



ISSN: 1984-3151

ANÁLISE ESTATÍSTICA NO RECONHECIMENTO AUTOMÁTICO DE FACES UTILIZANDO PCA EIGENFACES

STATISTICAL ANALYSIS IN AUTOMATIC FACE RECOGNITION USING PCA EIGENFACES

Hudson Rodrigues Saldanha de Oliveira¹; Lucas Braga de Assis²;
Eduardo Queiroz Braga³

- 1 Bacharel em Engenharia Elétrica. UniBH. 2012. Belo Horizonte, MG. Precon Industrial. ifhrso@yahoo.com.br.
- 2 Bacharel em Engenharia Elétrica. UniBH. 2012. Belo Horizonte, MG. Almaviva do Brasil. lucasbassis@yahoo.com.br.
- 3 Mestre em Engenharia Elétrica. UFMG, 2007. Professor do Centro Universitário de Belo Horizonte - UniBH. Belo Horizonte, MG. eduardo.braga@prof.unibh.br.

Recebido em: 19/10/2012 - Aprovado em: 20/11/2012 - Disponibilizado em: 30/11/2012

RESUMO: Este artigo tem como objetivo a análise da ferramenta estatística denominada Análise de Componentes Principais, ACP utilizando Eigenfaces, no que se refere à reconstrução e reconhecimento de faces a partir de imagens estáticas propondo diferentes metodologias de classificação de faces.

PALAVRAS-CHAVE: PCA. Eigenfaces. Reconhecimento de faces.

ABSTRACT: This article aims to analyze the statistical tool called Principal Component Analysis, PCA using Eigenfaces, with regard to reconstruction and face recognition from still images by proposing different methods for classifying faces.

KEYWORDS: PCA. Eigenfaces. Recognition of faces.

1 INTRODUÇÃO

É fato que esta é a *Era da Tecnologia da Informação*, era em que são adotados recursos da computação para prover serviços, considerando como objetivo soluções otimizadas. O objeto deste trabalho é o reconhecimento automático de face utilizando ACP (Análise de Componentes Principais). O emprego desta técnica para o reconhecimento de face é denominada como *Eigenface*, metodologia

desenvolvida por Sirovich e Kirby (1987), e aprimorada por Turk e Pentland (1991).

O reconhecimento de faces por humanos se dá de forma natural e instantânea, quando realizada a captação da imagem pelos olhos, e esta imagem segue memorizada pelo indivíduo, e por fim o reconhecimento. Transferir esta mesma habilidade, para um sistema computacional é uma tarefa complexa, exige esforço computacional no processamento da imagem, dado as diversas

variações pertinentes de uma face e, além disto, o sistema é acompanhado com uma série de limitações. O trabalho de reconhecer uma face implica em fatores, que contemplam aspectos como a iluminação ambiente, pose do indivíduo, qualidade da imagem, dentre outros.

Os sistemas de reconhecimento facial apresentam vasta aplicabilidade, com destaque em sistemas de segurança. Esses sistemas são utilizados para identificar criminosos, monitorar pessoas pela rua e chave de acesso para sistemas e locais, podendo ser utilizado, por exemplo, no acesso ao caixa eletrônico de bancos financeiros, e em diversos sistemas de interface homem-máquina. Esses sistemas desempenham, portanto, um importante papel na segurança da informação, bens e pessoas.

Dependendo do método utilizado para identificação pode ser necessário a localização de certos pontos da face, como por exemplo: olhos, nariz, boca e sobranalha, contudo, neste trabalho é apresentado um sistema de reconhecimento facial baseado na Análise de Componentes Principais, que realiza uma análise estatística da imagem de face. Portanto, não leva em consideração a segmentação de elementos físicos da face humana e, sim, a variância do vetor de pontos (pixels) desta imagem em relação à um conjunto de treino.

Este trabalho tem por finalidade explorar a validade do método supracitado, implementando um algoritmo em Matlab.

2 ANÁLISE DE COMPONENTES PRINCIPAIS

Segundo A. Santos (2005), o método de ACP tem por objetivo principal o processamento de dados a fim de reduzi-los ou eliminar possíveis redundância de informação. Outra característica deste método consiste na representação do conjunto de dados através de combinações lineares de suas variáveis que melhor o representam. Portanto o ACP pode ser

aplicado a diversos problemas cujas variáveis estão correlacionadas entre si e não apenas para o reconhecimento facial, objetivo deste trabalho.

