

Dynamic Time Warping in Iris Biometric Recognition Process

P. R. da Silva and C. R. Bernadelli

Abstract— In general, iris recognition systems with linear normalization model ignore the Pupil Light Reflex – PLR. The PLR is responsible for adjusting light intensity reaches the retina and causes nonlinear iris contraction and dilation movements that generates significant differences between enrolled images and test images. This paper has proposed a method to reduce the influence of iris dynamics examined by decidability (d) and Equal Error Rate (EER), obtained in the comparison between iris codes in different states of dilation. The method has used the Dynamic Time Warping (DTW) technique to compare the Histograms of Gradients Oriented (HoG) vectors extracted from the iris texture. In this way, the most discriminated characteristics between test images and the gallery had been aligned and compared, considering a nonlinear deformation of the iris tissue caused by the PLR. The experimental results, using dynamic images, indicate the system performance worsens when compared to images in different states of contraction. For a direct comparison between iris well contracted with well-dilated iris, the proposed method improves the decidability from 3.50 to 4.39 and the EER from 9.69% to 3.36%.

Index Terms— Dynamic Time Warping, Equal Error Rate, Histogram of Oriented Gradients, Iris recognition, Pupil light reflex.

I. INTRODUÇÃO

A íris humana é formada por um tecido conjuntivo contendo fibras musculares, vasos sanguíneos e células pigmentares [1].

Outras variações na aparência da íris são provenientes das criptas (formações irregulares da superfície), de pequenas elevações da superfície e das sardas (concentrações de células pigmentadas). Todas essas estruturas compõem as características da íris e são consideradas únicas para cada pessoa [1], [2] e [3].

O reconhecimento biométrico da íris é um método automático de identificação que usa o padrão aleatório da textura da íris (características da íris). Modelos digitais, ou templates codificam estas características e permitem a identificação do indivíduo.

Muitos sistemas de reconhecimento de íris foram propostos, porém o mais conhecido é o sistema desenvolvido por John Daugman [4] que obteve taxas de erro próxima de zero utilizando uma base de dados com cerca de 632.500 imagens e 200 bilhões de comparações.

O protótipo proposto por Wildes et al. [5] utilizou um conjunto de 520 imagens e não reportou nenhuma falha. Um outro sistema, proposto por Lim et al. [6] utilizou cerca de 5.292 imagens e obteve taxa de reconhecimento de 98,4%.

Normalmente, esses sistemas possuem as seguintes etapas: Aquisição da imagem, Segmentação da íris, Normalização, Extração de características, Codificação da íris, Comparação e Apresentação dos resultados [7].

A. Efeitos dos Movimentos da Íris

O movimento de contração e dilatação da íris impõe várias consequências ao sistema de reconhecimento. A pressão das fibras musculares pode fazer com que algumas pequenas regiões do tecido da íris se dobrem por baixo de outras. Isso significa que pequenas partes do padrão desaparecerá e nenhum modelo de deformação será capaz de representar essa transformação [8].

Outro problema gerado pelo movimento da íris é a falsa rejeição entre códigos correspondentes em condições extremas, onde a textura da íris sob forte compressão, produz uma imagem normalizada distinta da imagem normalizada em condições normais [8] e [9]. Dessa forma, as regiões não afetadas ou menos afetadas pelos movimentos da íris devem fornecer informações suficientes para o processo de reconhecimento.

A maioria dos métodos de reconhecimento de íris baseia-se no modelo proposto por Daugman [10] que, por sua vez, adota um rígido controle na aquisição da imagem e aplica o modelo *homogeneous rubber sheet* na etapa de normalização. O modelo *homogeneous rubber sheet* projeta linearmente a região anular da íris em uma região retangular fixa e, segundo Daugman, proporciona a geração de códigos de íris que são invariantes sob distorções elásticas não afins.

Entretanto, Wyatt [11] explicou que o modelo *homogeneous rubber sheet* não representa a verdadeira deformação do tecido da íris e concluiu em seu trabalho que um modelo não linear é mais adequado. Resultados experimentais comprovaram que o método de Wyatt tornou o sistema de reconhecimento mais robusto contra estímulos externos, como por exemplo a variação da iluminação.

Por sua vez, Wei et al. utilizaram em seu trabalho um algoritmo para modelar a deformação não linear da íris utilizando uma deformação linear mais um desvio aditivo calculado por uma função Gaussiana [12].

B. Objetivos

O principal objetivo deste trabalho é avaliar e confirmar a influência dos movimentos da íris no processo de reconhecimento biométrico e utilizar um método capaz de reduzir essa influência. O método considera apenas as regiões da íris com maior similaridade, apesar da sua deformação não linear.

A aplicação é composta por subsistemas que correspondem às etapas típicas de reconhecimento de íris e baseado na implementação realizada por Libor Masek [13].

O aprimoramento do sistema foi baseado nos algoritmos de Histogramas de Gradientes Orientados (HoG) e *Dynamic Time Warping* (DTW). Os resultados obtidos foram comparados com os resultados fornecidos por um sistema tradicional implementado inicialmente.

Dois conjuntos distintos de imagens foram utilizados. A base de dados CASIA-IRIS-Lamp, formada por 16.212 imagens com resolução de 640X480 pixels, obtidas de 411 indivíduos diferentes e divididas em 819 classes. Durante o processo de aquisição do conjunto CASIA-IRIS-Lamp uma lâmpada intermitente próxima ao indivíduo introduz maior variação intraclasse, ou seja, deformações elásticas na textura da íris devido à contração e a dilatação da pupila sob diferentes condições de iluminação.

O outro conjunto utilizado é formado pelas imagens da base CASIA-IrisV1 que contém 756 imagens de 108 olhos (7 imagens de cada olho), capturadas em duas sessões e com resolução de 320X280 pixels.

