

# Reconhecimento de Íris em Ambientes Não Cooperativos Utilizando Wavelets e Gabor 2D

Sirlene Pio  
UFOP

sirlenepg@gmail.com

Fernanda Maria Ribeiro  
UFOP

fernandamaria\_si@yahoo.com.br

## Abstract

*Ainda há muitas questões em aberto relacionadas ao reconhecimento de íris em ambientes não cooperativos. Pesquisas na área têm se direcionado principalmente para os métodos de extração de características e classificação. Neste, trabalho reimplementamos um método que divide a íris em regiões, extrai características em cada região e aplica um esquema particular de classificação que utiliza um conjunto ordenado e crescente de seis limiares para minimizar as taxas de falsa rejeição e de falsa aceitação. Realizamos experimentos em duas bases de dados amplamente utilizadas, CASIA e UBIRIS, adotando diferentes extratores de características. A combinação entre a abordagem utilizada no método original, Filtro de Gabor 2D, e Wavelets obteve as menores EERs em ambas bases de dados.*

## 1. Introdução

A identificação de pessoas sempre foi necessária, os métodos de identificação são cada vez mais estudados e aprimorados com o intuito de impedir falsificações. Inicialmente era realizada através de um nome, depois um número de identificação (CPF - Cadastro de Pessoas Físicas), na atualidade, com o uso de biometria, onde são avaliadas características únicas de cada indivíduo. Na biometria digital cada indivíduo é identificado através de sua digital, o problema é que esta pode se degradar com o tempo ou com o tipo de atividade que o indivíduo desempenha tornando difícil sua identificação. Outro problema é que esta pode ser deixada em diversos lugares por um simples toque.

Outra técnica de biometria que está sendo muito discutida é a de reconhecimento de íris, onde cada indivíduo possui características únicas, sendo diferente a cada olho, o que torna mais difícil sua fraude. Em ambientes de análise fixos, a curtas distâncias e em bases menores, existem atualmente métodos eficientes para identificação correta. Mas a questão principal é como identificá-la sobre condições adversas em

ambientes naturais.

Assim um dos grandes problemas na utilização da biometria em íris é o seu reconhecimento a certa distância, em movimento, e com uso de alguns acessórios como lentes e óculos. As dificuldades também aumentam ao tentar realizar a caracterização sobre uma grande base de dados, com imagens degradadas por reflexos de luz e outros ruídos, onde um erro de identificação pode causar grandes danos.

Atualmente existem diversas técnicas aplicadas para o reconhecimento de íris com o intuito de superar as dificuldades de classificação causadas por este problema. Neste trabalho preliminar, propõe-se a reimplementação de um método de reconhecimento de íris em ambientes não-cooperativos que utiliza múltiplas assinaturas/características extraídas de seis sub-regiões distintas e sobrepostas da íris para melhorar a descrição de imagens de íris ruidosas [6]. Os autores também usam um esquema particular e interessante de classificação que utiliza um conjunto ordenado e crescente de seis limiares para minimizar a taxa de falsa rejeição relacionando-os com as dissimilaridades obtidas das seis sub-regiões da íris entre a imagem consultada e a imagem registrada. A combinação do método de extração de características utilizado em [6], Representação Gabor 2D, com outro método que se baseia em Wavelets, obteve os melhores resultados em nossos experimentos nas bases de dados CASIA e UBIRIS.

Este artigo apresenta na seção 2 alguns trabalhos relacionados ao reconhecimento de íris em ambientes não cooperativos. Na seção 3 é apresentada a metodologia. A seção 4 detalha os experimentos realizados. Encerrando na seção 5, com uma breve conclusão e possíveis trabalhos futuros.

## 2. Trabalhos Relacionados

No modelo seminal proposto por Daugman em 1993 [3] o Filtro de Gabor 2D é utilizado para extrair as características da imagem normalizada e gerar o vetor binário, conhecido como *IrisCode*. Esse modelo [3] ainda é visto como referência para o desenvolvimento de sis-

temas/métodos de reconhecimento de íris, porém não é robusto quando as imagens são adquiridas em ambientes não cooperativos. O problema de representar as informações presentes na íris de imagens degradadas é frequentemente abordado e investigado em trabalhos relacionados ao reconhecimento de íris em ambientes não cooperativos.