De acordo com Santos (2005), aplicado ao reconhecimento de faces, o ACP mostra-se bastante propício. Sua ideia central de reduzir a dimensionalidade do conjunto de dados, que possui como característica principal um grande número de variáveis correlacionadas.

O referido método, que também é conhecido como Transformada discreta de Karhunen-Loève (KLT), ou ainda Transformada de Hotelling, envolve uma base de Álgebra Linear e Estatística, que será discutida neste trabalho, a fim de se obter o nivelamento dos pesquisadores e a conceituação de alguns pontos importantes do método.

Para a aplicação do ACP são necessárias ferramentas da Álgebra Linear como autovetores e autovalores que serão descritos nesta seção.

2.1 AUTOVETORES E AUTOVALORES

Segundo Santos (2010), autovalores e autovetores correspondem às matrizes de transformação que decompõem uma matriz \mathbf{A} em outras duas, onde a primeira é diagonal e cada elemento desta diagonal representa um autovalor associado a um autovetor da segunda matriz que são Linearmente Independentes entre si e, portanto descorrelacionados.

Segundo o mesmo autor, para se encontrar estas matrizes de transformação pode-se abordar a seguinte proposição:

Uma matriz $\mathbf{A}_{[n \times n]}$ é semelhante a uma matriz $\mathbf{D}_{[n \times n]}$ se existir uma matriz \mathbf{P} não singular, ou seja, invertível, tal que, a Eq. 1 se verifica.

$$\mathbf{A} = \mathbf{P}^{-1} \mathbf{D} \mathbf{P} \quad (1)$$

É denominado processo de diagonalização de matrizes o processo de encontrar as matrizes \mathbf{D} e \mathbf{P} que satisfaçam à Eq. 1. Onde será visto que estas matrizes representam os autovalores e autovetores que se pretendem encontrar.

De acordo com o mesmo autor, uma matriz é diagonalizável se ela é semelhante a uma matriz diagonal; e uma matriz quadrada é invertível se seu determinante é não nulo. Com isto pode-se chegar à conclusão de que para cada vetor $\mathbf{P}_i \in \mathbf{P}$ existe um escalar λ tal que:

$$\mathbf{A}\mathbf{P}_i = \sum_{j=1}^n d_{ji}\mathbf{P}_j = \lambda_i\mathbf{P}_i$$

$$\text{para } i = 1, \dots, n. \quad (2)$$

Pois, considera-se \mathbf{D} uma matriz diagonal e λ_i representa o i -ésimo autovalor referente ao i -ésimo autovetor de transformação da matriz \mathbf{A} .

E, segundo Santos (2010), para se calcular os autovetores e autovalores, apoiando-se nas definições de semelhança de uma matriz diagonal e de singularidade, tem-se que o Polinômio Característico da Eq. 3 resume o método para se encontrar os autovalores e conseqüentemente os autovetores da matriz \mathbf{A} .

$$p(\lambda) = \det(\mathbf{A} - \lambda\mathbf{I}) \quad (3)$$

Os autovetores que serão encontrados no método ACP serão relacionados às autofaces (*Eigenfaces*) e cada uma das autofaces extraídas de um conjunto de treino contribuirá para explicação (reconstrução) de uma face de entrada.

2.2 COVARIÂNCIA

De acordo com Spiegel (1993), muitas vezes, para se expressar uma relação entre variáveis por meio de

equações que as concatenam, medidas como covariância são largamente utilizadas.

No caso do método ACP, a covariância, ou mais precisamente, a matriz de covariância, é fundamental na obtenção das autofaces, pois como será visto a seguir, além de resumir os dados (*pixels*) em informações relevantes, ou seja, na variância conjunta entre cada pixel, ainda transforma a matriz dos dados de entrada em outra à qual está sujeita às propriedades da diagonalização de matrizes, descritas no item anterior e, conseqüentemente, à obtenção de autovetores (autofaces).

Segundo Spiegel (1993), a média de um conjunto de amostras pode ser expressa como:

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (4)$$

Onde μ representa a média e N é o número de amostras. Portanto, a variância, que é uma medida do espalhamento da distribuição ao redor da média, ou a esperança matemática do quadrado do desvio em relação à média, pode ser definida de acordo com a Eq. 5.

$$\sigma_x^2 = E\{(x_i - \mu)^2\} \quad (5)$$

Onde E representa a Esperança matemática definida em Spiegel (1993), σ_x^2 representa a variância, x_i o i -ésimo valor do conjunto de dados.