II. DESEMPENHO DO SISTEMA

O software inicialmente implementado fornece a distribuição dos códigos correspondentes (*match*) e dos códigos não correspondentes (*non-match*), ou seja, ele determina o histograma das distâncias de Hamming (Hd) intraclasse e interclasse, conforme mostra a Fig. 1 e a Fig. 2.

Pode-se observar na Fig. 1 e na Fig. 2 que existe sobreposição de valores entre as duas distribuições para os dois conjuntos de imagens. Normalmente, a sobreposição representa a taxa de erro do sistema que necessariamente deverá escolher um valor de Hd para ser o limiar e garantir que a probabilidade de uma falsa correspondência fique abaixo de um nível especificado.

A proporção esperada de bits concordantes entre os códigos de duas íris diferentes é de 50%, o que corresponde a uma distância de Hamming igual a 0,5 [3]. Contudo, pode-se reduzir este valor para Hd = 0,45 devido à correção no alinhamento dos códigos [13].

No trabalho de Daugman [3], a média das distâncias de Hamming para a distribuição correspondente foi de 0,110 e a média das distâncias de Hamming para a distribuição não correspondente foi de 0,458, resultando em uma decidibilidade de 7,3. Além disso, Daugman utilizou um limiar adaptativo, variando de 0,27 a 0,33, para separar as distribuições correspondentes e não correspondentes.

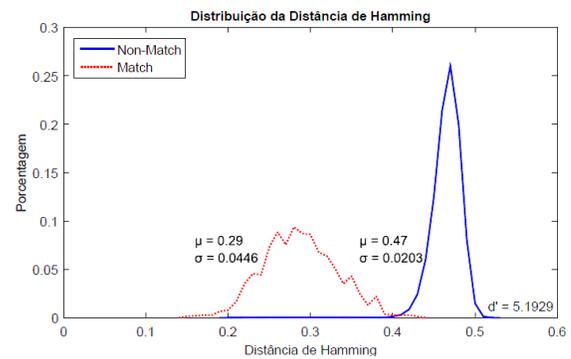


Fig. 1. Distribuição das distâncias de Hamming da base CASIA-Iris V1.

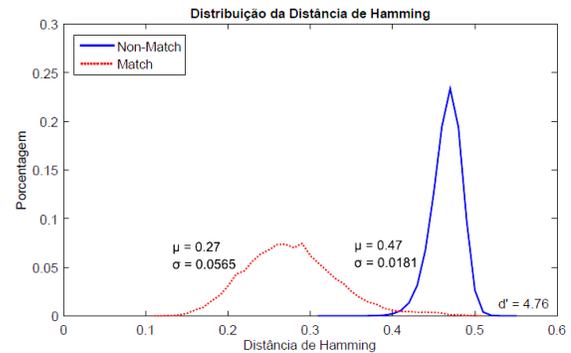


Fig. 2. Distribuição das distâncias de Hamming da base CASIA-IRIS-Lamp.

A média da distribuição correspondente do conjunto Casia-IrisV1 na Fig. 1 é de 0,29. Além disso, 100% destas amostras possuem Hd menor do que o limiar de 0,45 (nenhum falso negativo). Por sua vez, a média da distribuição não correspondente é de 0,47 e 19,24% destas amostras possuem Hd menor do que o limiar de 0,45 (falso positivo). Aqui a decidibilidade foi de 5,19.

Para o conjunto Casia-IRIS-Lamp a média da distribuição correspondente na Fig. 2 é de 0,27. Além disso, 1,60% destas amostras possuem Hd maior ou igual ao limiar de 0,45 (falso negativo). Por sua vez, a média da distribuição não correspondente é de 0,47 e 20,98% destas amostras possuem Hd menor do que o limiar de 0,45 (falso positivo). A decidibilidade foi de 4,76, que corresponde a uma degradação de aproximadamente 8% em relação ao conjunto Casia-IrisV1.

Os resultados obtidos sugerem que o conjunto CASIA-IRIS-Lamp está mais sujeito a erros, possivelmente por apresentar maior variabilidade devido ao movimento do tecido da íris. Dessa forma, existem claros indícios que o espaçamento temporal entre as imagens a serem comparadas deve ser levado em conta e que, ao contrário do que Daugman [10] afirmou, o modelo *homogeneous rubber sheet* não é capaz de eliminar os problemas causados pela contração e dilatação do tecido da íris.

A. Experimento 1

As curvas *receiver operating characteristics* (ROC) da Fig. 3 determinam as taxas de erro igual (EER) para os conjuntos de imagens utilizados. Quanto menor for a EER maior será a capacidade do sistema em classificar corretamente uma amostra. Para o conjunto CASIA-IrisV1 a EER foi de 0,74% e

para o conjunto CASIA-IRIS-Lamp a EER foi de 2,16%.

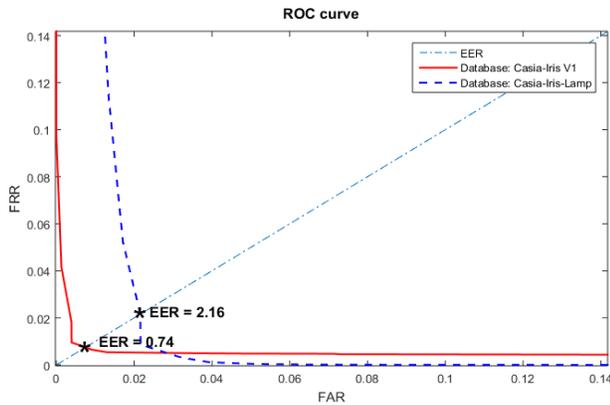


Fig. 3. ROC para CASIA-Iris V1 e CASIA-IRIS-Lamp.

B. Experimento 2

Para este experimento foi utilizado apenas o conjunto CASIA-IRIS-Lamp, contudo as imagens deste conjunto foram divididas empiricamente em três grupos de acordo com a taxa de dilatação (Td) da pupila.

Durante a segmentação, a transformada de Hough fornece o raio da pupila e o raio da íris [13]. Esses valores permitem determinar a taxa de dilatação da íris, ou seja, o valor do raio da pupila dividido pelo valor do raio da íris.

