

Reconhecimento facial utilizando Floresta de Caminhos Ótimos e algoritmos de votação

Jair José da Silva, Luis Mariano del Val Cura

Faculdade Campo Limpo Paulista (FACCAMP)
Campo Limpo Paulista – SP – Brazil
silvajj.cc@gmail.com, delval@cc.faccamp.br

Abstract. *This paper presents experimental results of a facial recognition algorithm based on the Optimum Path Forest (OPF) classifier using voting methods. In this approach feature vectors are extracted from the difference image built by comparing two facial images. The facial recognition algorithm classifies feature vectors in two classes: the class of difference images of the same individual (intrapersonal class) and the class of difference images of different individuals (interpersonal class). The classification process integrates the results of multiple classifiers using voting methods.*

Resumo. *Este artigo apresenta resultados experimentais de uma proposta de algoritmo de reconhecimento facial baseado no classificador supervisionado Floresta de Caminhos Ótimos (OPF) com o uso de métodos de votação. Nesta proposta, o vetor de características é extraído da imagem diferença resultante de duas imagens faciais comparadas. Para verificar se as imagens comparadas pertencem ao mesmo indivíduo, este descritor diferença é classificado em duas classes: a classe que representa imagens diferença do mesmo indivíduo (classe intrapessoal) e a classe que representa imagens diferença de indivíduos diferentes (classe interpessoal). Para este processo de classificação o trabalho propõe o uso de múltiplos classificadores que integram seus resultados através de algoritmos de votação.*

1. INTRODUÇÃO

Algoritmos convencionais de reconhecimento facial extraem das imagens da face descritores em forma de vetores de características, que representam as propriedades que permitem a identificação dos humanos [Jain et al. 2007]. Geralmente, o reconhecimento facial é realizado comparando o descritor obtido de uma imagem de consulta com o descritor de uma imagem alvo, atribuindo-se a esta comparação um valor de similaridade. Este valor de similaridade é comparado com um valor limiar de decisão prefixado para decidir se as imagens pertencem ou não ao mesmo indivíduo. Quando a comparação é realizada entre descritores do mesmo indivíduo temos uma comparação genuína e caso contrário, temos uma comparação impostora.

Uma abordagem diferente, apresentada pela primeira vez em [Moghaddam et al. 2000], realiza a comparação subtraindo primeiramente as imagens de consulta e alvo e extraindo posteriormente um vetor de características desta imagem diferença. Para realizar o reconhecimento facial, este vetor de característica precisa ser classificado

como correspondente a uma imagem diferença da classe intrapessoal (comparação genuína) ou da classe interpessoal (comparação impostora). A hipótese desta proposta é que as imagens diferenças de imagens do mesmo indivíduo possuem características diferentes das imagens diferenças de imagens de indivíduos diferentes. O reconhecimento facial em [Moghaddam et al. 2000] é realizado então através de um classificador bayesiano que estima o valor da probabilidade de que o descritor da imagem diferença pertença à classe intrapessoal. Este valor é utilizado como similaridade para, a partir do limiar de decisão, determinar se as imagens de consulta e alvo pertencem ou não ao mesmo indivíduo.

O uso de um classificador bayesiano em vetores de alta dimensionalidade, como é o caso de descritores biométricos, impõe um alto custo computacional, tanto no treinamento do classificador como no processo de classificação. Adicionalmente, exige distribuição normal e separação linear das classes intrapessoal e interpessoal.

Neste trabalho propomos a utilização do classificador Floresta de Caminhos Ótimos (OPF) [Papa et al. 2009] que não impõe condições na distribuição dos descritores biométricos. Adicionalmente, neste trabalho introduzimos a classificação por votação proposta em [Ponti-Jr et al. 2011], na qual são criados n classificadores OPFs independentes, e a classificação final é obtida pela integração por votação dos resultados de cada um deles.

Como parte da pesquisa foram realizados experimentos com descritores biométricos obtidos pelos métodos de extração de características faciais eigenfaces [Turk et al. 1991] e casamento de grafos elásticos, ou EBGM [Wiskott et al. 1997].

O artigo está organizado como segue: a Seção 2 apresenta o classificador Floresta de Caminhos Ótimos (OPF) e a abordagem de votação, a Seção 3 descreve a adaptação e uso do classificador OPF como algoritmo biométrico, a seguir na Seção 4 são apresentados os resultados experimentais obtidos, e finalmente na Seção 5 temos as conclusões e trabalhos futuros.

