

Estudo da Eficiência do Reconhecimento Facial Utilizando PCA Incremental

GUSTAVO A. F. MELO, RODRIGO F. SOUTO E ADOLFO BAUCHSPIESS

Laboratório de Automação, Visão e Sistemas Inteligentes - Departamento de Engenharia Elétrica
UnB – Universidade de Brasília, Campus Darcy Ribeiro, 22460 Brasília, DF, Brasil
{gafmelo, fontes, adolfobs}@ene.unb.br

Resumo — Um sistema de reconhecimento facial para aplicações no mundo real deve armazenar informações de um grande número de indivíduos em seu banco de dados. Para o monitoramento de ambientes públicos, as imagens das câmeras devem ser segmentadas e as faces encontradas devem ser avaliadas pelo sistema de reconhecimento facial. O esforço computacional para acrescentar novos indivíduos ao banco de dados é muito importante. Tradicionalmente, ao se acrescentar um indivíduo o algoritmo PCA (*Principal Component Analysis*) utiliza novamente todo o banco de dados. Neste trabalho, apresenta-se um estudo da eficiência do algoritmo incremental que reduz significativamente o tempo de processamento, permitindo uma atualização eficiente do sistema de reconhecimento de faces. Isto é muito interessante na automação de sistemas de monitoramento de *shopping centers*, aeroportos e outros locais onde a segurança é importante. Mostram-se resultados alcançados com diferentes bancos de imagens, em particular a análise dos tempos envolvidos nas diversas etapas do reconhecimento de faces, com PCA convencional e com a PCA incremental.

Palavras-Chave: Reconhecimento de Faces, Método das Componentes Principais, PCA Incremental.

1. Introdução

O reconhecimento de faces é uma tarefa que o cérebro humano executa em aproximadamente 100ms. Mesmo alterando-se penteado, barba, usando óculos ou havendo passado anos, reconhecemos quase imediatamente rostos conhecidos. Programar um computador para realizar esta tarefa tem-se mostrado um grande desafio. A figura 1 ilustra variações de imagens de uma mesma face; de um homem e de uma mulher. Diferenças de iluminação, utilização de óculos, cachecol no pescoço, boca aberta e olhos fechados são alterações tão fortes na imagem que praticamente excluem uma abordagem geométrica (e.g., comparar distância entre olhos, tamanho da boca, comprimento da testa etc). Pesquisas seminais com a utilização de computadores para reconhecimento facial são devidas à Kirby e Sirovich (1990) e à Turk e Pentland (1991). Muitos trabalhos acadêmicos foram publicados desde então. No entanto, constata-se, ainda hoje, que relativamente poucos sistemas têm maturidade comercial (FRVT, 2002).

O reconhecimento de faces tem, comparado a outros métodos de identificação biométrica (impressão digital, íris, DNA etc.), a vantagem potencial de poder ser utilizado em tempo real e sem, necessariamente, a cooperação das pessoas monitoradas.

Se, por exemplo, um *shopping-center* monitora “clientes indesejados” (e.g., os que já foram flagrados furtando uma loja), ou um aeroporto deve impedir o embarque de criminosos, então é desejável que um

sistema automatizado localize faces nas imagens do circuito interno de TV, e, rapidamente verifique se esta pessoa está cadastrada no banco de dados correspondente.

Nesta situação, para que o sistema de reconhecimento facial seja capaz de reconhecer o rosto de determinado indivíduo, não é, em geral, suficiente armazenar uma única imagem da pessoa. Também não é factível, no reconhecimento, depender de imagens com condições favoráveis ao reconhecimento. Em ambientes vigiados não é, por certo, possível solicitar ao monitorado uma pose conveniente..

Desta forma, para um sistema reconhecer bem um conjunto grande de indivíduos com alta taxa de acerto, é necessário extrair informações de um conjunto razoável de imagens de cada indivíduo. Entretanto, quanto maior for o conjunto de imagens, maior o esforço computacional associado.



Figura 1 Variações faciais do ARFace Database.

