

# Uma Abordagem Escalável para Manutenção de Galeria de Faces

Gérson de Paulo Carlos      Hélio Pedrini  
Instituto de Computação  
Universidade Estadual de Campinas (UNICAMP)  
Campinas-SP, Brasil, 13083-852  
gerson.mtg@gmail.com, helio@ic.unicamp.br

William Robson Schwartz  
Departamento de Ciência da Computação  
Universidade Federal de Minas Gerais (UFMG)  
Belo Horizonte-MG, Brasil, 31270-010  
william@dcc.ufmg.br

**Resumo**—Reconhecimento de faces tem se destacado devido a sua aplicação em sistemas de biometria e vigilância, emergindo dois objetivos principais, a verificação e a identificação de faces. O primeiro busca aceitar ou negar uma identidade atribuída a uma certa face, enquanto que o segundo tem a meta de, dada uma face desconhecida, encontrar a melhor identidade para ela a partir de uma galeria de faces conhecidas. Para a tarefa de identificação, abordagens discriminativas como o método um-contra-todos têm alcançado acurácia superior em relação às abordagens descritivas como *eigenfaces*. Contudo, esses métodos apresentam problemas de escalabilidade quando a galeria de indivíduos conhecidos aumenta, pois é necessário recriar todos os modelos discriminativos. Este trabalho propõe e avalia um método para tornar o processo de manutenção da galeria descrito mais eficiente. Este método se baseia na criação de modelos um-contra-alguns com seleção aleatória de subconjuntos de indivíduos e na utilização de uma fila de prioridades para o casamento de amostras de teste. Resultados experimentais obtidos a partir da aplicação do método proposto em um conjunto público de faces são apresentados e comparados com outras abordagens da literatura.

**Abstract**—Face recognition has received increased attention due to its application in biometrics and surveillance systems, emerging two main objectives, verification and identification of faces. The first one aims at accepting or rejecting an identity assigned to a correct face, whereas the second aims at, given an unknown face, finding the best identity to it from a gallery of known faces. For the identification task, discriminative approaches such as the one-against-all method have achieved higher accuracy than descriptive approaches such as *eigenfaces*. However, such methods have scalability problems when the gallery with known individuals increases, since it is necessary to rebuild all discriminative models. This work describes and evaluates a novel method for making the process of gallery maintenance more efficient. This method is based on the construction of one-against-some models with random selection of subset of subjects and on the use of a priority queue to match test samples. Experimental results obtained by applying the proposed method on a publicly available face data set are presented and compared with other approaches in the literature.

**Keywords**—Face Identification; Partial Least Squares; Face Gallery.

## I. INTRODUÇÃO

Reconhecimento de faces se tornou uma área de pesquisa bastante ativa nos últimos anos devido a sua utilização em uma variedade de aplicações, tais como biometria, interação humano-máquina e vigilância. As duas tarefas principais do

reconhecimento de faces são a *verificação* e a *identificação*. A verificação tem como objetivo confirmar se uma identidade atribuída a uma face desconhecida é verdadeira ou não. Por outro lado, a identificação busca informar a identidade de uma face desconhecida com base em uma galeria de pessoas conhecidas.

Quando aplicado a ambientes bem controlados, o problema de reconhecimento de faces já possui soluções de qualidade, mesmo para galerias com um grande número de indivíduos [1]–[3]. No entanto, em aplicações com condições não controladas, em que as imagens adquiridas são suscetíveis a mudanças de iluminação, expressão facial ou idade do indivíduo, as taxas de reconhecimento podem decair a níveis não satisfatórios. Dessa forma, o reconhecimento de faces ainda é considerado um problema em aberto de pesquisa.

Além disso, devido ao grande tamanho das galerias encontradas em aplicações práticas, não apenas a acurácia, mas a escalabilidade do sistema de reconhecimento deve ser observada. Os principais problemas enfrentados em relação à escalabilidade são: primeiro, o número de indivíduos na galeria pode ser bastante grande, tal que algoritmos baseados em força bruta não produzirão bons resultados; segundo, em aplicações como vigilância e interação humano-computador, em que novos indivíduos são adicionados incrementalmente, a necessidade de reconstrução de todos os modelos da galeria sempre que ocorre a adição de um novo indivíduo, pode comprometer a eficiência do sistema.

A solução proposta por Schwartz et al. [4], que utiliza o esquema de classificação um-contra-todos baseado em modelos *Partial Least Squares* (PLS) [5]–[7], focou na combinação de descritores de características para aumentar a taxa de reconhecimento obtida. Contudo, o método ainda não resolve o problema da escalabilidade da manutenção da galeria, pois requer a reconstrução de todos os modelos quando um novo indivíduo é adicionado à galeria.