Em [6], o método proposto se baseia na divisão da íris segmentada em seis sub-regiões, seguido pela extração de características independentes em cada uma delas. Além disso, por meio da comparação entre as assinaturas extraídas das correspondentes regiões da íris, são obtidos seis valores de dissimilaridade que são fundidos por meio de uma regra de classificação.

No método proposto em [7] a imagem da íris segmentada é adicionalmente processada usando a remoção do canal azul, conversão de imagem para monocromática, equalização do histograma e remoção de reflexões, cílios e oclusões causadas pela palpebra. Os autores também analisam e escolhem a melhor wavelet para extração de características da íris.

### 3. Metodologia

Em [6], os autores melhoraram o método de reconhecimento descrito por Daugman [3] por meio de uma estratégia de partição da íris, criando dessa forma características mais robustas para o reconhecimento de íris em ambientes não cooperativos. A Figura 1 apresenta as etapas de desenvolvimento desse método.

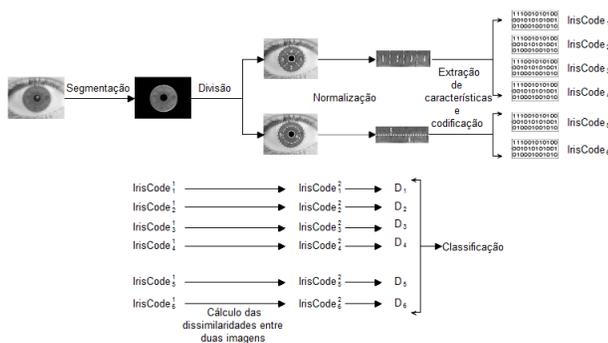


Figure 1. Etapas de desenvolvimento do método proposto em [6]

O método proposto se baseia na divisão da íris segmentada em seis sub-regiões, seguido pela extração de características independentes em cada uma delas. Além disso, através da comparação entre as assinaturas extraídas das correspondentes regiões da íris, são obtidos seis valores de dissimilaridade que são fundidos por meio de uma regra de classificação. Segundo [6], a extração de características e comparação independente de cada uma dessas sub-regiões evita que um eventual ruído, localizado em algum desses setores da íris, corrompa toda a assinatura biométrica. Neste

trabalho implementamos o mesmo método, os detalhes são descritos nas Subseções 3.1, 3.2, 3.1, 3.3, 3.4 e 3.5.

Além de implementar o método proposto em [6], visando melhorar a representação das informações contidas na íris, e consequentemente obtermos EER (Equal error rate) menores, incluímos Wavelets na etapa de extração de características. Ela é descrita na Subseção 3.3.

### 3.1. Segmentação

A segmentação consiste em localizar e extrair a área que contém a textura da íris da imagem capturada. Implementamos o método de segmentação proposto por [3] e utilizado em [6] para localizar a íris e a pupila nas imagens da base CASIA. O método citado não se mostrou robusto para segmentar imagens da base UBIRIS, então, essas foram segmentadas manualmente.

### 3.2. Normalização

O processo de normalização é conhecido como a Modelo Folha de Borracha [3] que consiste em: cada ponto  $(x, y)$ , pertencente a região de íris, é mapeado em um ponto representado em coordenadas polares pelo par  $(r, \theta)$ , de acordo com as Equações 1, 2 e 3. A Figura 2 ilustra esse processo.

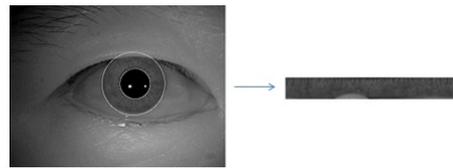


Figure 2. Mapeamento da região da íris para um formato normalizado.

$$I(x(r, \theta), y(r, \theta)) \rightarrow I_{norm}(r, \theta) \quad (1)$$

$$x(r, \theta) = (1 - r)x_p(\theta) + rx_i(\theta) \quad (2)$$

$$y(r, \theta) = (1 - r)y_p(\theta) + ry_i(\theta) \quad (3)$$

onde  $I$  é a matriz que contém os pixels da imagem capturada,  $I(x, y)$  é um ponto desta matriz;  $I_{norm}$  é a matriz normalizada,  $(r, \theta)$  é a posição correspondente a  $(x, y)$  na matriz normalizada (representada em coordenadas polares),  $(x_p, y_p)$  e  $(x_i, y_i)$  são as coordenadas dos centros das circunferências que modelam a pupila e a íris, respectivamente e  $r \in [0, 1]$ . Em [3]  $\theta \in [0, 2\pi]$ , neste trabalho como a imagem normalizada será dividida em seis sub-regiões (Figura 3)  $\theta \in [-\frac{\pi}{4}, \frac{7\pi}{4}]$ .