Já a covariância entre duas variáveis aleatórias, segundo Lima (2002), é definida por uma medida da relação linear entre duas variáveis, e que pode ser resumida na Eq. 6.

$$\sigma_{x,y} = E\{(x_i - \mu_x)(y_i - \mu_y)\} \quad (6)$$

Portanto, pode-se dizer que a covariância corresponde ao valor médio do produto dos desvios das variáveis X e Y, tomados em relação às suas respectivas médias.

De acordo com Spiegel (1993) e Lima (2002) se $\sigma_{x,y} > 0$ indica que as variáveis X e Y são diretamente proporcionais, se $\sigma_{x,y} < 0$, estas variáveis são inversamente proporcionais e caso $\sigma_{x,y} = 0$, X e Y são não correlacionadas.

De acordo com R. Santos (2010), a matriz de covariância, também conhecida como matriz de dispersão das variáveis aleatórias X_1, X_2, \dots, X_n , é simétrica, pois a covariância σ_{xy} é a mesma em σ_{yx} e, portanto é idêntica à sua transposta. Também, a diagonal principal desta matriz é composta pelas variâncias das variáveis. Esta matriz tem a forma apresentada na Eq. 7.

$$COV(X) = C = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1n} \\ \sigma_{21} & \sigma_2^2 & \dots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \dots & \sigma_n^2 \end{bmatrix} = C^T \quad (7)$$

2.3 CALCULANDO EIGENFACES

Uma imagem representada por uma matriz de pixels em tons de cinza com I linhas e C colunas pode ser representada por um vetor de $I \times C$ linhas e 1 coluna. E com este vetor imagem pode-se aplicar a ACP.

Baseado em Sirovich e Kirby (1987), Turk e Pentland (1991), o método para a obtenção da eigenface consiste no treinamento de uma base de dados que é apresentado em quatro etapas, e o reconhecimento de novas faces, que possui cinco etapas como descrito a seguir.

Inicialmente tem-se que escolher um banco de dados que servirá como conjunto de treino. Neste trabalho foi

utilizado como fonte o banco de dados *ORL Database* disponível na Internet, apresentado na Figura 1.

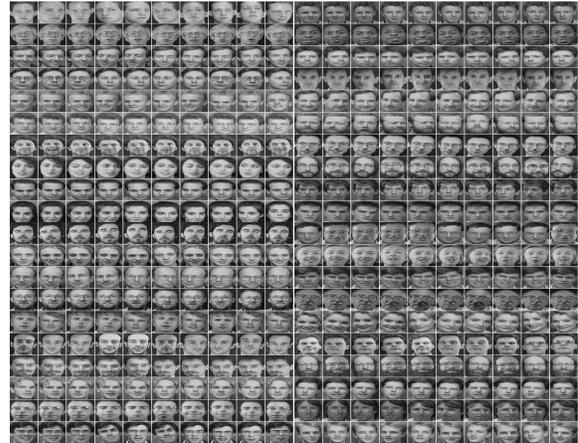


Figura 1 – Banco de dados de faces

Fonte – ORL Database, 2002.

No treinamento do banco de dados, inicialmente proposta por Sirovich e Kirby (1987), a primeira etapa consiste em extrair a matriz de covariância da matriz A e, a partir desta, calcular as *eigenfaces*. A matriz A representa o espaço das faces e cada uma de suas colunas representa uma face do conjunto de treino concatenada por linhas e dispostas em um vetor coluna. Para isto deve-se subtrair a média ψ , que é apresentada na Fig. 2, das faces originais Γ_i armazenando o resultado na variável Φ_i como apresentado na Eq. 8 e Eq. 9.

$$\psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \quad (8)$$

$$\Phi_i = \Gamma_i - \psi \quad (9)$$

Onde M representa o número de faces do conjunto de entrada. Então, pode-se calcular a matriz de covariância conforme a Eq. 10.

$$C = \frac{1}{M} \sum_{n=1}^M \phi_n \phi_n^T = A^T A \quad (10)$$

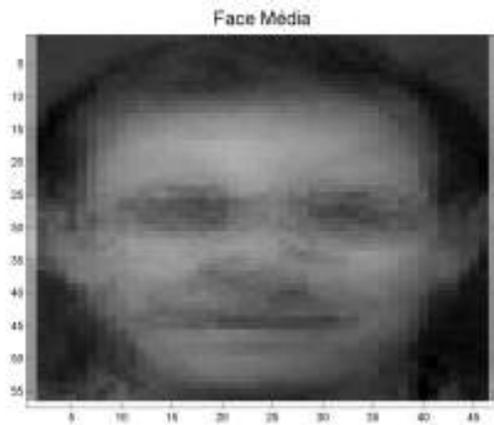


FIGURA 2 – Face média de um conjunto de treino com 120 faces.