Para tornar a manutenção da galeria escalável, permitindo a adição de novos indivíduos sem a necessidade de recalcular todos os modelos PLS, este trabalho propõe a utilização de um esquema de classificação denominado um-contra-alguns. Neste esquema, apenas modelos PLS considerando um subconjunto de indivíduos são criados e, quando um novo indivíduo é adicionado, novos modelos PLS são construídos

sem a necessidade de reconstrução dos modelos previamente computados. Adicionalmente, propõe-se a utilização de uma fila de prioridade para reduzir o número de projeções quando uma amostra teste é apresentada ao sistema.

Resultados experimentais mostram que, embora o custo computacional seja significativamente menor quando novos indivíduos são adicionados à galeria, as taxas de reconhecimento obtidas são comparáveis ao estado da arte e muito próximas daquelas obtidas com a utilização do esquema de classificação um-contra-todos. Adicionalmente, o número de projeções necessárias para efetuar o casamento de uma amostra de teste é significativamente reduzido.

O texto está organizado como segue. A seção II apresenta uma revisão bibliográfica dos principais trabalhos correlatos ao tema sob investigação. A metodologia proposta é descrita na seção III. Resultados obtidos com a aplicação do método proposto em um conjunto de faces, bem como uma comparação com outros métodos da literatura, são apresentados e discutidos na seção IV. Finalmente, conclusões e propostas para trabalhos futuros são apresentadas na seção V.

## II. TRABALHOS RELACIONADOS

Pesquisas na área de reconhecimento de faces têm avançado substancialmente nos últimos anos, conforme reportado em algumas revisões bibliográficas descritas por Tolba et al. [8] e Zhao et al. [9]. A maioria dos trabalhos baseia-se em métodos estatísticos de aprendizado ou casamento local [10]. Métodos na primeira categoria utilizam a face de uma maneira holística para efetuar o reconhecimento, incluindo técnicas como *Support Vector Machine* (SVM) e *AdaBoost* [11]. No entanto, esses métodos podem sofrer do problema da generalização que dificulta a estimação da distribuição de características das faces contidas no conjunto de testes [12]. Por outro lado, os métodos na segunda categoria, que inicialmente extraem informações faciais locais e depois executam o reconhecimento, podem sofrer com a falta de informações mais globais sobre a face.

A maioria dos sistemas atuais de reconhecimento de faces funciona corretamente quando provido com amostras coletadas sob condições de aquisição controladas. No entanto, quando há variação de iluminação ou efeito de borrramento nas imagens, o desempenho é reduzido drasticamente.

Para executar o reconhecimento em condições razoavelmente não controladas, Tan e Triggs [13] propuseram o uso de um pré-processamento para normalização da iluminação e utilizaram uma medida de distância similar à distância de Hausdorff durante o reconhecimento. Aggarwal et al. [14] apresentaram uma formulação baseada no modelo de iluminação Lambertiano para se tornar invariante a mudanças de iluminação. Shih e Liu [15] propuseram um novo espaço cromático, o  $LC_1C_2$ , como sendo uma transformação linear do espaço RGB para compensar mudanças na iluminação. Utilizando a informação da fase obtida a partir da transformada de Fourier, Ojansivu et al. [16] propuseram um descritor textural invariante a borrimento e à rotação. O método proposto por Schwartz et al. [4] propôs a utilização de um conjunto de

descritores de características para generalizar o problema de iluminação, obtendo resultados superiores ao estado da arte.

Outro desafio a ser superado está no fato de que a maioria dos algoritmos de reconhecimento de faces necessita de múltiplas amostras para estimar as características de cada sujeito considerado. No entanto, nem sempre é possível se obter mais do que uma amostra por sujeito, em aplicações reais. A disponibilização de apenas uma amostra por sujeito torna a coleta da galeria uma tarefa mais simples, além de reduzir o custo de armazenamento e o custo computacional [17]. Desta maneira, uma característica desejável dos sistemas de reconhecimento de faces é a capacidade de operar com um número reduzido de amostras por sujeito.

Algumas soluções têm sido propostas para a resolução do problema de existência de poucas amostras. Liu et al. [18] propuseram que cada amostra seja representada como um subespaço gerado por amostras obtidas a partir de pequenas translações. De la Torre et al. [19] propuseram uma abordagem denominada *Representational Oriented Component Analysis* para executar reconhecimento de faces quando apenas uma amostra por sujeito está disponível. Schwartz et al. [4] propuseram o uso da técnica estatística *Partial Least Squares* (PLS) [5]–[7] para a resolução desse problema.

