

Biometric iris classification when the eye's pupil reacts to light

Jones Mendonça de Souza

Department of Electrical and Computer Engineering
EESC/USP - University of Sao Paulo
São Carlos, SP - Brazil
Email: jonessouza@ifsp.edu.br

Adilson Gonzaga

Department of Electrical and Computer Engineering
EESC/USP - University of Sao Paulo
São Carlos, SP - Brazil
Email: agonzaga@sc.usp.br

Resumo—Is the human iris texture a reliable biometric trait under varying illumination? It is a well-known biological behavior that the eye's pupil contracts under varying levels of light intensity, and dilates in the absence of light. But, what happens with this biometric trait regarding its classification performance, taking into account each specific classification method? Based on this question, we propose in this paper to evaluate some texture descriptors for iris recognition, considering pupil contraction and dilation. We also propose a new descriptor called Median-LMP and compare its performance to Daugman's method, the CLBP, the MBP and the WLD. Our results show that Daugman's algorithm is the best one for iris recognition when pupils are contracted. However, if the pupil dilates, our descriptor performs better and faster than all the compared methods, primarily if one iris with a contracted pupil is used for searching another iris with a dilated pupil.

keywords - local descriptors; iris recognition; biometric systems

I. INTRODUÇÃO

Os sistemas biométricos são métodos para identificação pessoal com base em peculiaridades comportamentais e biológicas. Dentre as peculiares biométricas, a íris tem apresentado grande potencial em aplicações comerciais. A textura da íris apresenta um padrão altamente complexo, composta de fibras musculares dispostas em diferentes sentidos. Esta estruturação faz com que o padrão da íris seja exclusivo para cada pessoa e também para o seu próprio par.

O primeiro algoritmo desenvolvido para classificação dos padrões da íris foi proposto por John Daugman [1]. No algoritmo de Daugman a região de interesse é localizada utilizando-se um operador integro-diferencial, que realiza a delimitação entre a região da íris com a esclera e, da pupila com a íris. Para compensar a variação de rotação da imagem é proposto transformar o anel da íris, de coordenadas cartesianas para coordenadas polares, obtendo-se uma imagem dos padrões de íris com dimensão retangular. Para extrair as características é utilizado o filtro de Gabor 2D, baseando-se a informação de fase para representar os padrões em 2 bits. O grau de similaridade entre duas amostras é dado pelo cálculo da distância de Hamming.

No entanto, o algoritmo de Daugman tem sido aplicado em amostras de íris adquiridas em ambientes cooperativos, ou seja, imagens estáticas capturadas sob curta distância focal e sob iluminação controlada. Essas condições favorecem a captura

de uma amostra de íris com boa qualidade, com menos percentual de ruído e variação na textura da íris. Em um ambiente não cooperativo, como por exemplo no reconhecimento de íris a distância [2] e em movimento [3], a variação de iluminação irá produzir estímulos na pupila, de forma que a pupila se dilate quando houver baixa incidência de luz, e se contraia devido ao excesso de luz incidente nos olhos. Dessa maneira, se os músculos da pupila estiverem contraídos a área da textura da íris será maior e por consequência produzirá maior informação de atributos, favorecendo o processo de identificação. Mas, se a pupila estiver dilatada os padrões da íris serão comprimidos, obtendo-se uma área menor na textura da íris com pouca informação de atributos.

Para extrair as características da íris, além dos descritores de textura tradicionais como o filtro de Gabor 2D [1], a transformada de wavelet [4], a pirâmide laplaciana [5], a decomposição rápida de wavelet de Haar [6], alguns descritores de textura local também foram explorados. O *Local Binary Pattern* (LBP) [7] associado a textons discrimináveis [8] ou combinado com *Learning Vector Quantization* (LVQ) [9] foram aplicados para classificar amostras de íris. A principal vantagem dos descritores de textura local é sua invariância relativa à variação de iluminação [7].

Em um recente trabalho, Ferraz et al. [10] apresentaram um novo descritor de textura local chamado *Local Mapped Pattern* (LMP). A abordagem LMP foi avaliada para diversos tipos de textura, e apresentou melhor desempenho para amostras sob variação de iluminação do que a abordagem LBP.

