UNIVERSIDADE DE SÃO PAULO–USP
ESCOLA DE ENGENHARIA DE SÃO CARLOS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Jones Mendonça de Souza

**Reconhecimento de textura de íris sob
variação do tamanho da pupila**

São Carlos
2017

Jones Mendonça de Souza

**Reconhecimento de textura de íris sob
variação do tamanho da pupila**

Tese de doutorado apresentada ao Programa de Engenharia Elétrica da Escola de Engenharia de São Carlos como parte dos requisitos para a obtenção do título de Doutor em Ciências.

Área de concentração: Processamento de sinais e instrumentação

Orientador: Prof. Dr. Adilson Gonzaga

São Carlos

2017

Trata-se da versão corrigida da tese. A versão original se encontra disponível na EESC/USP que aloja o Programa de Pós-Graduação de Engenharia Elétrica.

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

S729r Souza, Jones Mendonça de
Reconhecimento de textura de íris sob variação do
tamanho da pupila / Jones Mendonça de Souza; orientador
Adilson Gonzaga. São Carlos, 2017.

Tese (Doutorado) - Programa de Pós-Graduação em
Engenharia Elétrica e Área de Concentração em
Processamento de Sinais e Instrumentação -- Escola de
Engenharia de São Carlos da Universidade de São Paulo,
2017.

1. Biometria. 2. Reconhecimento de íris. 3.
Descritores Locais. I. Título.

FOLHA DE JULGAMENTO

Candidato: Bacharel **JONES MENDONÇA DE SOUZA.**

Título da tese: "Reconhecimento de textura de íris sob variação do tamanho da pupila".

Data da defesa: 09/06/2017.

Comissão Julgadora:

Resultado:

Prof. Associado **Adilson Gonzaga**

(Orientador)

(Escola de Engenharia de São Carlos/EESC)

APROVADO

Prof. Associado **Evandro Luis Linhari Rodrigues**

(Escola de Engenharia de São Carlos/EESC)

Aprovado

Prof. Dr. **Marcio Merino Fernandes**

(Universidade Federal de São Carlos/UFSCar)

Aprovado

Prof. Dr. **Aparecido Nilceu Marana**

(Universidade Estadual Paulista "Júlio de Mesquita Filho"/UNESP – Bauru)

Aprovado

Profa. Dra. **Milena Bueno Pereira Carneiro**

(Universidade Federal de Uberlândia/UFU)

Aprovado

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica:
Prof. Associado **Luis Fernando Costa Alberto**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Luis Fernando Costa Alberto**

*Dedico esta conquista à minha mãe, **Jeronima Mendonça de Souza** (**in memoriam**), que em vida me ensinou o reto caminho e a importância dos estudos; à minha esposa **Taismara**, pela extrema paciência e sobretudo seu amor e; ao meu filho **Bryan**, que mesmo com poucos meses de vida me encheu de alegria e forças para que eu concluísse este percurso.*

Agradecimentos

Agradeço em primeiro lugar à Deus, por guiar meus caminhos e permitir que eu chegasse até aqui, concedendo-me saúde e paz interior para a realização deste trabalho.

Dentre muitos, gostaria de expressar minha especial gratidão:

Ao meu orientador Prof. Dr. Adilson Gonzaga, pela confiança depositada ao longo destes anos, por seu comprometimento e dedicação em orientar e corrigir este trabalho e, pelos riquíssimos ensinamentos, sem os quais minhas dificuldades seriam maiores.

Aos Professores Dr. Marcio Merino Fernandes e Dr. Evandro Luís Linhari Rodrigues, pelas contribuições sugeridas no exame de Qualificação.

Aos meus amigos de infância Allessandro, Alan e Paulo Ricardo pelos momentos de descontração, estímulo e ótima convivência.

Aos meus colegas do Laboratório de Visão Computacional (LAVI), pelas produtivas discussões e trocas de conhecimentos.

Aos meus colegas de ofício do IFSP, que muitas vezes me ajudaram com seus conhecimentos e experiências e muitas outras com palavras de apoio.

Aos meus alunos, com os quais aprendo diariamente e amplio meus horizontes, obrigado por acreditarem que eu podia mais.

Ao meu pai Donizete por ter feito seu melhor, por compreender minhas escolhas, por valorizar os meus conhecimentos e, por fornecer os recursos necessários para que eu tivesse uma boa educação.

À minha sogra Aparecida, por me depositar confiança, força e serenidade nas horas de desespero.

À minha esposa, Taismara, pela paciência, compreensão, ajuda e incentivo neste e em todos os momentos que compartilhamos juntos, sem você ao meu lado jamais teria conseguido. Minha eterna gratidão. Te Amo.

À toda minha família, irmãos, sogro, cunhado, cunhadas e sobrinhos, por todo carinho, apoio e suporte dados.

Enfim, a todas as pessoas que de alguma forma contribuíram para que este sonho fosse concretizado, que é a realização do meu doutorado.

“O estudo é a valorização da mente ao serviço da felicidade humana.”
(François Guizot)

Resumo

Mendonça de Souza, Jones **Reconhecimento de textura de íris sob variação do tamanho da pupila**. 155 p. Tese de doutorado – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2017.