Trabalhos também foram propostos com o foco voltado ao problema da escalabilidade, conforme mencionado na seção anterior. Uma técnica que combina classificadores em uma cascata de rejeição foi proposta por Yuan et al. [20], com o objetivo de reduzir o custo computacional na busca do vizinho mais próximo na tarefa de identificação de faces. Guo e Zhang [21] propuseram o uso de um esquema de votação combinado com *AdaBoost* para reduzir o número de comparações.

## III. METODOLOGIA

Esta seção descreve inicialmente o processo de identificação de faces baseado no esquema de classificação um-contra-todos, proposto por Schwartz et al. [4], e utilizado como ponto de partida deste trabalho. Em seguida, o esquema de classificação denominado um-contra-alguns é apresentado, ao qual será associada uma fila de prioridade com o objetivo de reduzir o número de projeções necessárias para a identificação de uma face de teste apresentada ao sistema.

### A. Identificação de Faces

O método de identificação de faces proposto por Schwartz et al. [4] possui três etapas principais: extração de características, modelagem individual para indivíduos contidos na galeria e execução de regressões para efetuar o casamento de amostras de teste desconhecidas com indivíduos presentes na galeria.

Na extração de características, após recortada a região da imagem contendo apenas a face e reescalada para um dado tamanho, cada amostra é decomposta em um conjunto de blocos e um conjunto de descritores é extraído para cada bloco. Características exploradas incluem informação relacionada com forma (extraída com uso do descritor HOG [22]), textura (capturada utilizando-se o descritor LBP [23]) e cor

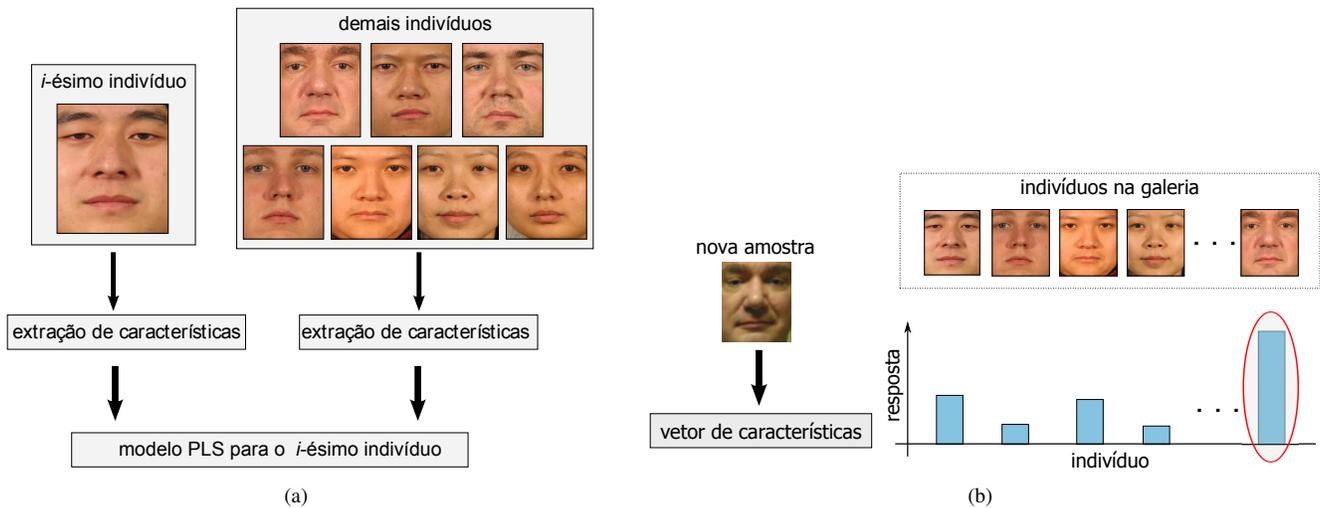


Figura 1: Abordagem um-contra-todos aplicada à identificação de faces. (a) construção dos modelos PLS para o  $i$ -ésimo indivíduo presente na galeria; (b) casamento de uma amostra de face com os indivíduos contidos na galeria.

(extraída a partir da média das intensidades dos pixels para cada banda de cor). Finalmente, um vetor de características  $v$  é composto pela concatenação dos descritores extraídos a partir de cada bloco. Este vetor é utilizado para descrever a face durante o reconhecimento.