2. O CLASSIFICADOR FLORESTA DE CAMINHOS ÓTIMOS E A ABORDAGEM DE VOTAÇÃO

Classificadores são algoritmos de aprendizado de máquina que conseguem associar uma determinada amostra, o descritor, a uma dentre n classes previamente definidas. No caso de classificadores supervisionados o algoritmo recebe, em uma fase de treinamento, um conjunto de descritores previamente associados a suas classes. Com este conjunto de treinamento o algoritmo deve aprender as características de cada classe para posteriormente na fase de teste, associar novos descritores a essas classes já definidas.

O algoritmo supervisionado Floresta de Caminhos Ótimos (OPF), proposto por Papa [Papa et al. 2009] constrói um classificador. Na fase de aprendizado o algoritmo constrói inicialmente um grafo completo no qual os nós são os descritores previamente rotulados em uma das classes e as arestas são rotuladas com as distâncias entre esses descritores, como mostra a Figura 1(a). Para o cálculo dos rótulos das arestas é usada uma função de distância e, via de regra, a distância euclidiana é empregada.

A partir do grafo completo o algoritmo prossegue construindo a Árvore

Geradora Mínima (MST) como mostra a Figura 1(b). O algoritmo percorre a MST e marca os nós protótipos, que são aqueles que estão unidos por arestas que conectam nós de classes diferentes (nós B e D em Figura 1(b)). Na sequência é realizado um processo de conquista em que os nós protótipos atribuem suas classes a outros nós do grafo usando um critério baseado em distância. Neste processo de conquista os nós protótipos recebem o valor zero e os outros um valor infinito. O primeiro nó (protótipo) consultará todos os outros nós conectados a ele aplicando a função do máximo valor entre seu valor e o custo da aresta. Em seguida é aplicada a função mínima entre o valor de retorno da função máximo e valor do nó a ser conquistado. O nó que for conquistado receberá valor do resultado das funções e o nome da classe do nó que ofereceu o melhor valor, como apresentado na Figura 1(c). Após percorrer todos os nós do grafo o algoritmo retornará uma floresta com várias árvores que representam as classes que




Figura 1. Etapas de construção do OPF: (a) Grafo completo (b) Árvore Geradora Mínima (c) O protótipo B conquista o nó A e o protótipo D conquista o nó C.

formam o grafo de treinamento, denominado OPF.

Para classificar um novo descritor, cada nó do OPF inicia um processo de conquista do descritor realizando o mesmo procedimento utilizado no treinamento. O novo descritor é rotulado com a classe associada ao nó que o conquistou.

Uma abordagem do algoritmo OPF utilizando um processo de votação foi proposta em [Ponti-Jr et al. 2011]. Nesta abordagem, o conjunto de treinamento é dividido em n subconjuntos e para cada um deles é construído um classificador OPF independente. Na fase de teste, um novo descritor é apresentado a cada classificador que associa o descritor a uma classe. Um algoritmo de votação toma uma decisão final sobre a classe desse novo descritor a partir da integração dos resultados de cada um dos classificadores.

3. PROPOSTA DO CLASSIFICADOR OPF COMO ALGORITMO BIOMÉTRICO

Este trabalho propõe o uso do classificador OPF para avaliar a relação com as classes intrapessoal e interpessoal de um descritor extraído da diferença de duas imagens. O classificador é treinado com um conjunto de descritores, gerados com imagens diferenças de indivíduos iguais e de indivíduos diferentes. Este treinamento gera duas classes, a classe intrapessoal e a classe interpessoal, respectivamente.

Se utilizarmos o algoritmo OPF em sua forma original, ele classificará um descritor de diferença em uma das classes intrapessoal e interpessoal, dependendo de qual dessas duas classes o conquiste. Para utilizar o algoritmo OPF como algoritmo biométrico, precisamos que em vez de classificar, ele retorne um valor que estime a relação da imagem diferença com as duas classes, isto é, que estime a similaridade das

imagens que foram subtraídas para construir o descritor.