O algoritmo incremental utilizado neste trabalho foi aplicado a três diferentes bancos de imagens. A eficiência do algoritmo incremental é analisada pela medida dos tempos envolvidos em cada etapa do processamento.

2. Reconhecimento de Faces via PCA

Existem diferentes abordagens para a implementação do reconhecimento de faces. Além da abordagem geométrica (Xue, Li e Teoh, 2003), pode-se citar a utilização de Redes Neurais Artificiais (Aitkenhead e McDonald, 2003) e o método da Análise das Componentes Principais (PCA). Cada um destes métodos tem vantagens em relação aos outros dependendo do contexto em que é utilizado. Dentro da proposta deste trabalho, o método PCA mostrou-se eficiente e simples de ser implementado.

Para reduzir o esforço computacional, o método PCA transforma o espaço amostral em um novo espaço de dimensão reduzida (Turk e Pentland, 1991). Uma vez que a dimensão do problema foi reduzida e se possui um certo classificador, o sistema está apto a reconhecer os indivíduos que tiveram imagens participando do banco de dados.

De fato, a técnica PCA consiste de um método estatístico de análise multivariável capaz de reduzir a dimensão do problema mantendo suas características mais relevantes (Haykin, 2001). Na literatura, a técnica PCA, ou transformada de Karhunen-Loeve é amplamente utilizada por se tratar de uma técnica ótima para a redução de dimensão (Haykin, 2001). Todavia, diversos classificadores podem ser utilizados para se obter, a partir do espaço reduzido, as informações necessárias ao reconhecimento. Há três classificadores que são utilizados com maior frequência para o reconhecimento facial: o neural, o bayesiano e a distância euclidiana. Neste trabalho, utilizar-se-á a distância euclidiana.

A aplicação do reconhecimento facial em *shopping-centers* e aeroportos, por exemplo, é dinâmica. Indivíduos são continuamente acrescentados e/ou retirados da lista de pessoas a serem monitoradas. Em um sistema dinâmico, onde se possam acrescentar novas imagens, cada novo conjunto a ser adicionado implicará em um novo cálculo para o sistema. Para sistemas com um grande número de imagens, este tempo até serem finalizados os cálculos será elevado, deixando o sistema inoperante por um longo período de tempo.

Desta forma, muito esforço tem sido feito de maneira a se reduzir este tempo de cálculo do sistema. Todavia, estes métodos ainda exigem demasiado esforço computacional, principalmente por se tratar de um processo com várias iterações (Xue, 2003). O algoritmo incremental proposto por Yongmin Li (2003) é bastante

interessante, notadamente por exigir poucas iterações e poder ser facilmente adaptado para o algoritmo PCA robusto (De La Torre e Black, 2001).

Neste contexto, o presente trabalho desenvolveu um estudo comparativo a fim de se analisar a eficácia do algoritmo PCA incremental de forma a reduzir o esforço computacional. Verificou-se posteriormente, disponibilizado na Internet, mas ainda não publicado, um trabalho que vai além do presente, nos aspectos incrementais do algoritmo PCA (Li, 2003).

3. O Algoritmo PCA

Nesta seção será descrito o algoritmo PCA convencional. Primeiramente será mostrado como se obter um espaço de faces de menor dimensão que o espaço das imagens originais. Em seguida, mostra-se como realizar o restante dos cálculos utilizando o espaço de faces. Por fim, é mostrado como se procede ao reconhecimento utilizando a distância euclidiana como classificador.

3.1 Obtenção do Espaço de Faces

Seja uma imagem em tons de cinza de N_L linhas e N_C colunas. Para a implementação da PCA, deve-se inicialmente transformar a imagem em um vetor coluna. Esta transformação pode ser feita através da concatenação das colunas, isto é, abaixo da primeira coluna colocam-se, na ordem, as demais colunas. Após o processo de concatenação, obtém-se um vetor com $(N_L N_C)$ linhas. Com a finalidade de se exemplificar este processo, considere a matriz 4x3 mostrada na figura 2(a). Após a concatenação, a matriz da figura 2(a) passa a ser um vetor coluna, como pode ser visualizado na figura 2(b).