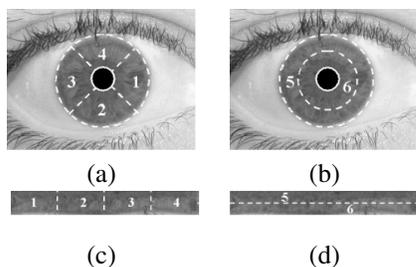


Figure 3. Extração de características: (a) Divisão da íris em quatro partes diferentes, (b) Divisão da íris em parte "exterior" e parte "interna", (c) Imagem normalizada correspondente à (a) e (d) Imagem normalizada correspondente a (b)

### 3.3. Extração de características

Neste trabalho, utilizamos a Representação Gabor 2D [6] e Wavelets [7] para extrair as características. Destacamos que o processo de extração de características, seja qual for a técnica (Representação de Gabor 2D ou Wavelet) utilizada, consiste na criação de seis assinaturas biométricas independentes, cada uma delas correspondente a uma região específica da íris.

#### 3.3.1 Representação Gabor 2D

O processo de extração de atributos utilizando o Filtro de Gabor 2D consiste em decompor o sinal de entrada, imagem normalizada, utilizando um par de filtros de Gabor em quadratura: uma parte real, especificada por uma função cosseno modulada por uma Gaussiana, e uma parte imaginária, especificada por uma função seno, também modulada por uma Gaussiana. Estes filtros espaciais têm a forma  $G(x, y) = e^{-\pi\phi} \cdot e^{-2\pi i\psi}$ , com

$$\phi = \left[ \frac{(x - x_0)^2}{\alpha^2} + \frac{(y - y_0)^2}{\beta^2} \right]$$

$$\psi = [u_0(x - x_0) + v_0(y - y_0).]$$

onde  $(x_0, y_0)$  representam uma posição na imagem,  $(\alpha, \beta)$  especificam a largura e o comprimento do filtro e  $(u_0, v_0)$  representam a modulação, com frequência espacial dada por  $W_0 = \sqrt{u_0^2 + v_0^2}$ . Basicamente, é realizado a projeção do Filtro de Gabor em blocos de dimensões fixas para se obter um conjunto de filtros centralizados na qual são utilizados como parâmetros  $\alpha$  e  $\beta$  variando com o inverso da frequência  $W_0$  [4].

#### 3.3.2 Wavelet

Wavelets são ondoletas usadas para decomposição de outras funções, através de vários filtros. A transformada Wavelet é um modelo de extração de características baseado em janelas que possuem área fixa, mas que varia a largura e comprimento com o tempo.

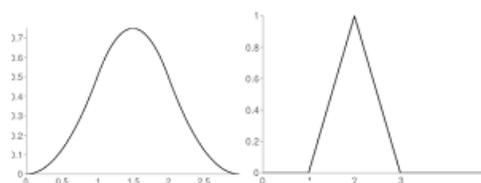


Figure 4. rbio2.2: imagem a esquerda, rbio3.1: imagem a direita

Existem diversas famílias de wavelets, tendo cada uma diversas variações, como: Haar, Daubechies, Symlets, Coiflets, Discrete Meyer, Biorthogonal (bior1.3, bior2.2, bior6.8) e a Reverse biorthogonal (rbio1.3, rbio2.2, rbio3.1, rbio3.3, rbio6.8).

Dentre estas se escolheu para a utilizada nos experimentos aquela que obteve os melhores resultados no artigo [7], no caso a rbio3.1 (Wavelet Reverse Biorthogonal 3.1) e a rbio2.2 (Wavelet Reverse Biorthogonal 2.2) ilustradas na Figura 4, que faz a decomposição do sinal e reconstrói este atribuindo zero as partes filtradas obtendo novamente o sinal com ótimos resultados.