Neste trabalho é proposto avaliar alguns descritores de textura local para o reconhecimento de íris, levando-se em consideração a contração e a dilatação da pupila. Além disso, é proposto um novo descritor de textura de íris baseado na abordagem LMP, denominado *Median Local Mapped Pattern* (Median-LMP). O método proposto foi comparado com diversos outros descritores de textura local como: o *Local Mapped Pattern* (LMP) [10], o *Completed Modeling of Local Binary Pattern* (CLBP) [11], o *Median Binary Pattern* (MBP) [12], o *Weber Local Descriptor* (WLD) [13], além do método clássico na literatura para o reconhecimento de íris proposto por John Daugman [1]. O objetivo desta avaliação é o de fornecer subsídios que possam ser utilizados no reconhecimento da íris à distância e em ambientes não cooperativos, onde as

condições de iluminação causam movimento da pupila e, portanto, variações de textura, degradando o desempenho de sistemas biométricos de íris.

II. MEDIAN LOCAL MAPPED PATTERN

A abordagem original LMP considera a soma das diferenças de cada nível de cinza de uma determinada vizinhança do *pixel* central como um padrão local, que pode ser mapeado para um histograma utilizando uma função de mapeamento [10]. Dada a vizinhança de um *pixel* $v = W \times W$, seu padrão pode ser mapeado para um *bin* no histograma (h_b) usando a Equação 1,

$$h_b = \text{round} \left(\frac{\sum_{i=1}^{v-1} f_{g_i} M(i)}{\sum_{i=1}^{v-1} M(i)} (B-1) \right) \quad i = 1 \text{ to } (v-1) \quad (1)$$

na qual, f_g é a função de mapeamento, $M(i)$ é uma matriz de ponderação com valores pré-definidos para cada posição de *pixel* dentro da vizinhança local e B é o número de *bins* do histograma. Esta equação representa uma soma ponderada de cada diferença de nível de cinza, a partir do *pixel* central da vizinhança, mapeada no intervalo [0,1] por uma função de mapeamento, arredondando-se os valores para os *bins* B possíveis no histograma. A função de mapeamento utilizada é a sigmoide apresentada na Equação 2, onde β é a inclinação da curva e $[g_i - g_c]$ são as diferenças de nível de cinza dentro da vizinhança centrada em g_c , e a matriz de ponderação apresentada na Equação 3 [10].

$$f_g = \frac{1}{1 + e^{-\frac{[g_i - g_c]}{\beta}}} \quad i = 1 \text{ to } (v-1) \quad (2)$$

$$M(i) = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad i = 1 \text{ to } (v-1) \quad (3)$$

Uma das principais vantagens mencionados em trabalhos anteriores sobre LMP é o baixo custo computacional associado a um alto desempenho. No entanto, pequenas diferenças ao comparar padrões, devido ao ruído ou à mudança de iluminação podem introduzir erros, principalmente se o valor central do *pixel* mudar de um padrão para outro. Hafiane et al [12] observaram o mesmo fenômeno e propuseram o *Median Binary Pattern* (MBP) resultando em um descritor de textura mais robusto para erros causados pela comparação com o *pixel* central.

Com base no MBP e levando-se em consideração o alto desempenho da abordagem LMP para diversos tipos de texturas, foi proposto neste trabalho um novo descritor de textura chamado *Median Local Mapped Pattern* (Median-LMP) para a discriminação da textura da íris com a variação do tamanho da pupila. O filtro mediano efetivamente reduz o ruído conhecido como “sal e pimenta” no processamento de imagens. É importante ressaltar que a imagem da íris adquirida à distância em um ambiente não cooperativo tem maior probabilidade de ser afetada pelo ruído, devido à mudança de iluminação. Sendo assim, é proposto utilizar o valor mediano de uma vizinhança $W \times W$ como o elemento de comparação. Isto é

feito modificando-se o g_c na Equação 2 pelo valor mediano da vizinhança analisada. Como a mediana da vizinhança já produz um filtro de suavização, foi proposto alterar a matriz de ponderação $M(i)$ original do LMP Equação 3 para pesos de potência de dois, ou seja, $M(i) = [2^0, 2^1, 2^2, 2^3, 2^4, 2^5, 2^6, 2^7]$, assim como proposto no trabalho de Hafiane et al [12]. A Figura 1 ilustra a comparação entre o LMP e Median-LMP para geração do código a partir de uma mesma vizinhança.