Para todas as 1.753 imagens utilizadas do conjunto CASIA-IRIS-Lamp, a taxa de dilatação ficou entre 0,20 e 0,70.

Dessa forma, o primeiro subconjunto, denominado de Subconjunto (1), consiste das imagens com pupilas menores ou com pupilas contraídas, cujas taxas de dilatação são menores do que 0,36 (Td pequeno). O segundo subconjunto, denominado de Subconjunto (2), compreende as imagens com pupilas de tamanho intermediário, com taxas de dilatação entre 0,36 e 0,52 (Td médio). O terceiro subconjunto, denominado de Subconjunto (3), contém as imagens com pupilas maiores ou dilatadas, cujas taxas de dilatação são maiores do que 0,52 (Td grande).

Para o Subconjunto (1) a média das distribuições das Hds correspondentes foi de 0,26, com desvio padrão de 0,0512. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,47, com desvio padrão de 0,0161 e a decidibilidade encontrada foi 5,53.

Para o Subconjunto (2) a média das distribuições das Hds correspondentes foi de 0,27, com desvio padrão de 0,0562. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,47, com desvio padrão de 0,0185 e a decidibilidade encontrada foi 4,78.

Para o Subconjunto (3) a média das distribuições das Hds correspondentes foi de 0,25, com desvio padrão de 0,0519. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,46, com desvio padrão de 0,0228 e a decidibilidade encontrada foi 5,24.

As curvas ROC da Fig. 4 determinam as EER para os três subconjuntos. Para os Subconjuntos (1), (2) e (3) as EER foram de 0,98, 1,76 e 1,55, respectivamente.

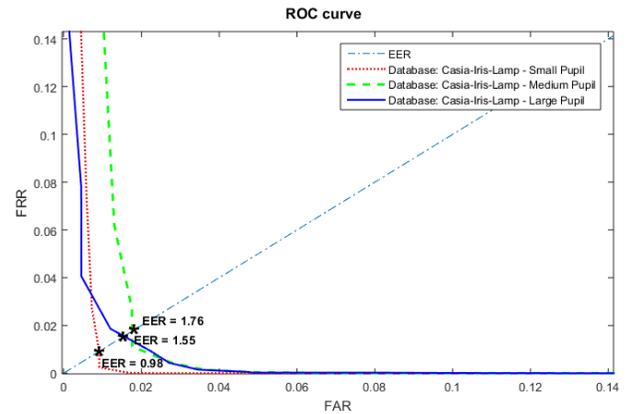


Fig. 4. ROC para os três subconjuntos CASIA-IRIS-Lamp.

C. Experimento 3

Neste experimento as imagens foram exclusivamente da base CASIA-IRIS-Lamp e, obrigatoriamente, a comparação foi feita com amostras pertencentes à subconjuntos diferentes. Nesse caso, as distribuições das distâncias de Hamming referem-se às comparações entre as imagens com taxas de dilatação bem diferentes. A Tabela I mostra, de forma simplificada, as comparações realizadas nesse experimento.

Amostra coletada	Amostra inscrita
Subconjunto (1) (Td < 0,36)	Subconjunto (3) (Td > 0,52)
Subconjunto (1) (Td < 0,36)	Subconjunto (2) (Td < 0,52)
Subconjunto (2) (Td < 0,52)	Subconjunto (3) (Td > 0,52)

As curvas ROC da Fig. 5 determinam as EER para a comparação entre os três subconjuntos. Para a comparação entre os Subconjuntos (1 e 3), (1 e 2) e (2 e 3) as EER foram de 9,69%, 3,52% e 2,64%, respectivamente.

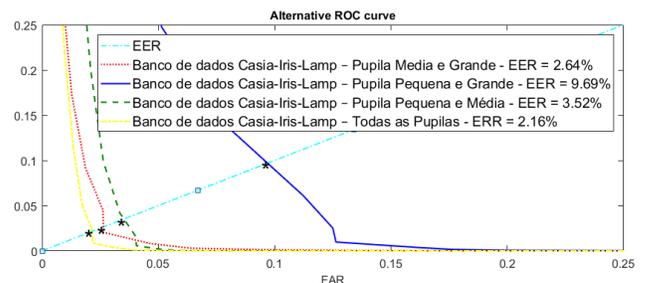


Fig. 5. ROC para a comparação entre os subconjuntos.

Para uma rápida comparação, a Fig. 5 também mostra a EER de 2,16%, referente à verificação utilizando todas as imagens. Lembrando que quanto menor for a EER maior será a capacidade do sistema em classificar corretamente uma amostra.

A média da distribuição das distâncias de Hamming para as comparações entre os Subconjuntos (1) e (2) foi de 0,29 com desvio padrão de 0,0547 e para as distribuições não correspondentes a média foi de 0,47 com desvio padrão de

0,0173. A decidibilidade encontrada foi 4,44.

A média da distribuição das distâncias de Hamming para as comparações entre os Subconjuntos (1) e (3) foi de 0,33, com desvio padrão de 0,0532 e para as distribuições não correspondentes a média foi de 0,47, com desvio padrão de 0,0194. A decidibilidade encontrada foi de 3,50.

Para as comparações entre os Subconjuntos (2) e (3) a média das distribuições correspondentes foi de 0,30, com desvio padrão de 0,0560 e para as distribuições não correspondente a média foi de 0,46, com desvio padrão de 0,0209. A decidibilidade encontrada foi 3,79.

As EER mostradas nas curvas ROC do primeiro experimento indicaram a maior dificuldade do sistema em classificar corretamente as amostras. Para os conjuntos CASIA-IrisV1 e CASIA-IRIS-Lamp as EER foram 0,76 e 2,16, respectivamente. Esse resultado mostra de forma significativa a degradação do sistema quando as imagens apresentam maior variabilidade.