Dado um descritor diferença $F_{n,m}$ obtido da diferença entre as imagens I_n e I_m , e dadas as classes X (intrapessoal) e Y (interpessoal), a função de similaridade entre I_n e I_m é definida pela Equação (1).

$$\text{sim}(I_n, I_m) = 1 - d(F_{n,m}, X) / (d(F_{n,m}, X) + d(F_{n,m}, Y)) \quad (1)$$

Onde $d(F_{n,m}, X)$ e $d(F_{n,m}, Y)$ representam a menor distância do descritor $F_{n,m}$ até os nós protótipos das classes intrapessoal e interpessoal, respectivamente.

Para nossa pesquisa, utilizamos duas metodologias de votação: a média tradicional e a média corrigida, sendo que esta média corrigida elimina do cálculo o maior e o menor valor obtido. Neste trabalho, a média será referenciada como média absoluta e a média corrigida, como média parcial.

4. RESULTADOS EXPERIMENTAIS OBTIDOS

Nos experimentos realizados foram utilizados vetores de imagens faciais, do Banco de Dados FERET [Phillips et al. 2000]. A base para treinamento foi criada com 65 indivíduos com 6 imagens para cada um deles, permitindo gerar 975 descritores diferença genuínos (65 x 6) e 2080 descritores diferença impostores. A base de testes foi criada com 50 indivíduos com 4 imagens para cada um, o que permitiu criar 300 descritores diferença genuínos (50 x 4) e utilizamos 1274 descritores diferença impostores. Para criar estes descritores diferença foram utilizados os métodos EBGM [Wiskott et al. 1997] e Eigenfaces [Turk&Pentland1991]. Como função de distância para o classificador OPF foi utilizada a distância euclidiana. Para a classificação por votação foram utilizados os métodos da média absoluta e da média parcial e foram utilizados dez, quinze, vinte, vinte cinco e cinquenta conjuntos OPFs, além do OPF tradicional com um conjunto. Os conjuntos OPFs utilizados foram os que apresentaram os melhores resultados nos testes que realizamos. Por este motivo resolvemos apresentar apenas estes resultados em nosso trabalho.

Para avaliar a acurácia do classificador OPF utilizamos as métricas biométricas [Jain et al. 2007]. O ERR (Equal Error Rate) é métrica biométrica onde a taxa dos erros das amostras genuínas são iguais à taxa dos erros das amostras impostoras; para a métrica FMR100 (False Matching Rate) temos a taxa dos erros das amostras genuínas onde o erro das amostras impostoras é 0,01; a FMR1000 é o erro das amostras genuínas onde o erro das amostras impostoras é 0,001; e o FMRZero é a taxa das amostras genuínas onde o erro das amostras impostoras é zero.

A Tabela 1 e o Gráfico 1 mostram os resultados obtidos com descritores EBGM utilizando o algoritmo de votação de média absoluta. A primeira coluna da tabela mostra a quantidade de classificadores OPF utilizados pelos algoritmos de votação. O Gráfico 1 mostra as curvas ROCs sendo que cada curva representa uma quantidade diferente de classificadores. O melhor resultado de EER é obtido com a votação de 50 classificadores embora não possui os melhores resultados para FMRs. Na FMR100 o melhor resultado é obtido com 15 classificadores. Na FMR1000, exceto com 50

classificadores, todos os outros testes ficam próximos ao valor para um único classificador. Já para o FMRZero, podemos considerar melhores resultados para 15 classificadores e um único classificador.

Tabela 1. Métricas EER, FMR100, FMR1000 e FMRZero dos OPFs classificando amostras EBGM, utilizando o método de votação da média absoluta.

Classificadores	EER	FMR100	FMR1000	FMRZero
OPF01	0,268718	0,595897	0,694359	0,714872
OPF10	0,24831	0,600616	0,705339	0,735113
OPF15	0,247433	0,577002	0,703285	0,715606
OPF20	0,251507	0,602669	0,708419	0,725873
OPF25	0,251507	0,602669	0,708419	0,725873
OPF50	0,23614	0,619097	0,722793	0,737166