III. BASES NÃO COOPERATIVAS

Para avaliar o descritor proposto em comparação com os descritores citados na literatura, em diferentes tamanhos de pupila, foram utilizadas as bases de dados não cooperativas UBIRIS V2 [3] e CASIA-Iris-Distance [2]. Para ambas bases de dados, foram utilizadas somente amostras do olho direito para geração do vetor de característica, porque as imagens do olho direito foram utilizadas para sintonizar os parâmetros β e $B = \text{bins}$.

A. Base de dados UBIRIS V2

Proença [3] propôs um sistema não cooperativo baseado na imagem da íris adquirida sob a banda visível. A proposta do autor foi capturar amostras da íris humana a 8 metros de distância, usando um modelo de câmera profissional Canon EOS 5D. Uma base de dados foi desenvolvida pelo autor simulando o movimento da cabeça em diferentes ângulos. O autor nomeou esta base de dados como UBIRIS V2, contendo 11.102 amostras de íris. Para realização dos experimentos, neste trabalho, selecionou-se apenas um subconjunto contendo amostras/classe com variação no tamanho na pupila, conforme ilustrado na Figura 2. Dessa maneira, foram selecionadas 882 amostras a partir da “Sessão 1” da base UBIRIS V2, divididas em 147 classes, sendo 6 amostras por classe.



(a) Amostra com a pupila contraída (b) Amostra com a pupila dilatada

Figura 2: Exemplo de duas amostras da base de dados UBIRIS V2 com diâmetros de pupila diferentes.

B. Base de dados CASIA-Iris-Distance

Dong et al [2] propuseram um dispositivo para capturar amostras de íris a 3 metros de distância. O dispositivo utiliza uma câmera *Pan-Tilt-Zoom* (PTZ) responsável pelo rastreamento e a focalização da região facial. Uma imagem de alta definição da face do usuário é adquirida, permitindo a extração de características da íris do lado esquerdo e direito. As imagens de íris foram digitalizadas sob a banda infravermelho próximo (NIR), com resolução espacial de 2352x1728 *pixels*.

100	50	25	100	50	25
10	100	50	25	50	30
100	10	255	30	15	20
100	100	15	20	50	25
10	50	30	10	50	30
100	15	20	100	15	20

(a) Imagem original com uma região local 3×3 destacada em vermelho

100	50	25
10	255	30
100	15	20

(b) Vizinhança 3×3 afetada pelo ruído no pixel central

neighborhood	f_g with $\beta=0.4$	Matrix $M(i)$
100 50 25	0 0 0	1 1 1
10 255 30	0 0.5 0	1 1 1
100 15 20	0 0 0	1 1 1

$$LMP_{code} = \text{round}\left(\frac{0+0+0+0+0.5+0+0+0}{9}(256-1)\right) = 14$$


(c) Código LMP gerado pelo valor do pixel central $g_c = 255$

neighborhood	f_g with $\beta=0.4$	Matrix $M(i)$
100 50 25	1 1 0	1 2 4
10 255 30	0 1 0.5	8 0 16
100 15 20	1 0 0	32 64 128

$$\text{Median-LMP}_{code} = \text{round}\left(\frac{1+2+0+0+8+32+0+0}{255}(256-1)\right) = 43$$

(d) Código Median-LMP gerado pelo valor mediano da vizinhança $g_c = 30$

Figura 1: Comparação entre o código LMP e Median-LMP.



(a) Amostra com a pupila contraída (b) Amostra com a pupila dilatada

Figura 3: Exemplo de duas amostras da base de dados CASIA-Iris-Distance com diâmetros de pupila diferentes.