No segundo experimento existe uma indicação que para imagens com a taxa de dilatação intermediária, entre 0,36 e 0,52, a decidibilidade diminui, evidenciando a influência da variação no tamanho da íris, deteriorando a resposta do sistema.

Para imagens com taxa de dilatação menor do que 0,36 e maior do que 0,52 as decidibilidades são próximas. Para o primeiro caso a decidibilidade é de 5,53 e para o segundo caso a decidibilidade é de 5,25, uma diferença de apenas 5%.

Uma possível justificativa para o resultado acima pode ser encontrada no fato de que imagens com baixa taxa de dilatação possuem íris com área maior e, portanto, os pontos amostrados para formar o *template* possuem características mais discriminantes, pois estão mais afastados entre si. Pelo mesmo raciocínio, imagens com maior taxa de dilatação possuem menor área de íris, porém as estruturas da íris estão mais comprimidas formando uma textura com grande quantidade de bordas e cantos que representam características mais discriminantes.

Por outro lado, imagens com taxa de dilatação intermediária apresentam uma textura com baixa frequência e poucas características devido ao menor espaçamento entre os pontos amostrados. Dessa forma, os códigos da íris gerados a partir dessas imagens apresentam poucos bits significativos, aumentando a intersecção das distribuições correspondentes e não correspondentes no ambiente de decisão e diminuindo a decidibilidade.

Assim, verifica-se que o subconjunto com menor taxa de dilatação apresenta a menor EER, 0,98, enquanto o subconjunto com taxa de dilatação intermediária apresenta a maior EER, 1,76, mostrando a influência dos movimentos da íris no processo de reconhecimento.

No terceiro experimento fica mais evidente a influência da dinâmica pupilar no sistema de reconhecimento, pois nas três comparações realizadas, as decidibilidades representam os piores resultados. A decidibilidade de 3,50 na comparação entre os Subconjuntos (1) e (3), que corresponde à comparação entre imagens com pupilas contraídas e pupilas dilatadas, representa o pior resultado.

A decidibilidade para a comparação entre os Subconjuntos

(2) e (3) foi de 3,79 e para a comparação entre os Subconjuntos (1) e (2) foi de 4,44. As EER para o terceiro experimento seguem a mesma direção da decidibilidade. A EER de 9,69 para a comparação entre os Subconjuntos (1) e (3) representa o pior resultado, considerando todos os cenários. A EER para a comparação entre os Subconjuntos (2) e (3) foi de 2,64 e para a comparação entre os Subconjuntos (1) e (2) foi de 3,52.

Verifica-se que o modelo *homogeneous rubber sheet* realmente não é o mais adequado, pois a deformação da íris presente na comparação entre os Subconjuntos (1) e (3) é a máxima possível e, portanto, as características utilizadas na etapa de comparação estão desordenadas.

III. DEFININDO O PROBLEMA

Conforme citado anteriormente, os sistemas de reconhecimento da íris alcançaram alto nível de sucesso sob condições restritas. No entanto, como comprovado por outros autores [8], [9], [11] e [12], e pelos experimentos realizados neste trabalho, ainda existem desafios quando as imagens apresentam alto grau de deformação causado pela variação da iluminação.

De forma geral, a variação do tamanho da íris é desconsiderada quando a imagem é normalizada [14]. Atualmente, alguns trabalhos tratam, de forma parcial, o problema associado com as variações de tamanho entre a íris cadastrada no sistema (*enrollment image*) e a imagem a ser reconhecida ou verificada. Porém, os trabalhos mais relevantes nesta área apenas apresentam modelos matemáticos probabilísticos, aplicados na etapa de normalização ou logo após.

Wei et. al. [12], propuseram um algoritmo de normalização não linear para corrigir a deformação da íris, onde a distância de qualquer ponto da região da íris até a borda da pupila é considerada como sendo a distância da deformação linear mais um desvio aditivo. Como modelo de desvio foi utilizado uma função Gaussiana e os seus resultados comprovaram uma redução na Taxa de Erro Igual (EER) quando comparado com os métodos de normalização lineares.

Thornton et. al. [8], estimaram a máxima probabilidade a posteriori dos parâmetros relativos à deformação, causada por alguma transformação (possivelmente não linear) entre duas imagens, com o objetivo de normalizar o padrão de deformação e retornar uma métrica de similaridade tolerante à esta deformação. Segundo esses autores, esse método probabilístico pode ser utilizado em qualquer tipo de padrão que experimenta deformações não lineares no plano. Seus resultados demonstraram uma significativa melhora na correspondência entre as imagens.

Ma et. al. [2] descreveram um algoritmo capaz de registrar as variações locais da estrutura da íris. O principal objetivo é que os pontos com variações locais bruscas denotem o aparecimento ou o desaparecimento de estruturas importantes da íris que podem ser utilizadas para representar suas características. Dessa forma, por meio de uma classe particular de *wavelets*, um vetor de posições das variações bruscas na imagem normalizada é gravado como característica da íris.

A metodologia empregada neste trabalho foi motivada pelos

trabalhos de Hollingsworth et. al. [15] e Monro et. al [16]. Hollingsworth et. al. [15] abordam a definição de bits frágeis, sugerida por Bolle [17]. Esses autores consideraram que alguns bits do código da íris têm maior probabilidade de inverterem devido ao ruído nas imagens. Desse modo, o processo de quantização dos bits próximos aos eixos de quantização pode ser altamente inconsistente.

Contudo, para a identificação dos bits menos consistentes é preciso armazenar e processar várias imagens da mesma íris. Além disso, Hollingsworth et. al. [15] utilizaram imagens normalizadas e não consideraram a dinâmica da íris e, finalmente, a definição de bits frágeis só se aplica aos sistemas baseados na proposta de Daugman, onde os coeficientes complexos da saída do filtro de textura são transformados em um código composto por bits.