Figura 2 Ilustração da ordenação dos pixels (b) obtidos de uma matriz imagem (a) para o algoritmo PCA.

O espaço de imagens é então definido como a matriz onde cada coluna é um vetor obtido de uma imagem facial pelo processo descrito acima. Para um conjunto de N imagens, a dimensão do espaço de imagens é de $(N_L N_C)$ linhas por N colunas.

A seguir, calcula-se a face média dos elementos contidos no espaço de imagens, sendo cada imagem um vetor-coluna, representado por $\mathbf{e}_i$. Desta forma:

$$\boldsymbol{\mu} = \frac{1}{N} \sum_{k=1}^N \mathbf{e}_k \quad (1)$$

Onde N é o número de imagens. O vetor da face média possui $(N_L N_C)$ linhas. Obtida a face média, é possível montar um outro conjunto de imagens. Neste conjunto, cada coluna representa a diferença entre uma face e a face média. Desta forma, o novo espaço de imagens é calculado da seguinte forma:

$$\Delta_k = \mathbf{e}_k - \boldsymbol{\mu}, \quad k = 1: N \quad (2)$$

Onde k indica o vetor-coluna e varia de 1 a N . Percebe-se que a matriz completa Δ tem dimensão de $(N_L N_C) \times N$. Define-se então a matriz de covariância da seguinte forma:

$$\mathbf{C} = \Delta \Delta^T \quad (3)$$

A matriz $\mathbf{C}$ tem dimensão de $(N_L N_C) \times (N_L N_C)$, possuindo um total de $(N_L N_C)^2$ pixels. O passo seguinte seria calcular os autovalores e os autovetores da matriz $\mathbf{C}$. Contudo, o esforço computacional para se calcular tais parâmetros para uma matriz típica seria enorme. Logo, optou-se por calcular os autovalores e os autovetores de outra forma. Primeiramente, define-se uma matriz $\mathbf{L}$ da seguinte forma:

$$\mathbf{L} = \Delta^T \Delta \quad (4)$$

Nota-se que a matriz $\mathbf{L}$ tem dimensão $N \times N$. Pode-se utilizar um teorema da Álgebra Linear (Silva, 2000) para mostrar a relação existente entre autovalores e autovetores das matrizes $\mathbf{C}$ e $\mathbf{L}$. Os autovetores de $\mathbf{C}$ podem ser calculados de uma forma mais simples, a partir da combinação linear do espaço das imagens originais com a matriz dos autovetores de $\mathbf{L}$. Matematicamente:

$$\mathbf{U} = \mathbf{E} \mathbf{V} \quad (5)$$

Onde a matriz $\mathbf{V}$ é constituída pelos autovetores de $\mathbf{L}$ e possui dimensão $N \times M$, sendo M o número de autovetores considerados para o reconhecimento, com M podendo variar de 1 a N . A matriz $\mathbf{E}$ é o espaço de imagens com dimensão de $N_L N_C$ linhas por N colunas, e a matriz $\mathbf{U}$ é composta pelos autovetores de $\mathbf{C}$ e possui dimensão $(N_L N_C) \times M$.

De fato, a ordem de grandeza dos autovalores representa a quantidade de informação contida no autovetor, de modo que os autovetores com os maiores autovalores correspondentes são os mais representativos. Desta forma, a escolha adequada de alguns autovetores é suficiente para se proceder ao reconhecimento.

A matriz $\mathbf{U}$ também é denominada *eigenspace*. As *eigenfaces* reúnem um conjunto de características importantes que descrevem a variação da imagem no espaço de imagens. Salvo o caso em que $M = N$, percebe-se que a dimensão deste novo espaço será menor que a dimensão do espaço de imagens. Na verdade, esta redução será tão maior quanto menor for o número de autovetores escolhidos.