Os autores desenvolveram uma base de dados denominada CASIA-Iris-Distance, que incluiu 142 usuários, totalizando 2.567 amostras de íris. A biblioteca OpenCV foi utilizada para a localização dos olhos nas imagens da base de dados, aplicando-se o classificador de objetos cascata de Haar. Para realização dos experimentos, neste trabalho, foram selecionadas 5 amostras por classe, totalizando 710 imagens de íris. A Figura 3 ilustra duas amostras de íris de mesma classe apresentando variação no tamanho da pupila, ocasionado pela mudança de luz do ambiente.

IV. PROCESSAMENTO E SEGMENTAÇÃO

A. Localização e segmentação da íris

Para a localização e segmentação das amostras de íris de cada base de dados foi aplicado o algoritmo de Daugman [1], conhecido como “*Rubber Sheet Model*” para se obter o anel da íris normalizado. Com base na amostra obtida a partir da aplicação do método de Daugman, foram gerados cinco subconjuntos com imagens em diferentes resoluções espaciais: 20×240 , 30×360 , 40×480 , 50×600 e 60×720 pixels, como ilustrado na Figura 4.




Figura 4: Subconjuntos gerados a partir das amostras normalizadas de cada base de dados.

B. Extração e comparação das características da íris

Para extração das características da íris foram implementados os extratores de cada método comparado: o filtro de Gabor 2D proposto por Daugman [1] e também os descritores de textura local, CLBP [11], WLD [13], MBP [12], LMP [10] e o Median-LMP (proposto neste artigo). No método de Daugman é utilizada a distância de Hamming para se obter a similaridade entre duas amostras. Já para os métodos baseados em descritores de textura local, foram gerados os histogramas de códigos correspondentes e calculada a similaridade entre duas amostras utilizando a distância Qui-Quadrado dada na Equação 4,

$$X^2(S, Y) = \frac{1}{2} \sum_{b=1}^B \frac{(S_b - Y_b)^2}{(S_b + Y_b)}, \quad (4)$$

na qual, S é a amostra de busca, Y é a amostra de consulta, B é o número de *bins* dos histogramas comparados, S_b é a frequência do nível de cinza de S , e Y_b é a frequência do nível de cinza de Y .

Foi utilizado o método de validação cruzada *leave-one-out* para se obter o número de Verdadeiros Positivos (TP) e o número de Falsos Negativos (FN), para todas as amostras de consulta. A taxa de acerto do sistema foi obtida pelo cálculo da Sensibilidade ou Hit-rate (H), dada pela Equação 5.

$$H = \frac{TP}{TP + FN}, \quad (5)$$

V. RESULTADOS E DISCUSSÃO

Em todas as tabelas, as células destacadas em cor “cinza escuro”, representam os melhores resultados obtidos para cada teste, e as células em cor “cinza claro” representam o segundo melhor resultado entre os métodos comparados, levando-se em consideração a resolução espacial da amostra.

A. Desempenho obtido com a Base de dados UBIRIS V2

A base de dados UBIRIS V2 é a que mais se aproxima do ambiente real não cooperativo, pois foi adquirida sob condições não restritas, ou seja, a distância, em diversos ângulos e com variação de iluminação. Devido a este cenário é encontrado nesta base de dados um grande volume de amostras com diferentes tamanhos de pupila.

Observando-se os resultados da Tabela I é possível notar que, apesar das baixas taxas de acerto de todos os métodos comparados, o descritor proposto Median-LMP atingiu as maiores taxas de acerto, e que estas taxas aumentam conforme aumenta-se o tamanho da amostra. Ou seja, este resultado demonstra que o aumento da quantidade de informação de textura contida em amostras maiores facilita o processo de classificação. O método de Daugman teve o segundo melhor desempenho em menores resoluções e o WLD responde melhor nas maiores, chegando a superar nosso descritor na resolução de 60x720 *pixels*.

