecommunications Symposium*, 2010.
- [3] G. Guo, S. Z. Li and K. Chan, "Face Recognition by Support Vector Machines". In: *Proceedings of the International Conference on Automatic Face and Gesture Recognition*, September, pp. 196-201, 2000.
- [4] P. Campadelli, R. Lanzarotti and G. Lipori, Automatic Facial Feature Extraction for Face Recognition. In: *Face Recognition*. Vienna, Austria: I-Tech Education and Publishing, 2007. p. 31-58.
- [5] Y. Zhang, Y. Liu, X. Wang and Z. Wang, "Fault Pattern Recognition in Power System Engineering", In: *International Conference on Industrial Mechatronics and Automation*, pp. 109-112, 2009.
- [6] T. Cootes, G. J. Edwards and C. J. Taylor, "Active Appearance Models". In: in *Proceedings of the European Conference on Computer Vision*, vol. 2, pp. 484-498, 1998.
- [7] F. Jerome, H. Trevor and R. Tibshirani, "Additive Logistic Regression: A Statistical View of Boosting", In: *Annals of Statistics*, vol. 28, pp. 2000, 1998.
- [8] J. Ben-Arie and K. R. Rao, "A Novel Approach for Template Matching by Nonorthogonal Image Expansion". *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 3, no. 1, pp.71-84, 1993.
- [9] G. M. Araujo, W. S. S. Junior, E. A. B. Silva and S. K. Goldenstein, "Detecção de Landmarks Faciais Usando SVM" In: *Simpósio Brasileiro de Telecomunicações*, 2011.
- [10] A. P. Mendonça, E. A. B. Silva, "Two-Dimensional Discriminative Filters for Image Template Detection" In: *Proceedings of the International Conference on Image Processing*, pp. 680-683, 2001.
- [11] A. P. Mendonça, E. A. B. Silva, "Closed-Form Solutions for Discriminative Filtering using Impulse Restoration Techniques", *IEE Electronics Letters*, vol. 38, n. 22, pp. 1332-1333, 2002
- [12] M. Kirby and L. Sirovich, "Application of the Karhunen-Loève Procedure for the Characterization of Human Faces", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 12, 1990.
- [13] P. Viola and M. Jones, "Robust real-time object detection", *International Journal of Computer Vision*, vol. 57, no. 2, pp. 137-154, 2001.
- [14] Xiaoyang, T. and Triggs, B., Enhanced Local Texture Feature Sets for Face Recognition Under Difficult Lighting Conditions. *IEEE Transactions on Image Processing*, vol. 19, n. 6, pp. 1635-1650, 2010
- [15] D. Nandy and J. Ben-Arie, "EXM Eigen Templates for Detecting and Classifying Arbitrary Junctions" In: *Proceedings of International Conference on Image Processing*, pp.211-215, 1998.
- [16] R. Kohavi, "A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection" In: *Proceedings of the International Joint Conference on Artificial Intelligence*, pp.1137-1143, Montreal, Canada, 1996.
- [17] "BioId Database", [Último acesso em Maio de 2013]. [Online]. Disponível em: <http://www.bioid.com/>
- [18] "The GML AdaBoost Matlab Toolbox", [Último acesso em Maio de 2013]. [Online]. Disponível em: <http://graphics.cs.msu.ru/en/science/research/machinelearning/adaboosttoolbox> .