

SeMicro-PR 2018

Sistema biométrico de verificação baseado nas veias da palma da mão

F. G. Gonçalves Camargo¹, G. L. Barboza¹, G. L. F. Ronque¹

¹UFPR, Curitiba, Brasil
guilbz98@gmail.com

Resumo— O uso da biometria como método de identificação e verificação pessoal vem se disseminando pois alia facilidade e segurança. Entretanto, a experiência tem mostrado que atualmente não existe uma única biometria perfeita capaz de ser utilizada em todas as situações. Neste âmbito, a análise de veias tem emergido como uma tecnologia promissora. Este trabalho apresenta um sistema biométrico de verificação baseado nas veias da palma da mão capaz de fornecer uma Taxa de Erros Iguais (EER) de 1,0667% medidos nas imagens do banco CASIA-MS-Palmprint V1.0, utilizando 5 amostras de treinamento. Empregou-se o descritor de textura HOG (Histogram of Oriented Gradients) em conjunto com fusão de primitivas e classificador SVM (Support Vector Machine) linear. O trabalho ainda compara o desempenho do descritor LPQ (Local Phase Quantization), o impacto do número de amostras de treinamento e a importância da escolha do kernel no classificador SVM.

I. INTRODUÇÃO

Os termos reconhecimento biométrico ou simplesmente biometria referem-se às tecnologias empregadas ao reconhecimento automático de um indivíduo baseado apenas em suas características fisiológicas e/ou comportamentais. O emprego da biometria estabelece a identidade do indivíduo através de quem ele é e não pelo que ele possui ou se lembra [1]. Com a evolução da tecnologia, a biometria trouxe também uma forma conveniente e segura de identificar pessoas e gradualmente vem substituindo ou se somando aos métodos tradicionais de identificação como senhas e assinaturas.

Da mão é possível extrair diversas características como a impressão digital, a geometria da mão, a impressão palmar, veias do dorso da mão, veia dos dedos e veias da palma. Embora a impressão digital seja a biometria de fato e a mais presente no dia-a-dia, ela sofre com algumas limitações. Contudo, novas tecnologias vêm emergindo e se provando mais seguras e suficientemente versáteis para se tornarem também um padrão [2]. Este é o caso da biometria baseada no padrão das veias da palma da mão [3], que já vem sendo utilizada no Brasil e no mundo para autenticação em caixas eletrônicas[4].

Este artigo propõem um sistema biométrico de verificação baseado nas veias da palma da mão utilizando

como primitivas dois descritores de textura, HOG (Histogram of Oriented Gradients) Triggs [8] e LPQ (Local Phase Quantization) Ojansivu [7]. Analisou-se também os classificadores SVM linear e RBF (Radial Basis Function).

II. MATERIAIS E MÉTODOS

A. Base de dados

A pesquisa desenvolvida neste artigo utiliza o banco de dados CASIA-MS-PalmprintV1 [5] coletado pelo Chinese Academy of Sciences Institute of Automation (CASIA). O banco contém 7200 imagens capturadas de 100 pessoas diferentes usando um equipamento multispectral desenvolvido pelos autores. São capturadas seis amostras de cada pessoa para ambas as mãos. Cada amostra contém seis imagens as quais foram capturadas ao mesmo tempo em espectros eletromagnéticos diferentes: 460, 630, 700, 850, 940 nm e luz branca. As imagens possuem resolução de 72 dpi com 8 bits de níveis de cinza.

Durante a aquisição das imagens, não foi solicitado ao voluntário apoiar a mão no equipamento desenvolvido para aquisição das amostras e, portanto, existe diferença de profundidade e/ou variação da inclinação dos dedos em algumas instâncias. Neste estudo, foram utilizadas apenas as imagens dos espectros de 850 e de 940 nm em que é possível processar as veias da palma.

B. Extração da região de interesse

A extração da região de interesse foi inspirada no trabalho de [6], diferenciando-se pela estratégia empregada na segmentação da palma da mão e na metodologia utilizada para a extração dos pontos chave necessários para a localização da ROI (Region of Interest).

Existem alguns desafios ao se segmentar as imagens do banco CASIA. O primeiro é que embora o equipamento esteja dentro de uma caixa preta existe uma abertura onde o usuário deve colocar a mão que permite a entrada de luz exterior, causando o aparecimento de uma região clara indesejável na base da mão. Além disso, o usuário tem autonomia para posicionar a mão dentro da caixa de aquisição e em muitos casos além da mão, encontramos partes significativas do braço, pulseiras, relógios e mangas

de blusa. Assim, o algoritmo de segmentação da mão deve ser robusto não só às variações de posicionamento da mão como também ser capaz de remover os pontos de entrada de luz externa e partes indesejadas do braço.