O procedimento para estimar modelos para cada um dos  $N$  indivíduos contidos na galeria  $g = \{s_1, s_2, \dots, s_N\}$ , em que  $s_i$  representa exemplares do  $i$ -ésimo indivíduo, codificados por meio dos vetores obtidos durante a extração de características, dá-se da seguinte maneira. Como a identificação de faces é um problema contendo múltiplas classes, um esquema de classificação um-contra-todos é aplicado para estimar modelos de regressão utilizando o método estatístico para modelar relações entre variáveis denominado *Partial Least Squares* (PLS) [5]–[7]. Dessa maneira, quando o  $i$ -ésimo indivíduo é considerado, as demais amostras,  $g \setminus s_i$ , são utilizadas como contra-exemplos, conforme ilustrado na Figura 1(a). PLS estima a capacidade de discriminação para cada descritor e retorna os coeficientes de regressão  $\beta_i$ . Este processo é executado para todos os  $N$  indivíduos contidos na galeria.

Após a estimação de todos os modelos PLS e seus respectivos coeficientes de regressão, esses coeficientes são utilizados para efetuar o casamento de amostras desconhecidas com indivíduos contidos na galeria. Quando uma nova amostra é apresentada, seu vetor de características é projetado em cada um dos  $N$  modelos. O melhor casamento da amostra ocorre com o modelo que apresentar a maior resposta. Este processo é ilustrado na Figura 1(b).

Devido ao fato de se utilizar o esquema de classificação um-contra-todos, quando um novo indivíduo é adicionado à galeria, todos os modelos PLS devem ser reconstruídos, pois o novo indivíduo deve entrar como amostra negativa dos modelos, o que eleva o custo computacional. Desta maneira, para eliminar a necessidade de se reconstruir todos os modelos, este trabalho propõe a utilização do esquema de classificação denominado um-contra-alguns. Neste esquema, modelos PLS

são criados considerando-se apenas um subconjunto de indivíduos. A próxima seção descreve os detalhes desta abordagem.

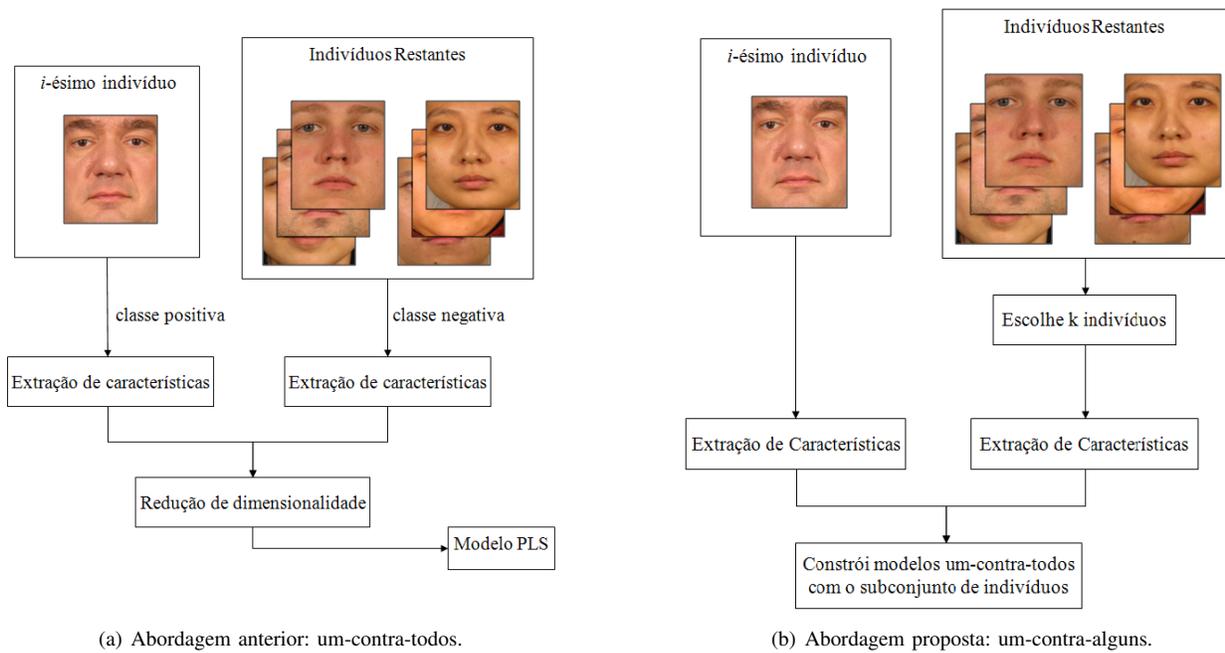
### B. Abordagem Um-Contra-Alguns e Fila de Prioridades

Buscando-se maximizar a discriminação entre  $C$  classes diferentes, o esquema de classificação um-contra-todos foi utilizado para estimar  $C$  modelos PLS, considerando variáveis de respostas únicas [4], [24]. Quando uma amostra de teste é considerada, ela é projetada em cada modelo, resultando em um conjunto de  $C$  respostas (uma para cada classe) e a classe que obtém a maior resposta é considerada como o melhor casamento.