3.2 Banco de Imagens

Para realizar testes com o algoritmo são necessárias imagens para servirem como uma base de testes. Para isto foram procurados bancos de dados contendo imagens de faces. Para mostrar a possível variação na apresentação das imagens, mostram-se na figura 1 algumas imagens como exemplo de um dos bancos utilizados (Martinez e Benavente, 1998). Como se pode perceber, há variações de iluminação e a utilização de disfarces para dificultar o reconhecimento. O banco de imagens que foi utilizado para os testes que serão descritos mais adiante é da AT&T Laboratories Cambridge (ATT_Faces, 2004). Este consta de 40 pessoas, com 10 imagens de cada. As imagens são apresentadas em 256 tons de cinza, com resolução de 92 por 112 *pixels*.

3.3 Cálculos do Modelo

Utilizando um subconjunto das imagens de uma mesma pessoa, escolhem-se algumas imagens para o cálculo do banco. A seguir, representa-se cada imagem da pessoa no espaço de faces. Considerando $\boldsymbol{\phi}$ como um vetor que representa uma imagem do indivíduo, a projeção desta imagem no espaço de faces dar-se-á da seguinte forma:

$$\mathbf{p}_K = \mathbf{U}^T (\boldsymbol{\phi}_K - \boldsymbol{\mu}) \quad (6)$$

O vetor $\boldsymbol{\mu}$ é o vetor da face média e apresenta dimensão $(N_L N_C) \times 1$. O vetor $\boldsymbol{\phi}_K$, de dimensão $(N_L N_C) \times 1$, representa a k -ésima imagem do indivíduo. A matriz $\mathbf{U}^T$ é a matriz transposta de $\mathbf{U}$. Sua dimensão é de $M \times (N_L N_C)$. O vetor $\mathbf{p}_k$ é a k -ésima projeção da k -ésima imagem, apresentando dimensão de $M \times 1$. O valor máximo de k indica o número de imagens utilizadas no treinamento. Para k variando de 1 a N_{CL} , pode-se concatenar os vetores $\mathbf{p}_k$ em colunas de modo a obter uma matriz $\mathbf{P}$ contendo todas as representações das imagens no espaço de faces. A dimensão da matriz $\mathbf{P}$ é de $M \times N_{CL}$.

A figura 3 ilustra o fluxograma do algoritmo PCA juntamente com os descritores, caracterizando todo o processo de reconhecimento. O último processo, que é chamado de “Descritores”, representa os dados obtidos para a classificação, as matrizes que armazenam os resultados dos cálculos.




Figura 3 Fluxograma para o reconhecimento facial.

3.4 O Reconhecimento de Faces

De maneira análoga à representação de uma face no *eigenspace*, uma imagem qualquer de um rosto também pode ser representada no espaço de faces. Considerando $\mathbf{h}$ o vetor representativo de uma face:

$$\omega = U^T (\mathbf{h} - \mu) \quad (7)$$

O vetor $\mathbf{h}$ tem $(N_L N_C)$ linhas ω é a representação da face no espaço de faces e possui M linhas.

O indivíduo referente ao vetor $\mathbf{p}_k$ que mais se aproximar do vetor ω será o reconhecido. Matematicamente, calcula-se a distância entre o vetor ω e cada vetor $\mathbf{p}_k$, de modo que a menor distância pertence ao vetor mais próximo. A distância calculada é a distância euclidiana entre os dois vetores, conforme:

$$\varepsilon_K = \sqrt{\|\omega - \mathbf{p}_K\|^2} \quad (8)$$

4. Algoritmo Incremental para PCA

Alguns dos fatores mais demorados para o cálculo do sistema do algoritmo da PCA são a leitura de cada imagem, o cálculo da face média e o cálculo da matriz Δ . Apresenta-se, abaixo, um meio de se incluir, ou retirar, um determinado conjunto de dados, aproveitando cálculos feitos anteriormente para as variáveis onde isto se aplica.