C. Segmentação da mão

Uma análise inicial das imagens do banco CASIA permite identificar que a região da palma da mão está totalmente delimitada a região mais clara do histograma da imagem. Assim, a etapa inicial de segmentação da mão consiste no uso do critério de Otsu [10] para criar uma máscara binária da palma da mão.

Depois de segmentar a palma da mão pôde-se observar que, em muitos casos, partes indesejadas, já mencionadas, foram erroneamente incorporados como parte da mão. A fim de mitigar este problema, aplica-se o operador Sobel [11] vertical e horizontal no intuito de encontrar as bordas da imagem, em seguida uma dilatação 5x5 é aplicada para engrossar e conectar as bordas encontradas. Usa-se então o inverso da imagem resultante e faz-se uma operação “E” com o resultado da binarização. Esta etapa permite a separação das regiões que ficaram grudadas à mão. Estes processos podem ser vistos na Figura 1.

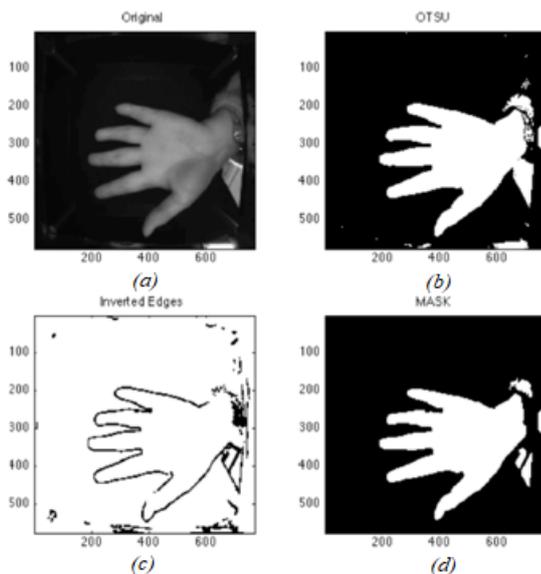


Fig. 1. Etapas do processo de segmentação da palma da mão. a) Imagem original, b) Resultado após binarização pelo critério de Otsu, c) Resultado da aplicação do operador Sobel e da inversão da imagem, d) Resultado da operação “E” entre as imagens b) e c)

Para finalizar o processo de segmentação, encontra-se os componentes conexos da máscara resultante e extrai-se o maior componente, que acaba por ser sempre a palma da mão. Aplica-se então uma operação morfológica de fechamento para suavizar o contorno da região resultante.

Após a localização da máscara de segmentação da mão, extrai-se o contorno externo e calcula-se centroide da região. Um pixel de contorno é aquele que possui ao menos um vizinho dentro da região, isto é, um vizinho cujo valor é 1, e algum vizinho fora da região, vizinho com valor 0. O

centroide por sua vez é calculado a partir do momento de ordem 1 da imagem. O momento de ordem 1 pode ser obtido fazendo a média das posições dos pixels pertencentes a região. A Figura 2 mostra um exemplo de região segmentada e seu contorno externo.

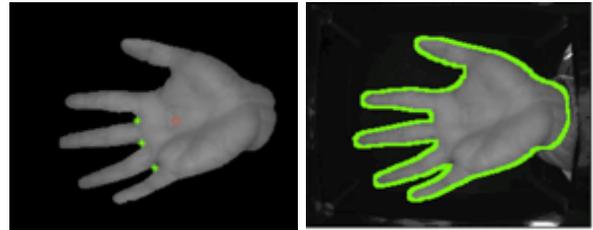


Fig. 2. Segmentação da palma da mão e seu contorno

Para garantir a invariância da extração ROI ao posicionamento da mão é necessário extrair pontos cujas posições são conhecidas independentemente da posição da palma da mão. Para tanto, a partir da distância dos pontos de contorno ao centroide da mão calcula-se as posições das juntas dos dedos indicador com médio e anelar com mínimo. Toma-se então a reta entre estes dois pontos como a aresta esquerda do quadrado da ROI. Por simples geometria, encontra-se as demais arestas do quadrado, recorta-se a ROI e redimensiona-se a região final para 128x128 pixels.