A matriz C representa a matriz de covariância dos pixels de cada imagem em relação aos pixels de todas as outras imagens do conjunto de treino e, portanto possui tamanho $N^2 \times N^2$, onde N representa o número de pixels de cada imagem. Esta matriz é quadrada, simétrica e não negativa e, portanto, como visto na seção 2.2, é factível encontrar seus autovalores e autovetores.

Na segunda etapa, após calcular as *eigenfaces*, deve-se escolher de maneira estocástica os H maiores que correspondem aos H maiores autovalores podendo ser descartados os demais. O k -ésimo autovetor (*eigenface*) é escolhido como representado na Eq. 11.

$$\lambda_k = \frac{1}{M} \sum_{n=1}^M (\mu_k^T \cdot \phi_n)^2 \quad (11)$$

Onde λ_k é um máximo sujeito à seguinte restrição:

$$\mu_l^T \mu_k = \begin{cases} 1, & l = k \\ 0, & \text{caso contrário} \end{cases} \quad (12)$$

Felizmente estes *eigenfaces*, mostrados na Fig. 3, não são os mesmos dos extraídos da matriz de covariância C da Eq. 10. Os H *eigenfaces* encontrados a partir da matriz de covariância definem o subespaço de faces e caso pretenda se inserir uma nova face esse subespaço deve ser recalculado. A última *eigenface* pode ser suprimida, pois apresenta autovalor nulo.

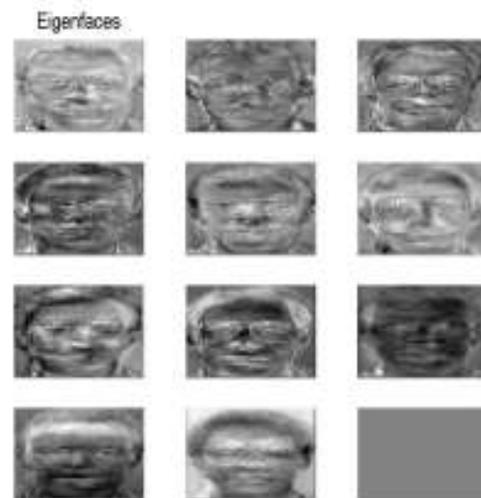


FIGURA 3 – ($H-1$) *Eigenfaces* de um conjunto de treino contendo 9 faces

A terceira etapa do método consiste no cálculo dos pesos de cada *eigenface* na reconstrução de cada face do conjunto de treino. Para isto deve-se projetar cada imagem deste conjunto no subespaço das faces. Cada face de entrada terá um vetor de peso de tamanho H .

A quarta e última etapa do treinamento consiste em armazenar as *eigenfaces* e os pesos de cada face do conjunto de treino para extração de novos vetores de peso e comparação (classificação), respectivamente.

Para que o sistema reconheça novas faces, na primeira das cinco etapas deve-se calcular o conjunto de pesos que representam a imagem de entrada no subespaço de faces projetando-a em cada um dos H autovetores.

Na segunda etapa deve-se determinar se a imagem é uma face observando se a sua projeção no subespaço de faces se aproxima dos pontos que representam as faces de treinamento.

Na terceira etapa tem-se um passo de decisão: se a imagem é uma face, classifique os seus padrões de pesos como uma face conhecida ou desconhecida de acordo com as faces de treinamento.

A quarta etapa consiste na atualização das autofaces e os pesos, sendo necessário para isto recalculer o subespaço de faces para um conjunto de treinamento com as novas faces inseridas.

Na última etapa de reconhecimento tem-se outro passo de decisão: se a mesma face desconhecida é apresentada várias vezes ao sistema, calcule os seus padrões de pesos e insira-os como face conhecida.

De acordo com Turk e Pentland (1991), as etapas IV e V são opcionais.

Turk e Pentland (1991) propõem uma melhoria no algoritmo, operando sobre a matriz de covariância a fim de reduzir custo computacional e, conseqüentemente, o tempo de processamento que será detalhado a seguir.