A representação matemática da decomposição e formação do sinal pode ser representada pela formula abaixo, onde o sinal da imagem pode ser representado por  $j$ -escala componentes- e  $k$ -deslocamentos-. A variável  $d_j$  representa os coeficientes dos detalhes e  $a_j$  os coeficientes escalares obtidos. A formula faz o calculo da representação de um sinal  $S$  através da wavelet somando se todos coeficientes escalares -aproximação- mais os coeficientes dos somatórios de todos os detalhes obtidos - detalhes horizontais, verticais e diagonais de cada vector, nas  $k$  decomposições[7].

$$S = \sum_k a_{j,k} \Phi_{j,k} + \sum_{j=1}^j \sum_k d_{j,k} \Psi_{j,k} = A_j + \sum_{j=1}^j D_j$$

A wavelet trabalha com dois filtros na decomposição do sinal: filtro de baixa frequência (low-pass  $\Phi_{j,k}$ ) e filtro de alta frequência (high pass  $\Psi_{j,k}$ ) que geram respectivamente os coeficientes de aproximação e os detalhes. Os detalhes possuem três dimensões de vetores de características que são das dimensões horizontais, verticais e diagonais. Estas são decompostas em quantos níveis se achar necessário.

$$\Phi_{j,k}(t) = \sum h_1(k) \Psi_{j-1,k}(t)$$

$$\Psi_{j,k}(t) = \sum h_0(k) \Psi_{j-1,k}(t)$$

### 3.4. Codificação

A etapa de codificação gera o vetor binário, conhecido como *IrisCode*. As estratégias de codificação para a Representação Gabor e para a Wavelet são descritas a seguir.

#### 3.4.1 Representação Gabor 2D

Para cada valor complexo de saída após a aplicação do filtro de Gabor 2D sobre a sub-região da imagem normalizada, o valor de fase  $\phi$  é decodificado em uma das quatro possibilidades apresentadas na Figura 5, ou seja, dado um valor de fase, verifica-se em qual quadrante este se localiza e então o substitui por dois bits. Por meio da extração de características e codificação, obtivemos os seis *IrisCode* uma para cada região da íris.

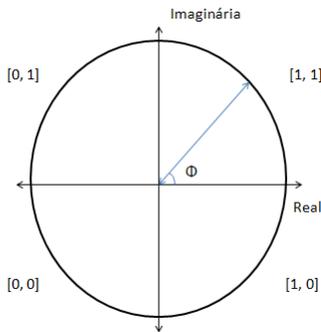


Figure 5. Representação do processo de demodularização e a formação de um vetor binário conhecido como *IrisCode*.

#### 3.4.2 Wavelet

O *IrisCode* é obtido através:

$$\begin{cases} \text{IrisCode}(x, y) = 0, \text{ se } V_i^l < \text{mediana}(V_i^l) \\ \text{IrisCode}(x, y) = 1, \text{ se } V_i^l \geq \text{mediana}(V_i^l) \end{cases} \quad (4)$$

onde  $V_i^l$  é o  $i$ -ésimo coeficiente vertical no nível  $l$ .

### 3.5. Classificação

Inicialmente, calcula-se a dissimilaridade entre duas imagens em todas as seis sub-regiões  $D_i = HD(I_i^1, I_i^2)$ , sendo  $i = 1, \dots, N$  ( $N$  é o número de sub-regiões),  $I_i^1$  a sub-região  $i$  da imagem 1,  $I_i^2$  a sub-região  $i$  da imagem 2. Para calcular a dissimilaridade entre duas imagens foi utilizada a Distância de Hamming (HD). Dado dois conjuntos binários  $A = \{a_1, \dots, a_N\}$  e  $B = \{b_1, \dots, b_N\}$  a Distância de Hamming é dada por  $HD(A, B) = \frac{1}{N} * \sum_{i=1}^N a_i \otimes b_i$ , onde  $a_i \otimes b_i$  é a operação lógica XOR.