Nessa transformação em dois bits na saída do filtro, o primeiro bit será igual a 1 se a parte real do coeficiente for positiva e o segundo bit será igual a 1 se a parte imaginária for positiva. Se uma região da íris for associada ao coeficiente complexo com a parte imaginária positiva, porém próxima a zero, então pequenos ruídos neste coeficiente podem alternar o código binário desta região de 11, em algumas situações para 10 em outras situações. Assim, é possível dizer que o bit em questão pode ser considerado um bit frágil, interferindo na precisão do sistema de reconhecimento.

Por sua vez, Monro et al. [16] utilizaram a transformada discreta do cosseno (DCT) para a extração de características da imagem normalizada da íris. Eles aplicaram a DCT em regiões retangulares sobrepostas. As diferenças entre os coeficientes da DCT para regiões adjacentes são então calculadas e um código binário é gerado a partir de seus cruzamentos por zero. Com a finalidade de aumentar a velocidade da correspondência, os três coeficientes mais discriminantes da DCT são mantidos e os restantes são desconsiderados.

Mais uma vez, os autores utilizaram imagens normalizadas e não consideraram a dinâmica da íris. Além disso, é necessário estimar e subtrair o nível de iluminação de cada imagem para tentar nivelar os coeficientes da DCT.

Dessa forma, considerando um ambiente mais real, espera-se um incremento na inconsistência entre os códigos gerados a partir da mesma íris, não só pela proximidade dos coeficientes complexos em relação aos eixos, mas também pela dinâmica do tecido da íris. Essa hipótese é reforçada pelos experimentos realizados neste trabalho e também pelos motivos citados anteriormente, resumidos nos itens a seguir:

A pressão no tecido da íris durante seu movimento pode fazer com que algumas pequenas regiões se dobrem por baixo de outras. Isso significa que pequenas partes do padrão desaparecerá e nenhum modelo de deformação será capaz de representar essa transformação [8];

Sob forte compressão, a textura da íris produz uma imagem normalizada com muitas diferenças da imagem normalizada em condições normais [8] e [9]. Dessa forma, as regiões não influenciadas ou menos influenciadas pelos movimentos da íris devem fornecer informações suficientes para o processo de reconhecimento;

O modelo *homogeneous rubber sheet* não representa a

verdadeira deformação do tecido da íris e, segundo Wyatt [11], um modelo não linear é mais adequado.

Como citado anteriormente, a íris é formada por pequenos blocos irregulares com distribuição aleatória e constituídos por estrias, criptas, sulcos, sardas e assim por diante. Essa distribuição aleatória e o conjunto de blocos representam as características mais distintas da íris.

Infelizmente, a posição de cada bloco e sua variação local também são aleatórias quando se leva em consideração o deslocamento não linear do tecido da íris durante sua contração e dilatação.

Assim, para resolver o problema da aleatoriedade e alinhar corretamente as características a serem comparadas, este trabalho propõe o uso do histograma de gradientes orientados (HoG) para descrever os movimentos realizado pelo tecido da íris, associado ao algoritmo *Dynamic Time Warping* (DTW) para alinhar as características que sofreram deformações não lineares e calcular a similaridade entre a imagem armazenada e a imagem de teste.

Por serem bem conhecidos, os algoritmos das técnicas utilizadas não serão detalhados aqui. Para maiores informações sobre HoG vide [18] e para DTW vide [19] e [20].

A abordagem proposta baseia-se na técnica de reconhecimento parcial da íris, onde o teste de correspondência entre as imagens é feito apenas nas regiões mais similares, considerando o estado de contração e dilatação da íris. O objetivo é aumentar a decidibilidade e diminuir a EER de sistemas que utilizam imagens dinâmicas.

IV. IMPLEMENTAÇÃO

O Diagrama de blocos da Fig. 6 demonstra a etapa proposta para a criação do que será denominado de "máscara dinâmica". O histograma de gradientes orientados é calculado para a imagem inscrita na galeria e para a imagem de teste. O HoG das imagens forma vetores de características que são alinhados e comparados pela DTW.

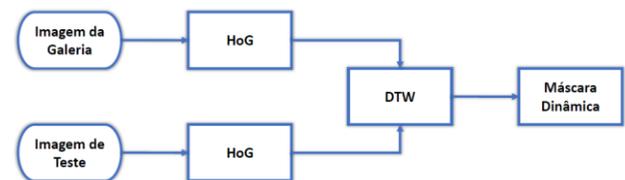


Fig. 6. Diagrama de blocos do sistema de alinhamento das características dinâmicas.

Os histogramas das células pertencentes à mesma posição espacial da imagem inscrita e da imagem de teste são denominados histogramas correspondentes por fornecerem os vetores de características das regiões correspondentes entre as imagens. As células correspondentes (ou histogramas correspondentes), que possuem grau de similaridade menor que um determinado limiar, são descartadas no processo de reconhecimento. Para isso, a máscara dinâmica é gerada para indicar a posição destas células.

Da Fig.7 a Fig. 12 tem-se o *template* de uma imagem da galeria, sua máscara de ruído determinada pelo sistema, um

template de teste e sua máscara de ruído e, finalmente a máscara dinâmica que indica a região onde a similaridade entre as imagens é menor que o limiar adotado, respectivamente. Para a máscara dinâmica da Fig. 8, o limiar adotado foi determinado empiricamente considerando a similaridade máxima encontrada entre as células menos quatro vezes o desvio padrão.



Fig. 7. Template da imagem inscrita na galeria.



Fig. 8. Template da imagem de teste.



Fig. 9. Máscara de ruído da imagem da galeria.



Fig. 10. Máscara de ruído da imagem de teste.



Fig. 11. Máscara dinâmica da imagem inscrita na galeria.



Fig. 12. Máscara dinâmica da imagem de teste.

V. RESULTADOS

Os experimentos 2 e 3 foram repetidos para avaliar a eficácia da técnica proposta, porém as máscaras de ruído foram transformadas em máscaras dinâmicas. As novas distribuições de distância de Hamming e as novas curvas ROC, do experimento 2, que representam a saída do sistema de reconhecimento para os subconjuntos (1), (2) e (3) são apresentadas nas Figs. 13, 14 e 15, respectivamente.