D. Extração das primitivas

As primitivas utilizadas neste trabalho foram o descritor *Local Phase Quantization* (LPQ) e o descritor *Histogram of Oriented Gradients* (HOG). O LPQ é um descritor de textura robusto aos efeitos de desfoque, provando-se superior ao *Local Binary Pattern* (LBP) em aplicações cujas imagens estejam levemente desfocadas ou borradas [7]. Este descritor utiliza a informação da fase computada a partir da transformada discreta de Fourier bidimensional em diversas janelas de 5x5 pixels dentro da imagem. Toma-se então os quatro coeficientes de mais baixa frequência de cada janela e compõem-se um histograma com 256 divisões, sendo este último utilizado como descritor. Os autores do descritor mostram que os coeficientes de fase de mais baixa frequência tendem a serem relativamente imunes aos efeitos de desfoque da imagem. Além disso, como apenas a informação de fase é utilizada, o descritor fica imune às variações de iluminação.

Ainda, como a textura das veias ao longo da região palmar é altamente não uniforme, optou-se neste trabalho por subdividir a região de interesse da palma da mão em 4 e 8 sub-regiões não sobrepostas. Os histogramas individuais destas regiões são então concatenados formando um vetor único de 1024 e 2048 valores respectivamente.

O segundo descritor utilizado foi o HOG introduzido por TRIGGS [8] e primeiramente utilizado para a detecção de pessoas em imagens é baseado no histograma local normalizado da orientação do gradiente da imagem tomado sobre uma grade densa. Na prática, isto significa que a imagem é primeiramente dividida em pequenas regiões

espaiais que se sobrepõem, chamadas de células. Para cada célula acumula-se o vetor 1-D do histograma da direção do gradiente (ângulo do vetor gradiente no pixel).

Para aumentar a robustez do descritor às variações de iluminação e sombra, células adjacentes são agrupadas em blocos e em seguida normaliza-se os vetores dos histogramas contidos neste bloco utilizando a norma L2. O conjunto de histogramas normalizados e concatenados das células pertencentes a um bloco formam o descritor HOG.

E. Classificação

Para cada um dos 100 indivíduos do banco de imagens CASIA, treinou-se uma SVM no método um-contra-todos. Dessa forma, as amostras do indivíduo cujo modelo queria-se treinar são definidas como positivas e todas as demais como negativas. Em seguida, estes dois grupos são divididos em amostras de treinamento e de teste baseado no cenário de estudo. Se forem utilizadas 5 amostras para treinamento e 1 para teste, separa-se uma amostra de cada indivíduo para o grupo de teste e as demais para treinamento. No caso de 3 ou 4 amostras o procedimento é o mesmo. Para a análise de desempenho dos resultados, acumulou-se todas as permutações possíveis de separação dos grupos para um dado cenário.

III. RESULTADOS E DISCUSSÃO

Todos os testes realizados foram feitos em ambiente MATLAB e com base nas imagens de 850 e 940 nm do banco CASIA-MS-Palmprint-V1. Os comprimentos de onda selecionados são utilizados porque a hemoglobina presente no sangue faz com que pequenas veias e vasos fiquem altamente visíveis.

Optou-se pela utilização das imagens de apenas uma das mãos (a direita), embora o algoritmo de segmentação da ROI seja capaz de trabalhar com ambas. Esta escolha é embasada na menor usabilidade que uma implementação prática teria se solicitasse do usuário o fornecimento das duas mãos.

Para cada caso de teste, extraiu-se a Curva de Características de Operação do Receptor (ROC) e a partir dela, calculou-se a Taxa de Erros Iguais (EER) e a área abaixo da curva ROC (AUC). Os resultados para cada grupo de teste foram colocados em um mesmo gráfico ROC à fim de facilitar a comparação.

Na Figura 3 são apresentadas as curvas ROC obtidas para as bases de 850 e de 940 nm. Na legenda da figura pode-se ler o valor de EER e de AUG obtido juntamente com o nome do descritor empregado (HOG, LPQ), número de amostras utilizadas para treinamento (3, 4, 5), parâmetros utilizados no descritor e se foi utilizada a SVM linear ao invés da RBF. A Tabela 1 apresenta detalhadamente os cenários de teste realizados neste estudo.