Dado os conjuntos de dissimilaridade  $D_i = [D_1, \dots, D_N]$  e de limiares  $T_i = [T_1, \dots, T_N]$ , o próximo passo é contar o número de  $D_j \in D$  que são menores ou iguais a  $T_i$ :

$$C(D, T_i) = \sum_{j=1}^N II_{\{D_j \leq T_i\}}, \quad (5)$$

As imagens  $I^1$  e  $I^2$  serão classificadas como correspondentes à mesma íris se:

$$\exists_i : C(D, T_i) \geq i, i = 1, \dots, N. \quad (6)$$

Usando as Equações 8 e 9, realizamos uma busca exaustiva no intervalo  $[0, 1]$  para os seguintes valores de incremento  $[0, 1; 0, 05; 0, 025; 0, 01]$ , com o objetivo de encontrar o conjunto de limiares  $T_i = [T_1, \dots, T_N]$  que minimizasse a taxa de erro EER. Seja  $T_i = [T_1, \dots, T_N]$ ,  $T_i \in \mathbb{R}^+$  um conjunto de  $N$  valores de limiares:

$$T_i \leq T_j, \forall i < j \quad (7)$$

A FAR (False Acceptance Rate) equivale a probabilidade de ocorrência de Erro do Tipo I. O Erro do Tipo I, também conhecido como  $\alpha$ -erro ou falso positivo, acontece quando aceita-se como genuína uma coisa que é falsa. A FRR (False Rejection Rate) equivale a probabilidade de ocorrência de Erro do Tipo II. O Erro do Tipo II, também conhecido como  $\beta$ -erro ou falso negativo, acontece quando rejeitamos algo que deveria ter sido aceito.

$$FAR = \sum_{i=1}^6 P \left( C(D^E, T_i) \geq i, \bigcap_{j=1}^{i-1} C(D^E, T_j) < j \right), \quad (8)$$

$$FRR = \prod_{i=1}^6 P (C(D^I, T_i) < i). \quad (9)$$

onde  $D^E$  representa o conjunto de dissimilaridades interclasse e  $D^I$  o conjunto de dissimilaridades intraclasse.

### 3.6. Bases de Dados

A base de dados CASIA-IrisV4 [1] é de longe a mais amplamente usada para testar sistemas de reconhecimento de íris. CASIA-IrisV4 [1] contém um total de 54.601 íris imagens de mais de 1.800 indivíduos naturais e 1.000 indivíduos virtuais. A Figura 6(a) apresenta um exemplo de imagem da base de dados CASIA.

Na base de dados UBIRIS.v2 [5] as imagens foram capturadas em condições não restritas (em diferente distâncias, em movimento e no comprimento de onda visível) com os correspondentes fatores de ruído mais realistas. UBIRIS.v2 [5] contém um total de 11.102 imagens

de íris de mais de 261 indivíduos. A Figura 6(b) apresenta um exemplo de imagem da base de dados UBIRIS.

Nos experimentos, utiliza-se 800 imagens de 80 indivíduos (10 imagens por indivíduo) da base de dados UBIRIS e 800 imagens da base de dados CASIA. Dessas 800 imagens de cada base de dados, 400 imagens de 40 indivíduos foram utilizadas no treino de forma que sobram 400 imagens de outros 40 indivíduos para o teste.



Figure 6. Exemplo de imagem: (a) CASIA e (b) UBIRIS

## 4. Experimentos

### 4.1. Wavelet

Assim como em [7] utilizamos a componente vertical da Wavelet para representar as informações contidas na íris. Realizamos experimentos variando os níveis de decomposição, as dimensões da imagem normalizada e para as Wavelets rbio3.1 e rbio2.2.

As Tabelas 1 2 apresentam os resultados obtidos na base de dados CASIA utilizando respectivamente a Wavelet rbio3.1 e a Wavelet rbio2.2 para os níveis de decomposição [1, 2, 3, 4, 5].

Table 1. CASIA - rbio3.1: variando os níveis de decomposição

wname	Componente	# colunas	# linhas	EER (%) incr. 0,1	EER (%) incr. 0,05
rbio3.1	v1	16	128	50,00	50,37
rbio3.1	v2	16	128	49,97	13,99
rbio3.1	v3	16	128	50,00	24,32
rbio3.1	v4	16	128	50,00	35,61
rbio3.1	v5	16	128	49,97	35,90

Table 2. CASIA - rbio2.2: variando os níveis de decomposição

wname	Componente	# colunas	# linhas	EER (%) incr. 0,1	EER (%) incr. 0,05
rbio2.2	v1	16	128	50,00	12,59
rbio2.2	v2	16	128	50,00	<b>9,83</b>
rbio2.2	v3	16	128	50,00	19,67
rbio2.2	v4	16	128	50,00	29,57
rbio2.2	v5	16	128	50,00	41,51

Selecionamos os parâmetros que obtiveram a menor EER, 9,83% nas Tabelas 1 2 (Wavelet rbio2.2 com dois níveis de decomposição) e variamos o número de linhas e colunas da imagem normalizada, os resultados são apresentados na Tabela 3.