A matriz de Covariância C , da Eq. 10 possui dimensionalidade de $N^2 \times N^2$, de modo que se tem N^2 *eigenfaces* e autovalores. Computacionalmente, isto não é muito eficiente, pois a maior parte destes *eigenfaces* não é útil para o reconhecimento. Assim, as etapas referentes ao cálculo da matriz de covariância, e dos autovalores e autovetores referentes a essa matriz, é substituído pelo esquema proposto por Turk e Pentland (1991), considerando as Eq. 13 e Eq. 14:

$$L = A^T A \quad \text{ou} \quad L_{n,m} = \Phi_n^T \Phi_m \quad (13)$$

$$U = A.V \quad \text{ou} \quad v_l = \sum_{k=1}^M v_{lk} \Phi_k$$

$$l = 1, \dots, M \quad (14)$$

Onde U representa a matriz de autovetores de C e V a matriz de autovetores de L .

Na Eq. 13 a matriz L possui tamanho $M \times M$ e representa a covariância entre cada face e todas as faces do conjunto de treino. Os M primeiros *eigenfaces* μ_L da matriz C são calculados, conforme a Eq. 14, a partir dos M autovetores v_L da matriz L .

Note que a matriz L ($M \times M$) é menor que C ($N^2 \times N^2$) pois em geral $M < N^2$. Com isto ter-se-á de avaliar apenas M números, ao passo que no método original deve-se avaliar N^2 para o cálculo dos *eigenfaces*. Isto simplifica o processamento, pois normalmente o número de faces é muito menor que o número de pixels de cada face ($M \ll N^2$).

Para o reconhecimento e até mesmo para a reconstrução de faces, estes M primeiros *eigenfaces* são suficientes, entretanto, para o reconhecimento em especial, pode-se ainda eliminar alguns destes *eigenfaces* e trabalhar com apenas os M' de maiores autovalores ($M' < M$). A reconstrução da face com restrição de Componentes Principais é representada na Fig. 4.

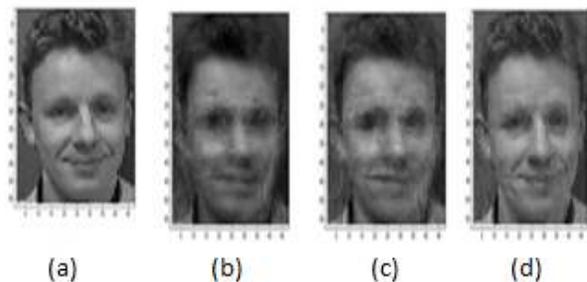


FIGURA 4 – Face (a) original, reconstruída (b) com 30 CP's, (c) com 60 CP's, (d) com 90 CP's de um total de 119 CP's.

2.4 CLASSIFICAÇÃO DE IMAGENS

Turk e Pentland (1991) afirmam que se deve classificar primeiramente se a imagem representa uma face humana ou não. E, em caso positivo, se esta imagem está inserida no banco de dados treinado sendo, portanto, conhecida, caso contrário, desconhecida.

De acordo com Körting e Duarte Filho (2004), o reconhecimento de faces por *eigenfaces* é composto por dois estágios: um para o treinamento e outro para o reconhecimento. No estágio de treinamento a face de cada indivíduo Γ_k é projetada no espaço das imagens gerando a matriz Ω da Eq. 15.

$$\Omega = U^T(\Gamma - [\psi, \psi, \dots, \psi]_{[n \times M]}) \quad (15)$$

Esta matriz Ω possui tamanho $M \times M$ e cada uma de suas colunas representa os vetores de peso do conjunto de treino que serão utilizadas posteriormente.

Segundo o mesmo autor, para-se realizar o reconhecimento de uma imagem de prova Γ_{nova} , deve-se projetá-la no espaço de imagens, conforme a Eq. 16.

$$\Omega^{nova} = U^T(\Gamma^{nova} - \psi) \quad (16)$$

A reconstrução pode ser realizada através da Eq. 17 (TURK; PENTLAND, 1991), (KÖRTING; DUARTE FILHO, 2004) e (MENDONÇA, 2008).

$$\Gamma_f = U\Omega + \psi \quad (17)$$

Segundo Mendonça (2008), as distâncias euclidianas obtidas na Eq. 18 e na Eq. 19 são as medidas mais utilizadas para classificar esta face de entrada.

$$\varepsilon_k = \left\| \Omega^{nova} - \Omega_k \right\| \quad k = 1 \dots n \quad (18)$$

$$\varepsilon = \left\| \Gamma - \Gamma_f \right\| \quad (19)$$

De acordo com Körting e Duarte Filho (2004), define-se ainda, um valor limiar, este valor representa a maior distância aceitável entre imagens de teste e as imagens de treinamento, como mostra a Eq. 20.