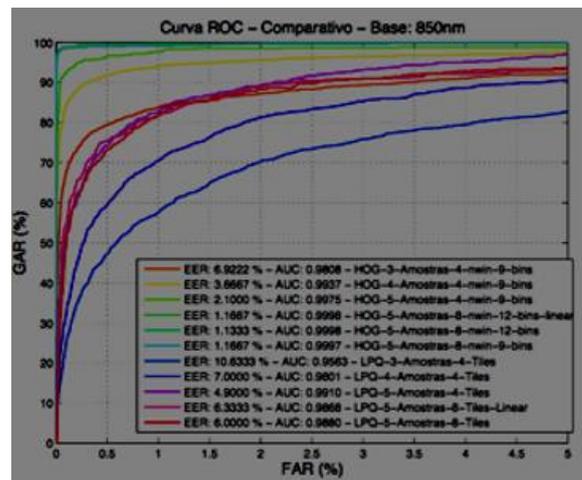


Fig. 3. Comparativos de desempenho para a base de 850 nm

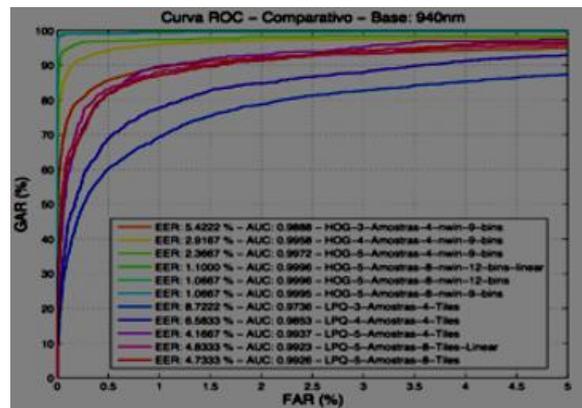


Fig. 4. Comparativos de desempenho para a base de 940 nm

TABELA 1. CENÁRIOS DE TESTES

Descritor	Parâmetros	Amostras	SVM
HOG	32x32, 9 bins	3	RBF
HOG	32x32, 9 bins	4	RBF
HOG	32x32, 9 bins	5	RBF
HOG	16x16, 12 bins	5	Linear
HOG	16x16, 12 bins	5	RBF
HOG	16x16, 9 bins	5	RBF
LPQ	4 sub-regiões	3	RBF
LPQ	4 sub-regiões	4	RBF
LPQ	4 sub-regiões	5	RBF
LPQ	8 sub-regiões	5	RBF
LPQ	8 sub-regiões	5	Linear

A partir da análise da Figura 3 é possível verificar que os melhores resultados obtidos ocorreram nas amostras de 940 nm, sendo o melhor deles o HOG com 5 amostras de treinamento, células de tamanho 16x16 pixels, histograma

com 12 divisões e *kernel* RBF. A EER obtida neste caso foi de 1,0667% com AUC de 0,9996. Os piores casos ficaram por conta do descritor LPQ com 3 amostras de treinamento e 4 sub-regiões. Pode-se perceber que o fator de maior impacto no desempenho do sistema é o número de amostras utilizadas para treinamento. Este resultado já era esperado, haja vista que a capacidade de generalização do classificador SVM é altamente influenciada pela quantidade de amostras fornecidas no treinamento.

Outro ponto que chama a atenção é que o classificador HOG desempenha melhor que o LPQ em todos os casos, notadamente no caso 850 nm com 5 amostras, onde ele chega a ter uma taxa de erros iguais 6 vezes menor que o LPQ. A estratégia de normalização mais sofisticada empregada pelo HOG beneficia àquelas amostras dentro de uma mesma classe que sofreram grandes deformações e, portanto, variações mais importantes de iluminação e sombreamento.

A opção pelo *kernel* linear na SVM teve pouco impacto no desempenho do sistema. Devido a sua menor complexidade computacional em comparação ao RBF, justifica-se a opção pelo *kernel* linear ao RBF em aplicações com processamento em tempo real.