O método proposto segue as mesmas etapas do trabalho para identificação de faces [4], como ilustrado na Figura 2(a). A principal diferença entre os métodos é que, enquanto na abordagem um-contra-alguns considera-se somente um subconjunto dos indivíduos como classe negativa, na abordagem um-contra-todos utiliza-se todos os indivíduos restantes. No entanto, quando se considera apenas um subconjunto de indivíduos na classe negativa, a adição de novos indivíduos não requer a reconstrução de modelos previamente criados, o que permite a manutenção dinâmica da galeria. O diagrama da Figura 2(b) mostra os passos seguidos pelo método um-contra-alguns, discutidos a seguir.

Pode ser visto no diagrama da Figura 2(b) que, por um lado, na abordagem um-contra-alguns é considerado um subconjunto dos indivíduos como classe negativa, ao invés de todos os indivíduos restantes. Desse modo, não é necessário conhecer todos os indivíduos no momento da adição de um novo indivíduo. Entretanto, por outro lado, mais que um modelo é criado, considerando-se um dado indivíduo como amostra positiva. Assim, haverá mais de uma resposta da regressão para cada indivíduo e, como na técnica um-contra-todos, o indivíduo associado com a maior resposta é considerado como a melhor escolha para a amostra testada.

Assim sendo, para a criação da galeria inicial (contendo todos os  $N$  indivíduos conhecidos até o momento), calcula-se



(a) Abordagem anterior: um-contra-todos.

(b) Abordagem proposta: um-contra-alguns.

Figura 2: Diagramas dos métodos de classificação um-contra-todos e um-contra-alguns. (a) técnica um-contra-todos para cada indivíduo; (b) técnica um-contra-alguns para cada indivíduo – após a escolha do subconjunto dos indivíduos restantes, aplica-se o método um-contra-todos.

$N \times k$  modelos PLS, em que  $k - 1$  é o número de amostras negativas em cada modelo. Escolhe-se aleatoriamente quais serão os  $k - 1$  indivíduos utilizados em cada modelo, procurando-se manter os indivíduos uniformemente distribuídos. Além disso,  $k \ll N$  e é estimado experimentalmente.

Quando um novo indivíduo é adicionado à galeria,  $k$  novos modelos PLS são computados, contendo amostras deste indivíduo como classe positiva e um subconjunto aleatoriamente escolhido de  $k$  indivíduos na classe negativa. Devido à característica de apenas um subconjunto de indivíduos ser considerado, não há a necessidade de se reconstruir os modelos como no esquema de classificação um-contra-todos.

Devido à criação de  $k$  modelos PLS para adição de um novo indivíduo, a execução do casamento de uma amostra de teste utilizando uma busca ingênua levaria ao teste de todos os modelos um-contra-alguns criados anteriormente, acarretando um total de  $N \times k$  projeções, em contraste com  $N$  projeções necessárias quando se utiliza o esquema um-contra-todos. Assim, uma técnica mais eficiente para o uso dos modelos criados durante o teste de uma imagem se fez necessária.

Com o objetivo de se obter uma técnica para guiar a busca, evitando o desperdício de computação com indivíduos que certamente não contribuiriam mais para o processo de identificação, propõe-se um método baseado em fila de prioridades, em que apenas os modelos que possuem indivíduos com alta chance de apresentarem casamento correto são considerados no teste. O Algoritmo 1 resume o funcionamento da busca em conjunto com a fila de prioridades.

Contudo, somente o uso da fila não economizaria tempo de processamento, pois, sem condição de parada alguma, ainda testaria todos os modelos existentes. Desse modo, foram adicionadas algumas condições de parada, entre as quais:

#### Algoritmo 1: Busca e fila de prioridades

##### Inicialização:

- inicializa a fila com valores nulos;
- escolhe aleatoriamente um indivíduo;
- seleciona e marca um modelo que contenha o indivíduo;
- projeta a face de teste nesse modelo;
- atualiza a fila com as respostas obtidas que forem menores do que a prioridade atual;
- ordena decendentemente a fila;

##### Laço principal:

**enquanto** há indivíduos sem resposta na fila **faça**

- seleciona primeiro indivíduo da fila;
- se** houver modelos desmarcados do indivíduo **então**
  - escolhe modelo desmarcado que contenha o indivíduo;

**senão**

- sai do laço;
- projeta face de teste nesse modelo e marca-o;
- adiciona as respostas na fila, se forem mínimas;
- ordena decendentemente a fila;

- o primeiro indivíduo da fila é o casamento correto da amostra de teste.