Tabela I: Taxas de acerto (H) obtidas com a base de dados UBIRIS V2

Métodos	Resolução das amostras				
	20 × 240	30 × 360	40 × 480	50 × 600	60 × 720
Daugman	54.08	54.13	54.44	54.78	55.32
MBP	48.27	49.04	49.16	57.36	58.27
Median-LMP	60.18	66.22	68.63	72.33	75.88
LMP	47.71	52.16	53.28	54.75	59.27
WLD	37.48	40.21	58.77	65.14	79.88
CLBP_M _{8,1} ^{u2}	42.49	43.85	44.53	44.30	43.74
CLBP_S _{8,1} ^{u2}	47.93	47.14	47.59	46.80	46.04
CLBP_S/M/C _{8,1} ^{u2}	50.65	48.61	48.61	48.95	47.14
CLBP_S_M/C _{8,1} ^{u2}	48.73	47.25	47.02	47.02	46.91
CLBP_S/M _{8,1} ^{u2}	47.59	46.46	47.25	47.93	45.66
CLBP_M/C _{8,1} ^{u2}	45.21	44.98	47.36	45.78	46.04

B. Desempenho obtido com a Base de dados CASIA-Iris-Distance

Esta base de dados foi desenvolvida utilizando um sistema biométrico multimodal para aquisição de imagens da face e da íris a longa distância. As amostras foram adquiridas a uma distância de 3 metros da câmera, e cada uma delas contém a região frontal da face. Os olhos do lado direito foram utilizados para a realização dos experimentos deste trabalho. Os resultados apresentados na Tabela II, mostram o mesmo comportamento da base anterior. Ou seja, o Median-LMP é o melhor descritor em todas as resoluções, Daugman é o segundo melhor nas baixas e WLD responde melhor nas altas resoluções. O aumento na taxa de acerto, comparativamente à Tabela I, deve-se ao fato que, diferentemente da UBIRIS V2, esta base foi adquirida sob iluminação NIR, o que reduziu os reflexos naturais causados pela luz visível, aumentando o desempenho.

Tabela II: Taxas de acerto (H) obtidas com a base de dados CASIA-Iris-Distance

Métodos	Resolução das amostras				
	20 × 240	30 × 360	40 × 480	50 × 600	60 × 720
Daugman	69.23	69.88	71.13	72.44	72.44
MBP	58.19	52.21	54.40	54.77	58.90
Median-LMP	74.08	77.50	81.20	84.55	88.77
LMP	58.73	61.25	64.99	66.04	70.25
WLD	52.77	66.14	71.33	78.44	89.88
CLBP_M _{8,1} ^{u2}	44.13	32.14	44.12	42.33	46.71
CLBP_S _{8,1} ^{u2}	58.40	44.88	50.88	52.48	48.66
CLBP_S/M/C _{8,1} ^{u2}	60.22	58.29	54.87	62.22	58.30
CLBP_S_M/C _{8,1} ^{u2}	58.77	54.33	58.91	52.23	56.80
CLBP_S/M _{8,1} ^{u2}	50.66	58.90	50.27	54.19	56.14
CLBP_M/C _{8,1} ^{u2}	54.41	50.44	50.44	46.31	52.66

C. Tempo de execução

Um dado importante no reconhecimento biométrico de íris em ambientes não controlados é o tempo computacional envolvido na busca por uma amostra em um banco de dados. Utilizando-se busca sequencial, foi avaliado o tempo de execução de cada método comparativamente. Todos os testes foram realizados em um computador Intel Core I7 920, 2,67 GHz, com 6 GB de RAM, executando o Windows 8.0 e com o software Matlab versão R2001a. Os tempos comparativos de execução foram plotados em gráficos levando-se em consideração a pesquisa de uma amostra com todas as outras da base de dados, ou seja, o tempo “um-para-muitos” e, também o tempo necessário para comparar apenas uma amostra com

outra, o tempo de execução “um-para-um”. Tanto para o tempo de “um-para-um” quanto o de “um-para-muitos”, foi levado em consideração o tempo necessário para o método extrair as características da amostra de busca (obtida pelo método “*Rubber Sheet Model*”) e, comparar com as características previamente armazenadas no banco de dados.

Como pode ser observado na Figura 5 a abordagem original LMP apresenta os menores tempos de execução entre todos os outros métodos avaliados, e o descritor proposto neste trabalho Median-LMP é o segundo método mais rápido dentre os outros comparados.




Figura 5: Tempo de execução “um-para-um”.