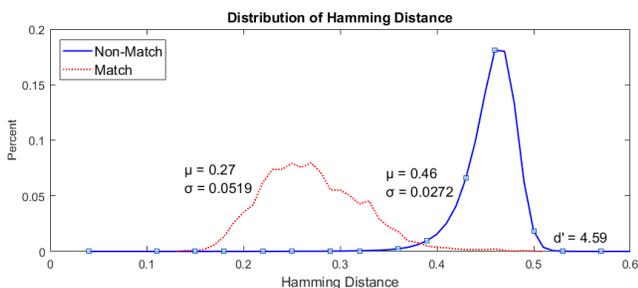


Fig. 13. Distribuição das distâncias de Hamming de acordo com a taxa de dilatação utilizando máscara dinâmica Taxa de dilatação <0,36 e máscara dinâmica.

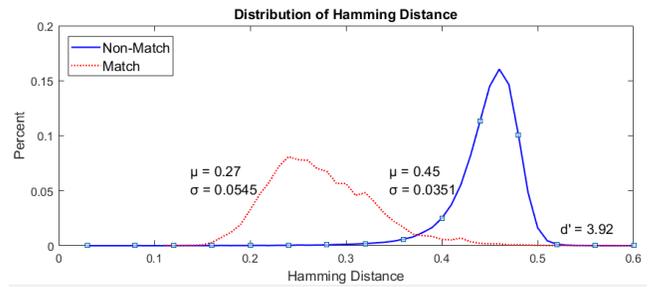


Fig. 14. Distribuição das distâncias de Hamming de acordo com a taxa de dilatação utilizando máscara dinâmica Taxa de dilatação < 0,36 e > 0,52 e máscara dinâmica.

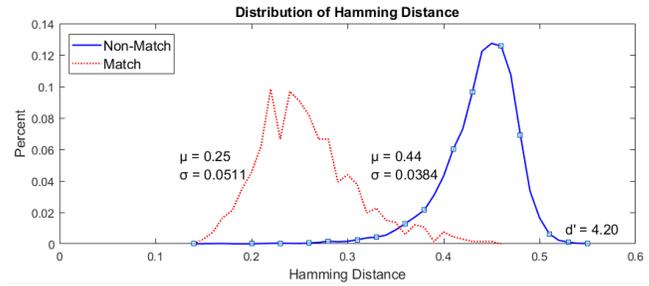


Fig. 15. Distribuição das distâncias de Hamming de acordo com a taxa de dilatação utilizando máscara dinâmica Taxa de dilatação > 0,52 e máscara dinâmica.

Considerando o desempenho da máscara dinâmica, elaborada para cada comparação entre as imagens do Subconjunto (1), a média das distribuições correspondentes foi de 0,27, com desvio padrão de 0,0519. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,46, com desvio padrão de 0,0272 e a decidibilidade encontrada foi 4,59.

Da mesma forma, considerando o desempenho da máscara dinâmica, elaborada para cada comparação entre as imagens do Subconjunto (2), a média das distribuições correspondentes foi de 0,27, com desvio padrão de 0,0545. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,45, com desvio padrão de 0,0351 e a decidibilidade encontrada foi 3,92.

Finalmente, considerando o desempenho da máscara dinâmica, elaborada para cada comparação entre as imagens do Subconjunto (3), a média das distribuições correspondentes foi de 0,25, com desvio padrão de 0,0511. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,44, com desvio padrão de 0,0384 e a decidibilidade encontrada foi 4,20.

As curvas ROC da Fig. 16 determinam as EER para os três subconjuntos, considerando o desempenho da máscara dinâmica. Para os Subconjuntos (1), (2) e (3) as EER foram de 2,51%, 4,63% e 4,84%, respectivamente. A Fig. 16 também mostra a EER de 4,64% referente à comparação entre todas as imagens dos Subconjuntos (1), (2) e (3).

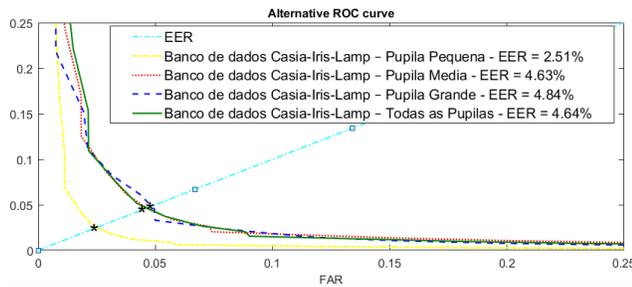


Fig. 16. ROC para os três intervalos de Td utilizando a máscara dinâmica.

O sistema apresenta precisão e especificidade de 90% para o Subconjunto (1), onde a taxa de dilatação é a menor. O Subconjunto (2) possui uma precisão e uma especificidade de 89%. O Subconjunto (3) possui uma precisão e uma especificidade de 87%. A sensibilidade para os Subconjuntos (1), (2) e (3) foi de 98%, 96% e 87%, respectivamente.

As novas distribuições de distância de Hamming e as novas curvas ROC, do experimento 3, que representam a saída do sistema de reconhecimento para os Subconjuntos (1 e 2), (1 e 3) e (2 e 3) são apresentadas nas Figs. 17, 18, 19 e 20, respectivamente.

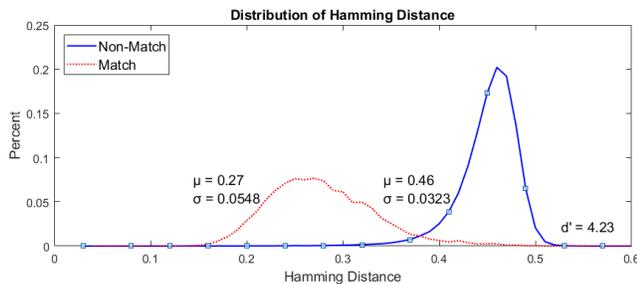


Fig. 17. Comparações entre os Subconjuntos (1) e (2) utilizando máscara dinâmica.