- a avaliação pelo menos uma única vez de todos os indivíduos da galeria.
- todos os modelos que contenham o primeiro elemento da fila serem avaliados.

Colabora para o funcionamento das condições o fato de a prioridade ser definida pelo mínimo dentre as respostas obtidas até então para um dado indivíduo, pois independe, assim, do número de avaliações realizadas. Para a segunda condição, o

fato de as respostas obtidas por meio das regressões PLS serem fortemente positivas para o indivíduo correto e negativas para as demais é fundamental.

A principal vantagem do método de classificação um-contra-alguns está em que, quando um novo indivíduo  $j$  é apresentado ao sistema, os modelos existentes não precisam ser reconstruídos ao se considerar o novo sujeito, como era necessário na abordagem original. Alguns modelos PLS considerando  $j$  como classe positiva são construídos, escolhendo-se subconjuntos aleatórios dos indivíduos já processados para representar a classe negativa. A próxima seção descreve os resultados alcançados a partir desta modificação na técnica de classificação um-contra-todos e pela adição da fila de prioridades.

#### IV. RESULTADOS EXPERIMENTAIS

Esta seção avalia alguns aspectos do método proposto. Primeiramente, resultados obtidos com a abordagem um-contra-alguns com fila de prioridade, descrita na seção III-B, são mostrados e comparados com outros métodos disponíveis na literatura. Em seguida, uma comparação entre os tempos de inserção de novos indivíduos entre o método um-contra-todos original e o proposto um-contra-alguns e os ganhos obtidos são apresentados e discutidos.

Os experimentos foram conduzidos em um processador Intel Core i7-860, 2,8GHz com 8GB de RAM e com sistema operacional Linux. A implementação foi realizada no MATLAB 7.12.0.

Para os experimentos, utilizou-se o conjunto de dados FRGC versão 1 [25]. A principal característica deste conjunto de dados é de ser composto de faces adquiridas em condições sem controle, buscando aproximar os testes de um ambiente real. Os testes consideraram apenas o experimento 4 do FRGC, que é o mais difícil dos quatro e é composto por 152 classes na galeria (contém número diferente de amostras por classe) e 608 imagens de teste extraídas sem controle de aquisição.

##### A. Taxa de Reconhecimento

Este experimento visa testar a eficiência do método proposto quanto à taxa de reconhecimento, ainda sem a inserção de novos indivíduos. Para tal, criou-se a galeria com todos os indivíduos e executou-se os testes sobre ela. A Tabela I contém os valores obtidos para o experimento 4 descrito no FRGC para diversos métodos da literatura. O experimento seguiu o protocolo aplicado em [4]. O parâmetro  $k = 9$  foi utilizado que, a partir da Figura 3(a), representa o valor que retorna melhor valor de acurácia e ainda apresenta um custo computacional aceitável. Na criação da galeria, utilizou-se 13 fatores para os modelos PLS. A taxa de reconhecimento obtida foi 84,4%, valor próximo ao método um-contra-todos.

Embora a taxa de reconhecimento seja menor que àquela obtida pelo método um-contra-todos, o tempo para adição de novos indivíduos é bem menor, conforme discutido na próxima seção, o que possibilita a manutenção dinâmica da galeria.

Tabela I: Taxas de reconhecimento, em porcentagem, obtidas para o experimento 4 do conjunto de dados FRGC.

Método	Experimento 4
LPQ [16]	74,5%
LC <sub>1</sub> C <sub>2</sub> [15]	75,0%
ROCA [19]	75,5%
PLS um-contra-todos [4]	86,2%
PLS um-contra-alguns	84,4%

##### B. Inserção de Novos Indivíduos

Experimentou-se a capacidade do método proposto para a inserção de novos indivíduos incrementalmente em uma galeria existente e comparou-se com o método original. Assim, uma galeria inicial pequena foi criada (8 indivíduos para  $k = 3, 5, 7$  e 16 indivíduos para  $k = 9$ ).

A Figura 3 mostra gráficos com diferentes características do método um-contra-alguns para diferentes parâmetros com o método um-contra-todos. No experimento (a), os valores finais de taxa de reconhecimento foram de 83,88% para o método proposto, ou seja, mesmo quando incremental, não há perdas significativas, uma vez que o método um-contra-todos obteve 87,30%. No experimento relacionado ao tempo de adição em (b), percebe-se que, enquanto o método original (um-contra-todos) possui comportamento quadrático, o método proposto tem comportamento constante, o que apresenta um ganho significativo, possibilitando a manutenção dinâmica da galeria.