$$\theta_c = \frac{1}{2} \max_{j,k}^n \{ \Omega_j - \Omega_k \} \quad (20)$$

Por fim, de acordo com Turk e Pentland (1991), é realizada a classificação da nova imagem, mediante os seguintes critérios:

- Se, $\varepsilon \geq \theta_c$

Então a nova imagem não representa uma face;

- Se, $\varepsilon < \theta_c$ E $\varepsilon_k \geq \theta_c$,

Então a imagem representa uma face humana de um indivíduo não presente no banco de faces treinado;

- Se $\varepsilon < \theta_c$ E $\min(\varepsilon_k) < \theta_c$,

Então a imagem representa a face de um indivíduo presente no banco de dados treinado.

Segundo Arnold, Frater e Pickering (2007), um método comum para medição da qualidade de um serviço de vídeo reconstruído é a relação sinal-para-ruído de pico (PSNR). O erro médio quadrático entre um original e uma imagem reconstruída do tamanho $M \times N$ pixels é definido pela Eq. 21

$$MSE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (x_{ij} - \hat{x}_{ij})^2 \quad (21)$$

Onde $X_{i,j}$ é o valor do pixel original e $X_{i,j}$ é o valor do pixel reconstruído.

O PSNR é então definido pela Eq. 22.

$$PSNR = 10 \log_{10} \frac{(Peak_to_peak_signal)^2}{MSE} \quad (22)$$

Para uma imagem com escala de 256 níveis de cinza o *Peak_to_peak_signal* é 255.

3 METODOLOGIA

Na primeira etapa desta pesquisa foi realizada uma abordagem na fundamentação estatística do método com enfoque na matriz de covariância e também sobre a Álgebra Linear envolvida no *Eigenfaces* com o estudo de autovetores.

Foi implementado na segunda etapa, utilizando a ferramenta computacional MATLAB um algoritmo que executasse a extração de *eigenfaces*, a reconstrução e o reconhecimento de uma imagem, a partir de um banco de faces disponível na Internet.

Já na terceira etapa foram realizados os testes para validação do método. Para isto imagens de faces frontais bem enquadradas foram utilizadas simulando, por exemplo, um check-in de um aeroporto, uma liberação de acesso de funcionários de uma empresa

ou um reconhecimento de um suspeito em um banco de faces de criminosos. Estas faces utilizadas fazem parte do banco de faces *Olivetti Research Laboratory*, disponibilizadas gratuitamente na Internet. O banco de faces ORL database utilizado conta com 10 faces de 40 pessoas diferentes, totalizando 400 imagens, sendo estas frontais, com pouca variação na orientação da cabeça, diferentes condições de iluminação e expressões distintas.

Os testes de reconhecimento foram realizados considerando as seguintes variáveis de entrada: o número de faces ou mais precisamente o número de variações por indivíduo do conjunto de treino, porcentagem de componentes principais utilizadas, dimensão da imagem e método de comparação.

As comparações se dividiram em quatro diferentes métodos: Moda Estatística, Média dos *Clusters*, MSE dos *Clusters* e o método Individual ou '*Um contra todos*'.

A moda estatística se resume no cálculo da distância euclidiana ou erro quadrático médio, Eq. 18 e Eq. 21 respectivamente, entre a face de entrada e as do conjunto de treino. A partir destas distâncias, são tomadas as menores distâncias e dentro deste subconjunto de valores é verificado qual indivíduo é responsável pela maior parte destas distâncias. Quando não há moda neste subconjunto ou quando há mais de uma moda é classificado o indivíduo responsável pelo menor valor.

A Média dos *Clusters*, também calcula a distância euclidiana entre a face de entrada e cada uma do conjunto de treino, conforme Eq. 18. As distâncias referentes a um mesmo indivíduo são agrupadas em um *cluster* e por fim calculado o valor médio deste *cluster*. A face será classificada de acordo com a menor média entre os *clusters*.

O MSE dos *Clusters* opera de maneira semelhante à Média dos *Clusters*, no entanto, é utilizada a Eq. 21 em detrimento da Eq. 18.

Por fim o método Individual, também conhecido como 'um contra todos', calcula de maneira semelhante aos outros métodos a distância euclidiana e o erro quadrático médio, no entanto, para a classificação utiliza-se apenas o indivíduo responsável pela menor distância encontrada.

4 RESULTADOS E DISCUSSÃO

O valor limiar de classificação, calculado pela Eq. 20 ou definido de maneira empírica, classificou

corretamente as faces ou não faces nos testes preliminares.