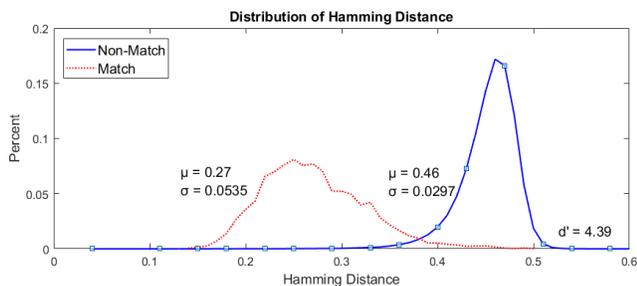


Fig. 18. Comparações entre os Subconjuntos (1) e (3) utilizando máscara dinâmica.

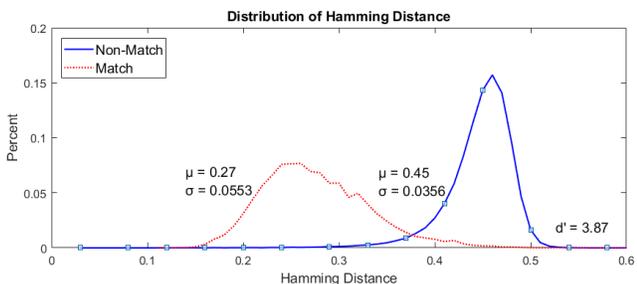


Fig. 19. Comparações entre os Subconjuntos (2) e (3) utilizando máscara dinâmica.

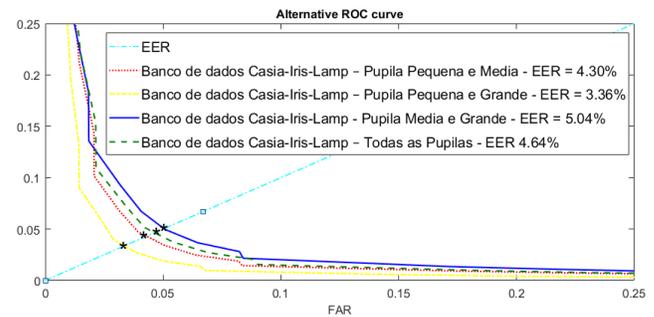


Fig. 20. ROC para a comparação entre os subconjuntos utilizando máscara dinâmica.

Considerando o desempenho da máscara dinâmica, elaborada para cada comparação entre as imagens dos Subconjuntos (1) e (2), a média das distribuições correspondentes foi de 0,27, com desvio padrão de 0,0548. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,46, com desvio padrão de 0,0323 e a decidibilidade encontrada foi 4,23.

Da mesma forma, considerando o desempenho da máscara dinâmica, elaborada para cada comparação entre as imagens dos Subconjuntos (1) e (3), a média das distribuições correspondentes foi de 0,27, com desvio padrão de 0,0535. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,46, com desvio padrão de 0,0297 e a decidibilidade encontrada foi 4,39.

Finalmente, considerando o desempenho da máscara dinâmica, elaborada para cada comparação entre as imagens dos Subconjuntos (2) e (3), a média das distribuições correspondentes foi de 0,27, com desvio padrão de 0,0553. Para as distribuições não correspondentes do mesmo subconjunto a média foi de 0,45, com desvio padrão de 0,0356 e a decidibilidade encontrada foi 3,87.

As curvas ROC da Fig. 21 determinam as EER para os três subconjuntos, considerando o desempenho da máscara dinâmica. Para os Subconjuntos (1 e 2), (1 e 3) e (2 e 3) as EER foram de 4,30%, 3,36% e 5,04%, respectivamente. A Fig. 20 também mostra a EER de 4,64% referente à comparação entre todas as imagens dos Subconjuntos (1), (2) e (3).

O sistema apresenta uma precisão e um especificidade de 91% para as comparações entre as imagens dos Subconjuntos (1) e (2). A comparação entre as imagens dos Subconjunto (1) e (3) possui uma precisão e uma especificidade de 88%. A comparação entre as imagens dos Subconjuntos (2) e (3) possui uma precisão e uma especificidade de 88%.

A sensibilidade, a especificidade e a precisão para a comparação entre todas as imagens dos Subconjuntos (1), (2) e (3) foi de 96%, 86% e 86%, respectivamente.

VI. CONCLUSÕES

Os resultados experimentais indicam que a técnica utilizada não é indicada para comparações entre as imagens com taxas de dilatação próximas. Na repetição do experimento 2, utilizando a máscara dinâmica, os resultados da decidibilidade e da EER pioraram. Para o subconjunto (1) a decidibilidade passou de 5,53, sem máscara para 4,59 com máscara. Para o subconjunto

(2) a decidibilidade passou de 4,78, sem máscara para 3,92 com máscara. Finalmente, para o subconjunto (3) a decidibilidade passou de 5,24, sem máscara para 4,20 com máscara.

Para o subconjunto (1) a EER passou de 0,98%, sem máscara para 2,51% com máscara. Para o subconjunto (2) a EER passou de 1,76%, sem máscara para 4,63% com máscara. Finalmente, para o subconjunto (3) a EER passou de 1,55%, sem máscara para 4,84% com máscara.

Esse resultado já era esperado, pois as taxas de dilatação das imagens de cada subconjunto são próximas e, portanto, qualquer perda de informação provocada pela máscara dinâmica prejudica ainda mais a performance do sistema, conforme comprova também os valores das matrizes de confusão.

Na repetição do experimento 3, utilizando a máscara dinâmica, as comparações entre as imagens dos Subconjuntos (1 e 2) e (2 e 3) também não tiveram melhoria nos resultados. Contudo, os resultados comprovam que a utilização da técnica proposta é útil no teste de comparação que envolve as imagens dos Subconjuntos (1) e (3). Estes subconjuntos são constituídos pelas imagens com menores e maiores taxas de dilatação, portanto a variação da área da íris e sua deformação não linear estão mais evidentes.