Com base no tempo de execução “um-para-muitos”, em que é avaliado o tempo necessário para encontrar a classe de uma amostra de consulta dentro da base de dados completa, por meio da busca sequencial, é possível observar na Figura 6 que o método CLBP-M atingiu os menores tempos de execução, sendo considerado o mais rápido para esta finalidade. No entanto, o descritor proposto neste trabalho Median-LMP também apresentou um bom desempenho, estando entre os mais rápidos.

Avaliando-se as taxas de acertos obtidas com as bases de imagens de íris não cooperativas, é possível concluir que, a metodologia proposta neste trabalho obteve melhor desempenho do que todos os métodos comparados. Nas duas bases utilizadas, uma adquirida com iluminação visível e outra com iluminação NIR, o descritor proposto neste trabalho atingiu a maior taxa de acerto relativamente a todos os outros comparados, com amostras de 20 x 240 *pixels* até 50 x 600 *pixels*. Somente na resolução espacial de 60 x 720 *pixels*, o WLD foi melhor do que os outros descritores deixando o Median-LMP em segundo lugar. Além disso, com exceção dos descritores derivados do CLBP, todos os outros tiveram comportamentos similares nas duas bases: a taxa de acerto cresceu com o aumento da área amostrada da textura da íris (aumento da resolução espacial). Isso permite concluir que uma maior quantidade de informação discriminante (textura) aumenta o desempenho deste tipo de sistema biométrico. No entanto, este aumento de taxa de acerto (“bônus”) corresponde




Figura 6: Tempo de execução “um-para-muitos”.

também a um aumento do tempo de processamento (“ônus”), característico de cada metodologia.

VI. CONCLUSÕES

Alguns trabalhos publicados anteriormente concluíram que a textura da íris muda sob contração e dilatação da pupila, podendo reduzir o desempenho de sistemas biométricos [14] [2] [3] [15]. Além disso, há um crescente interesse em relação ao reconhecimento de íris em ambientes não cooperativos, como por exemplo, a distância e/ou em movimento. Imagens adquiridas de maneira não cooperativa e sob iluminação não controlada podem apresentar variação no tamanho da pupila para a mesma pessoa. Baseado nessas argumentações, neste artigo foi proposto avaliar alguns descritores locais de textura e também o método clássico de John Daugman [1] para o reconhecimento de íris, aplicados em imagens com variação do tamanho da pupila. Para isso, foram utilizadas duas bases de imagens de íris adquiridas de modo não cooperativo, a UBIRIS V2 e a Cassia-Iris-Distance.

Além disso, foi proposto, neste trabalho, um novo descritor local de textura denominado Median-LMP e foram avaliados os seguintes descritores locais de textura: *Local Mapped Pattern* (LMP) [10], *Completed Modeling of Local Binary Pattern* (CLBP) [11], *Median Binary Pattern* (MBP) [12], *Weber Local Descriptor* (WLD) [13], além do método proposto por John Daugman [1]. Para avaliar o “ônus” de cada método, foi medido o tempo de processamento necessário para comparação de uma amostra com as amostras da base de imagens. Neste sentido, duas variáveis foram avaliadas: o tempo de execução do algoritmo e a dimensionalidade do vetor de características. Observou-se que o descritor proposto Median-LMP é o que atingiu maior desempenho (“bônus versus ônus”) entre todos os métodos avaliados para todas as bases de dados. Apesar da abordagem WLD obter maior taxa de acerto quando aplicada em amostras com maior resolução espacial (60 x 720 *pixels*), o tempo gasto para geração do vetor de características é mais alto do que os tempos necessários para os métodos de Daugman e para o Median-LMP. O método

de Daugman consome maior tempo de execução, porque na etapa de comparação o algoritmo usa um procedimento de “*shift*” para se obter a melhor distância de Hamming entre os vetores de características. Sendo assim, o descritor Median-LMP se torna um método mais viável para aplicações em tempo preditivo.

Como neste trabalho foram utilizados somente olhos lado direito para realização dos experimentos, sugere-se para trabalhos futuros avaliar os descritores abordados a partir de ambos lados dos olhos, obtendo-se um vetor de característica mais robusto para a classificação. Sugere-se ainda modelar e avaliar o problema considerando que a aquisição é afetada por *Random-Valued Impulse Noise* e, comparar os resultados aplicando-se a técnica de *Deep Learning*.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro da FAPESP, processo #2015/20812- 5 e, do Instituto Federal de São Paulo (IFSP), para a realização deste trabalho.