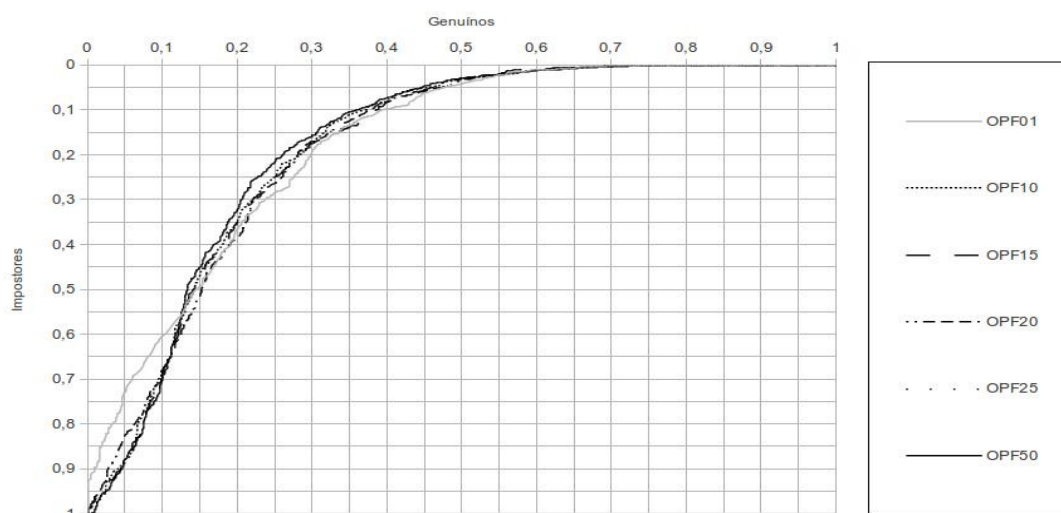


Gráfico 1. Curvas ROCs dos OPFs classificando amostras do EBGM, utilizando o método de votação da média absoluta.

A Tabela 2 e Gráfico 2 mostram as métricas calculadas do EER e FMR para descritores EBGM utilizando o método de votação da média parcial.

Estes resultados da Tabela 2 mostram que para a EER o melhor resultado é obtido com 50 classificadores. Para as métricas FMR100 e FMR1000 os melhores resultados foram obtidos com 15 classificadores. No caso do FMRZero, o uso de 15 classificadores continua com o melhor resultado, mas similar ao uso de um único classificador. Estes resultados são muito similares aos obtidos para o método de votação de média absoluta.

Tabela 2. Resultados com descritores do método EBGM com votação por média parcial.

Algoritmo	ERR	FMR100	FMR1000	FMRZero
OPF01	0,268718	0,595897	0,694359	0,714872
OPF10	0,249755	0,596509	0,704312	0,741273
OPF15	0,249442	0,572895	0,691992	0,715606
OPF20	0,256674	0,600616	0,707392	0,726899
OPF25	0,256674	0,600616	0,707392	0,726899
OPF50	0,236989	0,612936	0,722793	0,738193




Gráfico 2. Curvas ROCs dos OPFs classificando amostras do EBGm, utilizando o método de votação da média parcial.

A Tabela 3 e Tabela 4, assim como o Gráfico 3 e Gráfico 4, mostram resultados trabalhando com descritores do método *Eigenfaces*.

Tabela 3. Resultados com descritores do método Eigenfaces com votação por média absoluta.

Algoritmo	ERR	FMR100	FMR1000	FMRZero
OPF01	0,36975	0,850112	0,911633	0,911633
OPF10	0,350899	0,702128	0,790594	0,829787
OPF15	0,358225	0,706607	0,759239	0,797312
OPF20	0,31019	0,68533	0,772676	0,792833
OPF25	0,319054	0,697648	0,786114	0,818589
OPF50	0,317845	0,674132	0,743561	0,769317




Gráfico 3. Curvas ROCs dos OPFs classificando amostras do eigenfaces, utilizando o método de votação da média absoluta.

A Tabela 3 e o Gráfico 3 apresentam o desempenho do algoritmo utilizando o

método de votação da média absoluta e a Tabela 4 e o Gráfico 4 os resultados com votação por média parcial.

A Tabela 3 e Gráfico 3 mostram que com o uso do algoritmo de votação de média absoluta para a EER o melhor resultado é conseguido com 20 classificadores. Já para FMR100, o FMR1000 e FMRZero o melhor resultado foi alcançado com 50 classificadores.