Considera-se que cada imagem seja um vetor-coluna, representado por $\mathbf{e}_i$. A imagem média do conjunto atual é dada por:

$$\mu = \frac{1}{N} \sum_{k=1}^N e_k \quad (9)$$

Onde N é o número de imagens. Se forem adicionadas R imagens, o novo conjunto terá uma nova quantidade N_i de imagens:

$$N_i = N + R \quad (10)$$

Deste modo, a média deste novo banco será:

$$\mu_F = \frac{1}{N_i} \sum_{k=1}^{N_i} e_k = \frac{\sum_{k=1}^N e_k + \sum_{k=N+1}^{N_i} e_k}{N + R} \quad (11)$$

Multiplicando e dividindo o primeiro somatório por N e substituindo (10) em (11):

$$\mu_F = \frac{N\mu + \sum_{k=N+1}^{N+R} e_k}{N + R} = \frac{N\mu + \sum_{j=1}^R e_j}{N + R} \quad (12)$$

Sabendo que a média das imagens incluídas é:

$$\mu_A = \frac{1}{R} \sum_{j=1}^R e_j \quad (13)$$

Multiplica-se e se divide o segundo somatório de (12) por R , obtendo:

$$\mu_F = \frac{N\mu + R\mu_A}{N + R} \quad (14)$$

Utilizando a equação (14), é possível calcular a média do novo conjunto de dados sem a necessidade de somar todas as imagens contidas no banco.

A fim de se evitar a leitura de todo o banco novamente, deve-se ainda calcular a matriz Δ em função de parâmetros já calculados e dos parâmetros do conjunto a ser acrescentado. A matriz diferença definida para o conjunto antigo de dados é da forma:

$$\Delta = [\mathbf{e}_1 - \mu, \mathbf{e}_2 - \mu, \dots, \mathbf{e}_N - \mu] \quad (15)$$

Assim:

$$[\Delta_1, \Delta_2, \dots, \Delta_N] = [\mathbf{e}_1 - \mu, \mathbf{e}_2 - \mu, \dots, \mathbf{e}_N - \mu] \quad (16)$$

Tem-se, então:

$$\begin{cases} \Delta_1 = \mathbf{e}_1 - \mu \\ \Delta_2 = \mathbf{e}_2 - \mu \\ \vdots \\ \Delta_N = \mathbf{e}_N - \mu \end{cases} \quad (17)$$

A nova matriz de diferença é dada por:

$$\Delta_F = [\mathbf{e}_1 - \mu_F, \mathbf{e}_2 - \mu_F, \dots, \mathbf{e}_{N+R} - \mu_F] \quad (18)$$

Substituindo os vetores $\mathbf{e}$ da equação (17) em (18), tem-se a matriz diferença desejada (19):

$$\Delta_F = [\Delta_1 + \mu - \mu_F, \Delta_2 + \mu - \mu_F, \dots, \Delta_N + \mu - \mu_F, \dots, \Delta_{N+1} - \mu_F, \dots, \Delta_{N+R} - \mu_F] \quad (19)$$

Os parâmetros acima não necessitam de uma nova leitura de todas as imagens do novo banco, pois já foram calculados ou dependem dos novos dados a serem acrescentados.

5. Resultados Obtidos

Nesta seção serão apresentados os resultados obtidos. Primeiramente, mostrar-se-á a taxa de acertos conseguida com o algoritmo PCA empregando a distância euclidiana como o classificador. Em seguida, tem-se a comparação dos resultados dos tempos entre o algoritmo convencional e o incremental, apresentando-se a distribuição dos tempos gastos em cada um.

5.1 O Sistema FaceUnB

A fim de se verificar a validação do modelo, o sistema *FaceUnB* de reconhecimento de faces foi implementado em *MatLab*TM. Este sistema é capaz de fazer o reconhecimento de faces e adicionar um novo conjunto utilizando o algoritmo incremental. Utilizou-se o banco de dados da AT&T Laboratories Cambridge (ATT_Faces, 2004). O computador utilizado possui um AMD Duron 1.3GHz com 512MB de memória, rodando sobre o *Microsoft Windows 2000*.

A partir deste sistema, foram obtidos os dados apresentados neste trabalho. As telas na figura 4 ilustram o processo de reconhecimento de um indivíduo. A figura 4-a permite a escolha da imagem a ser reconhecida. A figura 4-b mostra o resultado do reconhecimento.

Neste mesmo sistema, foi possível utilizando uma *webcam* acrescentar novos indivíduos, bem como reconhecê-los em tempo real.