REFERÊNCIAS

- [1] J. Daugman, “High confidence visual recognition of persons by a test of statistical independence,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 15, no. 11, pp. 1148–1161, 1993.
- [2] W. Dong, Z. Sun, and T. Tan, “A design of iris recognition system at a distance,” in *Chinese Conference on Pattern Recognition*, vol. 2. Nanjing, China: **IEEE**, nov 2009, pp. 1–5.
- [3] H. Proença, “On the feasibility of the visible wavelength, at-a-distance and on-the-move iris recognition,” in *Workshop on Computational Intelligence in Biometrics: Theory, Algorithms, and Applications*. Hangzhou, China: **IEEE**, Apr. 2009, pp. 9–15.
- [4] W. W. Boles and B. Boashash, “A human identification technique using images of the iris and wavelet transform,” *IEEE Transactions on Signal Processing*, vol. 46, no. 4, pp. 1185–1188, 1998.
- [5] R. Wildes, J. Asmuth, G. Green, S. Hsu, R. Kolczynski, J. Matey, and S. McBride, “A system for automated iris recognition,” in *Applications of Computer Vision, 1994., Proceedings of the Second IEEE Workshop on*, Dec 1994, pp. 121–128.
- [6] T. W. Ng, T. L. Tay, and S. W. Khor, “Iris recognition using rapid haar wavelet decomposition,” in *2010 2nd International Conference on Signal Processing Systems*, vol. 1, July 2010, pp. V1–820–V1–823.
- [7] T. Ojala, M. Pietikäinen, and D. Harwood, “A comparative study of texture measures with classification based on featured distributions,” *Pattern Recognition*, vol. 29, no. 1, pp. 51–59, Jan. 1996. [Online]. Available: [http://dx.doi.org/10.1016/0031-3203\(95\)00067-4](http://dx.doi.org/10.1016/0031-3203(95)00067-4)
- [8] M. De Marsico, M. Nappi, and D. Riccio, “Noisy iris recognition integrated scheme,” *Pattern Recognition Letters*, vol. 33, no. 8, pp. 1006–1011, Jun. 2012.
- [9] M. Y. Shams, M. Z. Rashad, O. Nomir, and R. M. El-Awady, “Iris recognition based on lbp combined LVQ classifier,” *CoRR*, 2011.
- [10] C. T. FERAZ, O. PEREIRA, M. V. ROSA, and A. GONZAGA, “Object recognition based on bag of features and a new local pattern descriptor,” *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 28, no. 08, p. 1455010, 2014. [Online]. Available: <http://www.worldscientific.com/doi/abs/10.1142/S0218001414550106>
- [11] Z. Guo, L. Zhang, and D. Zhang, “A completed modeling of local binary pattern operator for texture classification,” *IEEE Transactions on Image Processing*, vol. 19, no. 6, pp. 1657–1663, June 2010.
- [12] A. Hafiane, G. Seetharaman, and B. Zavidovique, “Median binary pattern for textures classification,” in *Proceedings of the 4th International Conference on Image Analysis and Recognition*, ser. ICIAR’07. Berlin, Heidelberg: Springer-Verlag, 2007, pp. 387–398. [Online]. Available: <http://dl.acm.org/citation.cfm?id=2394970.2395010>
- [13] J. Chen, S. Shan, C. He, G. Zhao, M. Pietikainen, X. Chen, and W. Gao, “Wld: A robust local image descriptor,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 32, no. 9, pp. 1705–1720, Sept 2010.
- [14] R. M. da Costa and A. Gonzaga, “Dynamic features for iris recognition,” *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 42, no. 4, pp. 1072–1082, Aug 2012.
- [15] K. Hollingsworth, K. W. Bowyer, and P. J. Flynn, “Pupil dilation degrades iris biometric performance,” *Computer Vision and Image Understanding*, vol. 113, no. 1, pp. 150–157, 2009. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1077314208001173>