A Tabela 4 e o Gráfico 4 mostram os resultados com algoritmo de votação de média parcial. Podemos ver que para a EER temos o uso de 20 classificadores consegue o melhor resultado, e para o FMR100, FMR1000 e FMRZero repetindo o melhor resultado é conseguido com 50 classificadores, sendo os resultados similares aos da média absoluta.

Tabela 4. Resultados com descritores do método Eigenfaces com votação por média parcial

Algoritmo	ERR	FMR100	FMR1000	FMRZero
OPF01	0,36975	0,850112	0,911633	0,911633
OPF10	0,346173	0,699888	0,786114	0,818589
OPF15	0,351248	0,704367	0,770437	0,797312
OPF20	0,311639	0,690929	0,790594	0,793953
OPF25	0,320308	0,699888	0,792833	0,818589
OPF50	0,318176	0,675252	0,745801	0,769317




Gráfico 4. Curvas ROCs dos OPFs classificando amostras do eigenfaces, utilizando o método de votação da média parcial.

A partir dos resultados podemos concluir que o uso de múltiplos classificadores no método contribui para a melhora dos resultados do ERR quando comparado com o uso de um único classificador. Nos casos das métricas FMR a introdução de múltiplos classificadores, tem resultados muito próximos dos resultados do algoritmo com um único classificador.

No caso do método Eigenfaces a introdução de múltiplos classificadores contribui com uma melhora importante em todas as métricas sendo que o uso de 20 classificadores obtém o melhor valor de ERR e o uso de 50 classificadores para as métricas FMR.

Estes resultados mostram que o uso de múltiplos classificadores com algoritmos de votação pode potencializar em todos os casos a melhora do EER que é a métrica mais valorizada nos algoritmos biométricos. No caso do método de Eigenfaces, o uso de múltiplos classificadores potencializa todas as métricas em relação ao OPF tradicional.

5. CONCLUSÕES E TRABALHOS FUTUROS

Este artigo apresentou o uso do classificador Floresta de Caminhos Ótimos para reconhecimento facial com uso de algoritmos de votação. Foram realizados experimentos com descritores obtidos dos métodos EBGM e Eigenfaces. Foram utilizados dois algoritmos de votação: média absoluta e média parcial. Os resultados mostram que o uso de múltiplos classificadores contribui em todos os casos para a melhora da métrica EER e também para as outras no caso de descritores do método EBGM. Estes resultados sugerem que o uso de múltiplos classificadores pode potencializar a capacidade de reconhecimento do método de reconhecimento facial quando utilizada a abordagem por classificação em classes intrapessoal e interpessoal.

Em trabalhos futuros, serão pesquisados outros descritores de reconhecimento facial para verificar se a potencialização dos resultados se manifesta em outros métodos. Adicionalmente, pretende-se pesquisar outras métricas de similaridade para a criação dos classificadores OPF, assim como outros métodos de votação.

6. REFERENCIAS

- Jain, A. K., Flynn, P., Ross, A. (2007) "Handbook of Biometrics" – Springer Science Business Media, LLC, 233 Spring Street, New York, NY 10013, USA.
- Moghaddam, T., Jebara, T., Pentland, A. (2000) "Bayesian face recognition", *Pattern Recognition*, 33(11), pp 1771-1782.
- Papa, J.P., Falcão, A.X., Suzuki, C.T.N. (2009) "Supervised pattern classification based on optimum-path forest", *International Journal of Imaging Systems and Technology*, USA, 19(2) , pp 120-131.
- Phillips, P. J., Moon, H., Rizvi, S.A., Rauss, P.J. (2000) "The FERET evaluation methodology for face recognition algorithms", *IEEE Trans. PatternAnalysisandMachineIntelligence*, 22(10), pp1090-1104.
- Ponti-Jr, M.P., Papa, J.P. (2011) "Improving accuracy and speed of Optimum-Path Forest classifier using combination of disjoint training subsets". *Proceedings of the 10th International Workshop on Multiple Classifier Systems, MCS 2011, USA.*
- Turk, M., Pentland, A. (1991) "Face recognition using eigenfaces", *Proc. IEEE Conference on Computer Vision and Pattern Recognition*, pp. 586–591.
- Wiskott, L., Fellous, J.M., Krüger, N., Malsburg, C. (1997) "Face recognition by elastic bunch graph matching", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(7), pp 775-779.