A menor EER utilizando Wavelets para a base CASIA, 9,31% foi obtida para a Wavelet rbio2.2 com dois níveis de decomposição e para as imagens normalizadas

Table 3. CASIA - rbio2.2: variando dimensões imagem

wname	Componente	# colunas	# linhas	EER (%) incr. 0,1	EER (%) incr. 0,05
rbio2.2	v2	32	128	50,00	50,00
rbio2.2	v2	64	128	50,00	50,00
rbio2.2	v2	128	128	50,00	50,00
rbio2.2	v2	16	256	50,00	<b>9,31</b>
rbio2.2	v2	16	512	50,00	19,35

de dimensões 256-por-16. Para esses parâmetros realizamos experimentos para valores de incrementos menores [0,025; 0,01] e obtivemos, respectivamente, as EERs 3,84% e 3,47%.

As Tabelas 4 5 apresentam os resultados obtidos na base de dados CASIA utilizando respectivamente a Wavelet rbio3.1 e a Wavelet rbio2.2 para os níveis de decomposição [1, 2, 3, 4, 5].

Table 4. UBIRIS - rbio3.1: variando os níveis de decomposição

wname	Componente	# colunas	# linhas	EER (%) incr. 0,1	EER (%) incr. 0,05
rbio3.1	v1	16	128	50	32,68
rbio3.1	v2	16	128	50	<b>22,3</b>
rbio3.1	v3	16	128	50	28,09
rbio3.1	v4	16	128	50	36,05
rbio3.1	v5	16	128	49,96	41,23

Table 5. UBIRIS - rbio2.2: variando os níveis de decomposição

wname	Componente	# colunas	# linhas	EER (%) incr. 0,1	EER (%) incr. 0,05
rbio2.2	v1	16	128	50	45,43
rbio2.2	v2	16	128	50	30,24
rbio2.2	v3	16	128	49,99	26,79
rbio2.2	v4	16	128	50	31,66
rbio2.2	v5	16	128	49,98	35,08

Selecionamos os parâmetros que obtiveram a menor EER, 22,3% nas Tabelas 4 5 (Wavelet rbio3.1 com dois níveis de decomposição) e variamos o número de linhas e colunas da imagem normalizada, os resultados são apresentados na Tabela 6. A menor EER, utilizando Wavelets para a base UBIRIS, 22,3% foi obtida para a Wavelet rbio3.1 com dois níveis de decomposição e para as imagens normalizadas de dimensões 128-por-16. Para esses parâmetros realizamos experimentos para valores de incrementos menores [0,025; 0,01] e obtivemos, respectivamente, as EERs 20,76% e 20,63%.

Table 6. UBIRIS - rbio3.1: variando dimensões imagem

wname	Componente	# colunas	# linhas	EER (%) incr. 0,1	EER (%) incr. 0,05
rbio3.1	v2	8	128	28,06	23,26
rbio3.1	v2	32	128	50	50
rbio3.1	v2	64	128	50	50
rbio3.1	v2	128	128	50	50
rbio3.1	v2	16	256	50	26,57
rbio3.1	v2	16	512	50	33,97

### 4.2. Representação Gabor 2D

As Tabelas 7 8 mostram os resultados obtidos utilizando o Filtro Gabor 2D para extrair características da íris. As

menores EERs tanto para a base CASIA, 2,81, quanto para a base UBIRIS, 19,58, foram obtidas para os valores de incremento 0,01.