A decidibilidade e a EER para a comparação entre as imagens dos Subconjuntos (1) e (3), sem o uso da máscara dinâmica foi de 3,5 e 9,69%, respectivamente. Com o uso da máscara dinâmica a decidibilidade e a EER passaram para 4,39 e 3,36% respectivamente.

A matriz de confusão mostra um aumento no valor preditivo positivo e na sensibilidade, de 0,078 para 0,11 e de 0,83 para 0,97, respectivamente. Esse fato indica uma taxa maior de verdadeiro positivo, porém a precisão do sistema fica menor devido ao aumento na taxa de falso positivo, indicada pela especificidade que passou de 0,97 para 0,88.

AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de Minas Gerais – FAPEMIG, pelo apoio e suporte financeiro.

REFERÊNCIAS

- [1] J. Daugman, “How iris recognition works”, *Circuits Syst. Video Technol.* IEEE Trans., vol. 14, no. 1, pp. 21–30, 2004.
- [2] L. Ma, T. Tan, Y. Wang, and D. Zhang, “Efficient iris recognition by characterizing key local variations”, *IEEE Trans. Image Process.*, vol. 13, no. 6, pp. 739–50, Jun. 2004.
- [3] J. Daugman, “How Iris Recognition Works”, *Essent. Guid. to Image Process.*, vol. 14, no. 1, pp. 715–739, 2009.
- [4] J. Daugman, “New methods in iris recognition”, *IEEE Trans. Syst. Man. Cybern. B. Cybern.*, vol. 37, no. 5, pp. 1167–1175, 2007.
- [5] R. P. Wildes et al., “A system for automated iris recognition”, *Proc. 1994 IEEE Work. Appl. Comput. Vis.*, pp. 121–128, 1994.
- [6] S. Lim, K. Lee, O. Byeon, and T. Kim, “Efficient iris recognition through improvement of feature vector and classifier”, *ETRI J.*, vol. 23, no. 2, pp. 61–70, 2001.
- [7] Z. Zainal Abidin, M. Manaf, A. S. Shibghatullah, S. H. A. Mohd Yunos, S. Anawar, and Z. Ayop, “Iris Segmentation Analysis using Integro-Differential Operator and Hough Transform in Biometric System”, *J. Telecommun. Electron. Comput. Eng.*, vol. 4, no. 2, pp. 41–48, 2012.
- [8] J. Thornton, M. Savvides, and B. V. K. Vijaya Kumar, “A bayesian approach to deformed pattern matching of iris images”, *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 29, no. 4, pp. 596–606, Apr. 2007.
- [9] J. Z. Huang, T. N. Tan, L. Ma, and Y. H. Wang, “Phase correlation based iris image registration model”, *J. Comput. Sci. Technol.*, vol. 20, no. 3, pp. 419–425, 2005.
- [10] J. G. 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.
- [11] H. J. Wyatt, “A ‘minimum-wear-and-tear’ meshwork for the iris”, *Vision Res.*, vol. 40, no. 16, pp. 2167–76, Jan. 2000.
- [12] Z. Wei, T. Tan, and Z. Sun, “Nonlinear Iris Deformation Correction Based on Gaussian Model”, *Adv. Biometrics*, pp. 780–789, 2007.
- [13] Masek, Libor “Recognition of human iris patterns for biometric identification”, 2003.
- [14] K. Hollingsworth, K. W. Bowyer, and P. J. Flynn, “Pupil dilation degrades iris biometric performance”, *Comput. Vis. Image Underst.*, vol. 113, no. 1, pp. 150–157, 2009.
- [15] K. P. Hollingsworth, K. W. Bowyer, and P. J. Flynn, “The best bits in an Iris code”, *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 31, no. 6, pp. 964–973, 2009.
- [16] D. M. Monro, S. Rakshit, and S. Member, “DCT-Based Iris Recognition”, *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 29, no. 4, pp. 586–595, 2007.
- [17] R. M. Bolle, S. Pankanti, J. H. Connell, and N. K. Ratha, “Iris individuality: A partial iris model”, *Proc. - Int. Conf. Pattern Recognit.*, vol. 2, pp. 927–930, 2004.
- [18] N. Dalal and W. Triggs, “Histograms of Oriented Gradients for Human Detection”, 2005 *IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit. CVPR05*, vol. 1, no. 3, pp. 886–893, 2004.
- [19] Q. Chen, G. Hu, F. Gu, and P. Xiang, “Learning optimal warping window size of DTW for time series classification”, 2012 11th *Int. Conf. Inf. Sci. Signal Process. Appl. ISSPA 2012*, pp. 1272–1277, 2012.
- [20] S. Salvador and P. Chan, “FastDTW : Toward Accurate Dynamic Time Warping in Linear Time and Space”, *Intell. Data Anal.*, vol. 11, pp. 561–580, 2007.



Paulo Ricardo da Silva nasceu em Araxá - MG, Brasil. Graduado em Engenharia Elétrica pela Universidade Federal do Triângulo Mineiro – UFTM e mestre em Engenharia Elétrica na área de Eletrônica de Potência na Universidade Federal de Uberlândia UFU. Seus interesses em pesquisa incluem processamento digital de sinais, processamento digital de imagens, desenvolvimento e concepção de topologias de conversores, eletrônica de potência, correção de fator de potência e implementação de controle digital baseada em DSP.



Cláriton Rodrigues Bernadelli nasceu na cidade de Araporã - MG, Brasil. Recebeu o título de Doutor em Processamento de sinais em 2016 pela Programa de Pós-graduação da Faculdade de Engenharia Elétrica da Universidade Federal de Uberlândia. Atualmente é professor do curso de engenharia elétrica da Universidade Federal do Triângulo Mineiro. Seus interesses em pesquisa incluem processamento digital de imagens, processamento digital de sinais e comunicações digitais.