Com relação aos trabalhos publicados utilizando o banco CASIA para extrair os padrões vasculares da palma, Fischer *et al.* [12] obteve uma FAR de 0% para uma FRR de 1,7%, porém excluiu as imagens com muita variação no posicionamento, identificadas por meio da inspeção visual. Nesse caso, o autor elimina possíveis erros causados por essas imagens que são utilizados no trabalho aqui desenvolvido. Mirmohamadsadeghi e Drygajlo [13] obtiveram EER de 0,4% utilizando LBP em sub-regiões da ROI, entretanto, realizaram o dimensionamento da mesma para um mesmo tamanho e utilizaram a técnica de intersecção de histogramas para calcular a distância entre as amostras. Zhou e Kumar [9] obtiveram uma EER de 0,38%, porém testaram quatro métodos para extração das características e ao final realizaram a fusão de todos os métodos, sendo assim um sistema multimodal. Yuan e Li [14] obtiveram uma EER de 5%, mas escolheram visualmente as imagens entre os espectros de 850 e de 940 nm em que as veias estavam mais destacadas, portanto, excluindo as imagens em que as veias não estão completamente aparentes. Yan *et al.* [15] utilizaram três espectros para processamento das imagens, contudo, o de 850 nm foi usado para realizar o treinamento e os espectros de 700 e 940 nm para testes, não sendo realizada a fusão dos mesmos. Por fim, Kang *et al.* [16] utilizaram a Transformada de Características Invariante a Escala (SIFT) que é robusto a mudanças na escala, rotação e ângulo de visualização, compensando assim a variação na profundidade e na inclinação da mão e dos dedos que ocorre nas imagens do banco.

IV. CONCLUSÃO

Este artigo apresentou e testou um sistema biométrico de verificação baseado nos padrões de veias da palma da

mão. Analisou-se o desempenho do sistema para os descritores de textura HOG e LPQ e os classificadores SVM linear e RBF.

Obteve-se como melhor resultado uma EER de 1,0667% e AUC de 0,9996 medidos no banco CASIA-MS-V1 no comprimento de onda 940 nm, utilizando 5 amostras de treinamento, células de tamanho 16x16 pixels, histograma com 12 divisões, *kernel* RBF e descritor de textura HOG.

REFERÊNCIAS

- [1] Prabhakar S, Pankanti S, Jain A. Biometric Recognition: Security and Privacy Concerns, IEEE Security & Privacy Magazine, pp. 33-42, 2003.
- [2] Jain A, Anil K, Ross A, Prabhakar S. An Introduction to Biometric Recognition, IEEE Transactions on Circuits and Systems for Video Technology, Vol. 14, No. 1, pp. 4-20, 2004.
- [3] Jain A, Flynn P, Ross A. Handbook of Biometrics, Springer, New York, 2007.
- [4] Watanabe M. Palm Vein Authentication. Advances in Biometrics. Springer, 2008.
- [5] CASIA-MS-Palmprint V1. Disponível em: <http://biometrics.idealtest.org>. Acessado em: 20/06/2015.
- [6] Yingbo Z, Ajay J. Human Identification Using Palm-Vein Images, IEEE Transactions on Information Forensics and Security, 2011.
- [7] Ojansivu V, Heikkilä J. Blur Insensitive Texture Classification Using Local Phase Quantization. University of Oulu, Finland, 2008.
- [8] Triggs B, Dalal N. Histogram of Oriented Gradients for Human Detection. Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005.
- [9] Zhou Y, Kumar A. Contactless Palm Vein Identification using Multiple Representations. IEEE International Conference on Biometrics, 2010.
- [10] Otsu N. A threshold selection method from gray-level histograms. IEEE Trans. Sys., Man., Cyber, 1979.
- [11] Duda, R.O. and Hart, P.E., pp. 271-272 in Pattern Classification and Scene Analysis, John Wiley & Sons, New York, 1973.
- [12] Fischer M, Rybnicek M, Tjoa S. A Novel Palm Vein Recognition Approach Based On Enhanced Local Gabor Binary Patterns Histogram Sequence. In: 19th IWSSIP 2012: 19th International Conference on Systems, Signals and Image Processing, 2012 April 11-13; Vienna, Austria. IEEE; 2012; p. 429-32.
- [13] Mirmohamadsadeghi L, Drygajlo A. Palm Vein Recognition with Local Binary Patterns and Local Derivative Patterns. International Joint Conference on Biometrics Compendium. 2011; 1-6.
- [14] Yuan W, Li W. A Palm Vein Feature Extraction Method based on Affine Invariant. International Conference on Robotics and Biomimetics. 2012; 2323-6.
- [15] Yan X, Kang W, Deng F, Wu Q. Palm vein recognition based on multi-sampling and feature-level fusion. Neurocomputing. 2015; 151: 798-807.
- [16] Kang W, Liu Y, Wu Q, Yue X. Contact-Free Palm-Vein Recognition Based on Local Invariant Features. PLoS ONE. 2014; 9(5): 1- 12.