Table 7. CASIA (Representação Gabor 2D)

EER (%)			
incr. 0,1	incr. 0,05	incr. 0,025	incr. 0,01
5,6	3,55	2,9	<b>2,81</b>

Table 8. UBIRIS (Representação Gabor 2D)

EER (%)			
incr. 0,1	incr. 0,05	incr. 0,025	incr. 0,01
26,89	24,43	21,88	<b>19,58</b>

### 4.3. Representação Gabor 2D + Wavelet

As Tabelas 9 e 10 mostram os resultados obtidos quando somamos o vetor de dissimilaridades encontrado quando a Representação Gabor 2D foi usada para extrair características e o vetor obtido quando as Wavelets são utilizadas para representar as informações contidas na íris. Tanto para a base CASIA quanto para a base UBIRIS quanto menor o valor de incremento menor é a EER.

Table 9. CASIA (Representação Gabor 2D + Wavelet)

EER (%)			
incr. 0,1	incr. 0,05	incr. 0,025	incr. 0,01
3,57	1,85	<b>1,65</b>	

Table 10. UBIRIS (Representação Gabor 2D + Wavelet)

EER (%)			
incr. 0,1	incr. 0,05	incr. 0,025	incr. 0,01
28,84	19,52	16,93	<b>15,24</b>

### 4.4. Análise dos Resultados

Tanto na base de dados UBIRIS quanto na base CASIA, os melhores resultados foram encontrados para o método de extração de características que combina a Representação Gabor 2D com a Wavelet. Na Figura 7 podemos observar que as curvas ROCs (Receiver Operating Characteristic) geradas quando a Representação Gabor 2D + Wavelet é aplicada ao método de reconhecimento, curva em vermelho, é mais próxima da origem do que as curvas ROCs dos métodos que utilizam Representação Gabor 2D e a Wavelet separadamente, curvas azul e verde, respectivamente.

### 5. Conclusão e Trabalhos Futuros

Neste trabalho reimplmentamos e combinamos o método de reconhecimento de íris em ambientes não-cooperativos usando múltiplas assinaturas/características extraídas de seis sub-regiões distintas e sobrepostas da íris [6] com um método de extração de características baseado em Wavelets. Realizamos experimentos em duas bases de dados (UBIRIS e CASIA), e em ambas as menores EERs foram obtidas quando somamos o vetor de dissimilaridades

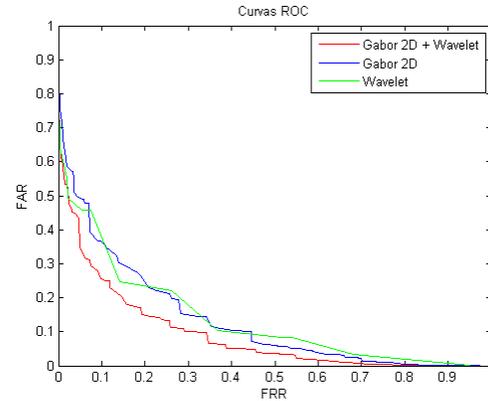


Figure 7. ROCs UBIRIS (incr. 0,025)

encontrado quando a Representação Gabor 2D foi usada para extrair características e o vetor obtido quando Wavelets são aplicadas para o mesmo fim.

Como trabalhos futuros pretendemos otimizar a etapa de treinamento, tornando possível experimentos para valores de incrementos menores.

### References

- [1] Casia iris image database [online]. <http://biometrics.idealtest.org/findTotalDbByMode.do?mode=Iris>.
- [2] C. R. Castelano. *Estudo comparativo da Transformada Wavelet no Reconhecimento de Padrões da íris humana*. PhD thesis, Universidade de São Paulo, 2006.
- [3] J. Daugman. High confidence visual recognition of persons by a test of statistical independence. *IEEE Trans. Pattern Anal. Machine Intell.*, 1993.
- [4] J. M. de Souza e Marcio Merino Fernandes. Sistema dinâmico para reconhecimento de Íris utilizando imagens de vídeo. *SIB-GRAPI*, page 954, 2012. Dissertação de Mestrado.
- [5] H. Proença and L. Alexandre. Ubiris: A noisy iris image database. *Proc. 13th Int'l Conf. Image Analysis and Processing*, pages 970–977, 2005.
- [6] H. Proença and L. A. Alexandre. Toward noncooperative iris recognition: a classification approach using multiple signatures. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(4):607–612, 2007.
- [7] R. Szwedczyk, K. Grabowski, M. Napieralska, W. Sankowski, M. Zubert, and A. Napieralski. A reliable iris recognition algorithm based on reverse biorthogonal wavelet transform. *Pattern Recognition Letters*, 2011.