Os testes iniciais foram realizados com as imagens do banco faces e um conjunto de treino contendo 3 faces de 40 pessoas, totalizando 120 faces. Os resultados encontrados estão disponíveis na Tab. 1.

Para um conjunto de treino com 160 faces, os resultados são apresentados na Tab. 2.

Para um conjunto de treino com 240 faces, os resultados são apresentados na Tab. 3.

280 TESTES												
Porcentagem de CPs utilizadas	TAXA DE ACERTO											
	(12x10) pixels				(31x22) pixels				(57x47) pixels			
	MODA	MÉDIA	MSE (med)	Individual	MODA	MÉDIA	MSE (med)	Individual	MODA	MÉDIA	MSE (med)	Individual
90%	72,50%	83,54%	80,71%	88,57%	72,50%	86,42%	85,00%	91,79%	72,50%	85,36%	84,29%	91,79%
70%	72,50%	83,93%	81,07%	88,57%	72,14%	86,43%	85,00%	91,43%	72,86%	84,29%	83,57%	91,07%
50%	72,50%	83,93%	80,71%	87,86%	72,86%	86,43%	83,93%	90,00%	73,57%	85,71%	84,64%	91,07%
30%	72,14%	83,54%	80,36%	87,50%	75,00%	85,71%	83,93%	89,29%	75,71%	85,71%	84,29%	90,00%
20%	72,14%	81,42%	78,57%	84,64%	72,14%	84,29%	81,07%	86,79%	71,79%	76,79%	73,57%	87,86%

TABELA 1—RESULTADOS DE RECONHECIMENTOS INDIVIDUAIS PARA UM CONJUNTO DE TREINO COM 120 FACES.

240 TESTES												
Porcentagem de CPs utilizadas	TAXA DE ACERTO											
	(12x10) pixels				(31x22) pixels				(57x47) pixels			
	MODA	MÉDIA	MSE (med)	Individual	MODA	MÉDIA	MSE (med)	Individual	MODA	MÉDIA	MSE (med)	Individual
90%	75,00%	85,42%	83,33%	91,25%	76,67%	88,33%	85,83%	92,50%	76,25%	88,75%	87,08%	93,75%
70%	75,00%	85,42%	83,33%	91,25%	77,08%	87,92%	85,42%	92,50%	76,67%	88,75%	86,67%	92,92%
50%	75,00%	85,42%	83,33%	90,42%	77,50%	87,92%	85,00%	92,50%	77,50%	88,33%	86,67%	92,50%
30%	74,58%	85,33%	84,17%	90,42%	77,08%	87,92%	86,25%	91,67%	79,17%	87,92%	86,67%	92,08%
20%	74,58%	84,58%	82,92%	89,17%	77,50%	86,25%	84,58%	91,67%	78,75%	85,83%	85,38%	91,67%

TABELA 2—RESULTADOS DE RECONHECIMENTOS INDIVIDUAIS PARA UM CONJUNTO DE TREINO COM 160 FACES.

160 TESTES												
Porcentagem de CPs utilizadas	TAXA DE ACERTO											
	(12x10) pixels				(31x22) pixels				(57x47) pixels			
	MODA	MÉDIA	MSE (med)	Individual	MODA	MÉDIA	MSE (med)	Individual	MODA	MÉDIA	MSE (med)	Individual
90%	77,50%	89,38%	87,50%	96,88%	81,25%	89,38%	89,38%	96,25%	80,63%	88,75%	87,50%	96,25%
70%	77,50%	89,38%	88,13%	96,88%	81,25%	89,38%	89,38%	96,25%	80,00%	88,75%	87,50%	95,00%
50%	78,13%	89,38%	88,75%	96,88%	81,25%	89,38%	89,38%	96,25%	81,25%	88,75%	86,88%	95,63%
30%	78,75%	89,38%	88,75%	96,88%	82,50%	89,38%	89,38%	96,25%	80,00%	88,75%	87,50%	96,25%
20%	78,75%	89,38%	88,13%	96,88%	81,87%	89,38%	88,75%	96,25%	81,25%	88,75%	88,13%	96,25%

TABELA 3–RESULTADOS DE RECONHECIMENTOS INDIVIDUAIS PARA UM CONJUNTO DE TREINO COM 240 FACES.

5 CONCLUSÃO

A técnica de *eigenfaces* apresentou como vantagens uma taxa de acertos considerável, fácil manipulação dos dados, a possibilidade de uma redução massiva de elementos redundantes (eliminação de *eigenfaces* de menor peso), além de se tratar de um método que, aliado a outros, otimizam seu desempenho.