Figura 4-a Seleção de foto para reconhecimento.




Figura 4-b Telas do programa de reconhecimento facial FaceUnB.

5.2 Desempenho

A figura 5 mostra os resultados dos testes realizados quando se testou o banco com diversas combinações de imagens. Para os testes escolheram-se 10, 25 e 40 indivíduos. Em seguida, verificou-se a taxa de acertos de reconhecimento, variando, para cada indivíduo, o número de imagens utilizadas para os cálculos do banco. Evidencia-se uma alta taxa de acertos para determinadas configurações do banco. Nota-se, inclusive, uma tendência de melhora na performance quando se aumenta o número de imagens utilizadas para os cálculos, ou seja, quando o sistema possui mais informações a respeito de determinada pessoa. Contudo, utilizando um mesmo número de imagens por indivíduo, observa-se uma diminuição na taxa de acertos, quanto maior for o número de indivíduos cadastrados no banco. Dependendo do número de indivíduos, de imagens utilizadas para os cálculos iniciais e de autovetores, chega-se a uma velocidade de até 7547 reconhecimentos por minuto.




Figura 5 Taxa de acertos pelo número de imagens utilizadas.

5.3 Comparação dos Algoritmos

Para se obter o gráfico mostrado na figura 6, realizou-se o cálculo do sistema do banco inicialmente com 5 indivíduos, utilizando 10 imagens de cada. Em seguida, foram acrescentados 5 indivíduos também utilizando 10 imagens de cada. Repetiu-se o acréscimo de indivíduos até o número máximo de 40 pessoas. A cada etapa foi registrado o tempo. Em seguida, utilizou-se o algoritmo convencional para treinar o banco de forma a obter a mesma configuração e mediu-se o tempo gasto.




Figura 6 Fluxograma do algoritmo PCA.

O mesmo procedimento acima descrito foi realizado acrescentando dois indivíduos com cinco imagens de cada um. Mostra-se, na figura 7, o resultado obtido.




Figura 7 Fluxograma do algoritmo PCA.

Exceto no cálculo inicial do banco, onde o processo incremental e o convencional são idênticos, o incremental se mostrou mais veloz em todos os demais cálculos. Tal resultado já era esperado, uma vez que o banco está sendo calculado pela primeira vez, não possibilitando a utilização do algoritmo incremental, de forma que o tempo para os cálculos para os dois algoritmos é igual.

5.4 Distribuição dos Tempos

Observa-se nas figuras 8 e 9 a distribuição do tempo gasto em cada etapa do algoritmo. Nota-se um decréscimo na participação no cálculo da face média e na leitura das imagens.

A etapa mais demorada do processo é justamente a leitura das imagens, de forma que este decréscimo é responsável pela diminuição do tempo total. Assim, as demais etapas mantêm aproximadamente o mesmo tempo e passam a ter uma participação maior, o que está de acordo com a Lei de Amdahl, a qual mostra que a oportunidade de aperfeiçoar determinado evento é afetada pelo tempo consumido por tal evento. Portanto, tornar mais rápidos os casos mais demorados é uma regra que vai influenciar muito mais positivamente no desempenho do algoritmo (Patterson, 2000).




Figura 8 Fluxograma do algoritmo PCA.




Figura 9 Fluxograma do algoritmo PCA.

6. Resultados

Apresentou-se um estudo comparativo de dois métodos de reconhecimento facial. O método incremental, conforme esperado, é mais rápido quando se inserem imagens de um novo indivíduo.

Obtiveram-se os tempos dos cálculos para diversas quantidades de imagens. Verificou-se em todos os casos um ganho de desempenho com o algoritmo incremental, da ordem de 30% no tempo para os cálculos.

Foi possível investigar o tempo em cada etapa do processo de treinamento. Notou-se que o algoritmo incremental atua, em especial, de forma a dispensar a leitura completa do banco de imagens. Apenas lê-se o arquivo relativo ao novo indivíduo. Isto reduz o esforço computacional desta etapa de 38% para 3%, com relação ao tempo.