A partir dos gráficos mostrados nas Figuras 3 (c) e (d), o comportamento assintótico das duas abordagens é o mesmo, embora a abordagem um-contra-alguns apresente maior custo computacional para testar amostras de teste. Percebe-se que a utilização da fila de prioridades proporcionou uma certa redução do número de projeções.

#### V. CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho propôs uma nova abordagem para a manutenção de galeria de faces, com uma simples alteração do método um-contra-todos, ao se criar modelos um-contra-alguns. Essa alteração mostrou-se eficaz para o processo de identificação de faces escalável quanto à adição incremental de novos indivíduos, reduzindo um processo quadrático para um que é constante.

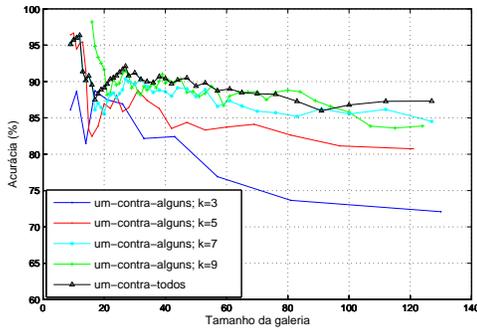
Como aprimoramento do método, empregou-se uma fila de prioridades durante a avaliação da galeria, a qual permitiu reduzir ainda mais as projeções necessárias. Esta redução será o foco de investigações futuras.

#### VI. AGRADECIMENTOS

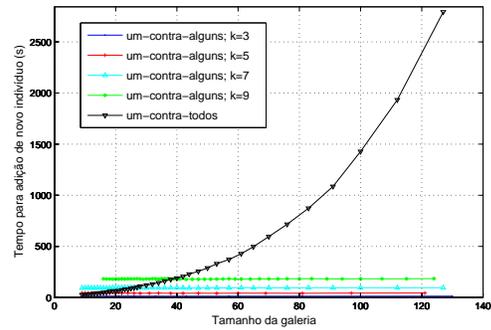
Os autores são gratos à FAPESP pelo apoio financeiro.

#### REFERÊNCIAS

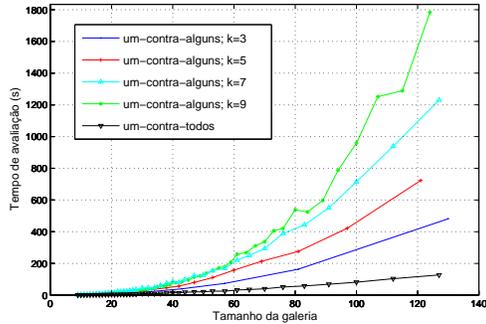
- [1] R. Chellappa, P. Sinha, and P. Phillips, "Face Recognition by Computers and Humans," *Computer*, vol. 43, no. 2, pp. 46–55, 2010.
- [2] X. Zhang and Y. Gao, "Face Recognition Across Pose: A Review," *Pattern Recognition*, vol. 42, no. 11, pp. 2876–2896, 2009.
- [3] A. F. Abate, M. Nappi, D. Riccio, and G. Sabatino, "2D and 3D Face Recognition: A Survey," *Pattern Recognition Letters*, vol. 28, no. 14, pp. 1885–1906, 2007.



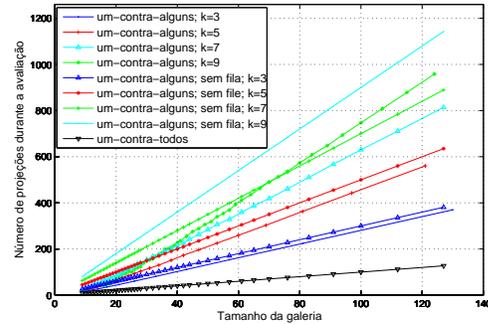
(a) Taxa de reconhecimento.



(b) Tempo de adição de 1 novo indivíduo.



(c) Tempo de avaliação das amostras de teste.



(d) Número de projeções para avaliação das amostras de teste.

Figura 3: Gráficos dos experimentos realizados sobre a adição incremental de indivíduos na galeria, comparando diferentes valores de  $k$  com o método um-contra-todos. (a) taxa de reconhecimento (em percentagem) dos métodos; (b) tempo (em segundos) para a adição de um novo indivíduo; (c) tempo (em segundos) para a avaliação de amostras de teste; (d) número médio de projeções por amostra durante a avaliação do conjunto de teste - aqui também foi comparado o método caso não utilizasse a fila de prioridades.

[4] W. R. Schwartz, H. Guo, J. Choi, and L. S. Davis, "Face Identification Using Large Feature Sets," *IEEE Trans. on Image Processing*, vol. 21, no. 4, pp. 2245–2255, 2012.