Em contrapartida, ainda não se tem conhecimento de um método matemático para determinar um limiar de maneira assertiva, que separe as imagens de entradas em imagens de faces ou não faces e, quando consideradas imagens de faces, dividi-las em pertencentes, ou não, ao conjunto de treino. Também, devido ao fato desta ser uma análise estatística, o método restringe-se às condições específicas de iluminação, orientação da cabeça em frente ao instrumento de captura e pano de fundo da imagem.

A mudança na dimensão da imagem influenciou pouco na resposta do sistema, o que pode ser visto como uma vantagem do ponto de vista da redução de dados, assim como a possibilidade da redução de

componentes principais utilizadas, que também impactou pouco nos resultados finais.

A moda estatística apresentou o pior resultado, o que evidencia que as faces de um *cluster* estão dispersas e sobrepostas em outros *clusters*.

Agrupando as imagens do conjunto de treino em *clusters*, a resposta do sistema, ao contrário do que se previa, foi inferior aos reconhecimentos individuais. No entanto sua taxa de acertos cresceu de maneira inversa à quantidade de componentes utilizadas, o que representa uma vantagem no que se refere à redução de dados. A distância euclidiana e o erro médio quadrático se mostraram semelhantes como método de classificação.

Analisando as imagens no método Individual, ‘um contra todos’, ou seja, associando a imagem de entrada à do conjunto de treino, que possui menor distância euclidiana ou menor erro quadrado médio, obteve-se um excelente resultado, principalmente quando se tem no conjunto de treino um número maior de faces por indivíduo.

REFERÊNCIAS

ARNOLD, J., FRATER, M., PICKERING, M. **Digital Television – Technology and Standards**. The University of New South Wales, ADFA Canberra, ACT, Australia, 2007. 644p.

AT&T Laboratories Cambridge, **ORL Database**. 2002. Disponível em: <<http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>>. Acesso em: 15 out. 2011.

KÖRTING, T. S., DUARTE FILHO, N. L. **Utilizando Eigenfaces para Reconhecimento de Imagens**. Rio Grande/ Rio Grande do Sul: Fundação Universidade Federal do Rio Grande, 2004. 11p. Disponível em: <<http://www.dpi.inpe.br/~tkorting/docs/Korting2004a.pdf>>. Acesso em: 26 ago. 2011.

LIMA, C. G. **Apostila de Estatística I**. Pirassununga/SP: USP/Faculdade de Zootecnia e Engenharia de Alimentos - Departamento de Ciências Básicas, 2002. 57p.

MENDONÇA, M. M. **Comparação entre métodos de normalização da iluminação utilizados para melhorar a taxa do reconhecimento facial**. São Carlos/ São Paulo: USP/ Escola de Engenharia de São Carlos—Departamento de Engenharia Elétrica, 2008. 125p. Disponível em: <<http://www.iar.unicamp.br/lab/luz/ld/Arquitetural/Pesquisa/Michelle.pdf>>. Acesso em: 25 set. 2011.

SANTOS, A. R. **Identificação de faces humanas através de PCA-LDA e Redes Neurais SOM**. São Carlos/ SP: USP/ Departamento de Engenharia Elétrica, 2005. 154p. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/18/18133/td-21042006-222231/pt-br.php>>. Acesso em: 15 mar. 2012.

SANTOS, R. J. **Álgebra Linear e aplicações**. Belo Horizonte/MG: Imprensa Universitária da UFMG, 2010. 506p. Disponível em: <<http://www.mat.ufmg.br/~regi/gaalt/gaalt2.pdf>>. Acesso em: 8 jun. 2012.

SIROVICH, L., KIRBY, M. **Low-dimensional procedure for the characterization of human face**. Rhode Island: Brown University/Division of Applied Mathematics, 1986. 6p. Disponível em: <<http://www-flare.cs.ucl.ac.uk/staff/S.Prince/4C75/Sirovich87.pdf>>. Acesso em: 12 dez. 2011.

SPIEGEL, M. R. **Estatística**. 3ª Ed. São Paulo/ SP: Makron Books, 1993.

TURK, M., PENTLAND, A. Eigenfaces for Recognition. Massachusetts Institute of Technology / **Journal of Cognitive Neuroscience**. 1991. 6p. Disponível em: <<http://www.cs.ucsb.edu/~mturk/Papers/jcn.pdf>>. Acesso em: 12 out. 2011.