Em continuação a esta pesquisa pretende-se, em longo prazo, expandir o *FaceUnB* para a operação em tempo real, podendo assim ser utilizado em aeroportos e outros prédios públicos. Nesta aplicação, seria necessário um algoritmo veloz e eficiente para a detecção e extração de uma face em dada imagem. Buscar-se-ia uma otimização na implementação do algoritmo de reconhecimento, bem como uma maneira de se tornar incremental os demais passos.

Agradecimentos

Agradecemos aos editores e voluntários do SIBGRAPI. Também agradecemos ao CNPq pelo apoio recebido.

Referências

- [1] Abdi H. and Deffebacher K.A. and O'Toole A.J. and D. Valentin. "Low- dimensional representation of faces in higher dimensions of the face space.", *J. Opt. Soc. Am.* (1993), 405–410.
- [2] Aitkenhead M.J., McDonald A.J.S., "A neural network face recognition system", *Engineering Applications of Artificial Intelligence* 16 (2003), 167–176
- [3] Artac, M., "Mobile robot localization with incremental PCA", *IEEE Melecom* (2002), 192 — 197
- [4] ATT_Faces (2004). AT&T Laboratories Cambridge - www.uk.research.att.com/pub/data/att_faces.zip
- [5] De la Torre F., Black M., "Robust principal component analysis for computer vision", *IEEE International Conference on Computer Vision* (2001)., Vancouver, Canada, Vol. 1, 362–369.
- [6] Franco A., Lumini A., D. Maio, "Eigenspace merging for model updating." *International Conference on Pattern Recognition* (2002)., Quebec, Canada, Vol. 2, 156–159.
- [7] FRVT (2002) Face Recognition Vendor Test 2002 – <http://www.frvt.org>
- [8] Hall P.M., Marshall A.D., Martin R.R., "Incremental eigenanalysis for classification." *British Machine Vision Conference* (1998)., Southampton, UK, 286–295.
- [9] Haykin, S.: "Redes Neurais, Princípios e Prática", 2ª Edição, Bookman, 2001
- [10] Kirby M. e Sirovich L. "Application of the Karhunen-Loeve procedure for the characterization of human faces", *IEEE Transaction on Pattern Analysis and Machine Intelligence* (1990), 12(1).
- [11] Kirby M. and Sirovich L. "Low-dimensional procedure for the characterization of human faces". *J. Opt. Soc. Am.* (1987), (3):519–524.
- [12] Lange J. and J. Buhmann and Von der Malsburg C. "Distortion invariant object recognition by matching hierarchically labeled graphs." *In Proceedings of the International Conference on Neural Networks* (1989), Washington DC, EUA, Vol. 1, 155–159.
- [13] Li, Y., "On Incremental and robust subspace learning", *Pattern Recognition* (2003). Paper in Press, accepted 6 November.
- [14] Martinez A.M., Benavente R., The AR Face Database. *CVC Technical Report #24* (1998)- http://rvl1.ecn.purdue.edu/~aleix/aleix_face_DB.html
- [15] Patterson D.A, Hennessy J.L., "Organização e projeto de computadores: A interface Hardware/Software", (2000), 2ª ed. Editora LTC.
- [16] Pentland A., Moghaddam B. e Starner T., "View-based and modular eigenspaces for face recognition", *Proceedings IEEE Conf. on Computer Vision and Pattern Recognition* (1994), 84–91.
- [17] Silva, P.Q., "Reconhecimento facial baseado em *eigenfaces* e em PCA – *Principal Component Analysis* com múltiplos *thresholds*". Dissertação de Mestrado (2000)., Universidade de Brasília, Brasília - DF.
- [18] Skocaj D., Leonardis A., "Incremental approach to robust learning of eigenspaces", *Workshop of Austrian Association for Pattern Recognition* (2002), 111–118.
- [19] Turk M., Pentland A., "Eigenfaces for recognition", *J. Cognitive Neurosci* 3(1) (1991), 71–86.
- [20] Xue Z., Li S. Z., Teoh E. K., "Bayesian shape model for facial feature extraction and Recognition", *Pattern Recognition* 36 (2003), 2819 - 2833.