[5] L. Elden, "Partial Least Squares vs. Lanczos Bidiagonalization—I: Analysis of a Projection Method for Multiple Regression," *Computational Statistics & Data Analysis*, vol. 46, no. 1, pp. 11 – 31, 2004.

[6] R. Rosipal and N. Kramer, "Overview and Recent Advances in Partial Least Squares," *Lecture Notes in Computer Science*, vol. 3940, pp. 34–51, 2006.

[7] H. Wold, "Partial Least Squares," in *Encyclopedia of Statistical Sciences*, S. Kotz and N. Johnson, Eds. New York: Wiley, 1985, vol. 6, pp. 581–591.

[8] A. Tolba, A. El-Baz, and A. El-Harby, "Face Recognition: A Literature Review," *International Journal of Signal Processing*, vol. 2, pp. 88–103, 2006.

[9] W. Zhao, R. Chellappa, P. J. Phillips, and A. Rosenfeld, "Face Recognition: A Literature Survey," *ACM Computing Surveys*, vol. 35, no. 4, pp. 399–458, 2003.

[10] J. Zou, Q. Ji, and G. Nagy, "A Comparative Study of Local Matching Approach for Face Recognition," *IEEE Trans. on Image Processing*, vol. 16, pp. 2617–2628, 2007.

[11] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification*. John Wiley & Sons, 2001.

[12] W. Zhang, S. Shan, W. Gao, X. Chen, and H. Zhang, "Local Gabor Binary Pattern Histogram Sequence (LGBPHS): A Novel Non-Statistical Model for Face Representation and Recognition," in *IEEE Intl. Conference on Computer Vision*, 2005, pp. 786–791.

[13] X. Tan and B. Triggs, "Enhanced Local Texture Feature Sets for Face Recognition under Difficult Lighting Conditions," in *IEEE Intl. Conference on Automatic Face and Gesture Recognition*, 2007, pp. 168–182.

[14] G. Aggarwal, S. Biswas, and R. Chellappa, "UMD Experiments with FRGC Data," in *IEEE Computer Vision and Pattern Recognition Workshops*, 2005, pp. 172–178.

[15] P. Shih and C. Liu, "Evolving Effective Color Features for Improving FRGC Baseline Performance," in *IEEE Computer Vision and Pattern Recognition Workshops*, 2005, pp. 156–163.

[16] V. Ojansivu, E. Rahtu, and J. Heikkilä, "Rotation Invariant Local Phase Quantization for Blur Insensitive Texture Analysis," in *International Conference on Pattern Recognition*, 2008.

[17] X. Tan, S. Chen, Z. Zhou, and F. Zhang, "Face Recognition from a Single Image per Person: A Survey," *Pattern Recognition*, vol. 39, pp. 1725–1745, 2006.

[18] J. Liu, S. Chen, Z. Zhou, and X. Tan, "Single Image Subspace for Face Recognition," in *IEEE Intl. Conference on Automatic Face and Gesture Recognition*, 2007, pp. 205–219.

[19] F. D. la Torre, R. Gross, S. Baker, and V. Kumar, "Representational Oriented Component Analysis (ROCA) for Face Recognition with One Sample Image per Training Class," in *IEEE Intl. Conference on Computer Vision and Pattern Recognition*, vol. 2, 2005, pp. 266 – 273.

[20] Q. Yuan, A. Thangali, and S. Sclaroff, "Face Identification by a Cascade of Rejection Classifiers," in *IEEE Computer Vision and Pattern Recognition Workshops*, 2005, pp. 152–159.

[21] G.-D. Guo and H.-J. Zhang, "Boosting for Fast Face Recognition," in *IEEE Intl. Conference on Computer Vision Workshops*, 2001.

[22] N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection," in *IEEE Conference on Computer Vision and Pattern Recognition*, 2005, pp. 886–893.

[23] T. Ahonen, A. Hadid, and M. Pietikainen, "Face Recognition with Local Binary Patterns," in *European Conference on Computer Vision*, ser. 35, 2004, pp. 469–481.

[24] W. R. Schwartz and L. S. Davis, "Learning Discriminative Appearance-Based Models Using Partial Least Squares," in *XXII Brazilian Symposium on Computer Graphics and Image Processing*, 2009.

[25] P. J. Phillips, P. J. Flynn, T. Scruggs, K. W. Bowyer, J. C., K. Hoffman, J. Marques, J. Min, and W. Worek, "Overview of the Face Recognition Grand Challenge," in *IEEE Intl. Conference on Computer Vision and Pattern Recognition*, 2005, pp. 947–954.