A textura da íris humana é uma das peculiaridades biométricas mais confiáveis, pois os padrões que compõem sua estrutura são considerados únicos e estáveis por longos anos. No entanto, amostras de íris capturadas em ambiente não cooperativo como reconhecimento de íris a distância, por exemplo, estão sujeitas a conter variações na textura, devido a mudanças comportamentais da membrana da íris. Outro problema é a complexidade do algoritmo, que o torna inviável para aplicações práticas ou em tempo real. O objetivo deste trabalho foi avaliar alguns descritores de textura locais para o reconhecimento biométrico de íris, considerando os efeitos de dilatação e contração da pupila. Para a comprovação da hipótese desta tese de doutoramento, foi utilizada uma base de dados contendo amostras de íris com a pupila contraída e dilatada, simulando assim, a aquisição natural em ambiente não cooperativo. Além disso, foram propostos dois novos descritores, denominados como *Median Local Mapped Pattern* (Median-LMP) e *Modified Median Local Mapped Pattern* (MM-LMP), que foram comparados com o método de Daugman, o *Local Mapped Pattern* (LMP), o *Completed Modeling of Local Binary Pattern* (CLBP), o *Median Binary Pattern* (MBP) e o *Weber Law Descriptor* (WLD). Os resultados da avaliação de desempenho mostraram que o algoritmo de Daugman é o melhor para o reconhecimento de íris quando é realizada a comparação entre amostras de íris com pupilas contraídas. No entanto, se a pupila está dilatada, os descritores propostos apresentaram o melhor desempenho, principalmente se uma amostra de íris com uma pupila contraída é comparada com outra íris com a pupila dilatada. Além disso, os descritores propostos e o LMP obtiveram os menores tempos de processamento, sendo mais adequados do que os demais para aplicações em tempo preditivo com implementação em hardware.

Palavras-chave: Biometria. Reconhecimento de íris. Descritores locais.

Abstract

Mendonça de Souza, Jones **Iris texture recognition under pupil size variation**
. 155 p. Ph.D. Thesis – São Carlos School of Engineering, University of São Paulo, 2017.

The texture of the human iris is one of the most reliable biometric traits, so the patterns that make up its structure are the only criteria and stable for long time. However, iris samples captured in a noncooperative environment as recognition of nature, for example, subject to contain variations in texture, due to behavioral changes of the iris membrane. Another problem is an algorithm complexity, which makes it impractical for practical or in real-time applications. The objective of this work is to evaluate some local texture descriptors for the biometric iris recognition, considering the effects of dilation and contraction of the pupil. In order to prove the hypothesis of this doctoral question, a database was used containing iris samples with a contracted and dilated pupil, thus simulating a natural acquisition in a noncooperative environment. In addition, two new descriptors, named Median-Local Standard Mapped (Median-LMP) and Modified Modified Local Standard Mapped (MM-LMP) were proposed, which were compared with the Daugman method, the Mapped Local Pattern (LMP), the Complete Local Binary Pattern Modeling (CLBP), the Median Binary Standard (MBP) and Weber Law Descriptor (WLD). The results of the performance evaluation show that the Daugman algorithm is the best for iris recognition when a study of iris samples with the students is performed. However, if a pupil is dilated, the proposed descriptors show the best performance, especially a sample of iris with a contracted pupil is compared to another iris with a dilated pupil. In addition, the proposed descriptors and the LMP obtained the shortest processing times, being more adequate than the others for predictive time applications with hardware implementation.

Keywords: Biometric. Iris recognition. Local Descriptors.

Lista de ilustrações

Figura 1	Cálculo do <i>Texture Unit</i> em uma vizinhança 3×3	37
Figura 2	cálculo do LBP em uma vizinhança 3×3	38
Figura 3	Exemplos de vizinhanças circulares para representação de micro-padrões em imagens usando LBP	39
Figura 4	Extração das características da íris utilizando os operadores $LBP_{P,R}^i$.	40
Figura 5	Amostras de íris do gênero feminino da base de dados Notre Dame ND-Iris-0405.	43
Figura 6	Exemplos das componentes do WLD obtidas por duas imagens.	44
Figura 7	<i>Local Binary Pattern</i> : a) Padrão local b) Resultado da limiarização c) Matriz de Pesos d) Código LBP.	46
Figura 8	Notação de uma vizinhança de <i>pixels</i> 3×3	46
Figura 9	Comparação entre o código LBP e LMP em um padrão local de vizinhança 3×3	48
Figura 10	Aquisição da amostra de íris pelo <i>IOM System</i>	50
Figura 11	Aquisição da amostra de íris pelo <i>IOM System</i>	51
Figura 12	Exemplo de amostras capturadas a distância por sequência de vídeo. .	52
Figura 13	Dispositivo utilizado para formação da base de dados UBIRIS V2. . . .	53
Figura 14	Exemplo de amostras da base UBIRIS V2 segmentadas.	54
Figura 15	Protótipo para aquisição de amostras de íris a 30 metros de distância. .	55
Figura 16	Amostras de mesma classe classificadas como genuína pelo sistema. . .	55
Figura 17	Distribuição dos pares casados e não casados.	58
Figura 18	Pontos de decisão em sistemas biométricos ilustrado pela curva DET. .	59
Figura 19	Comparação entre o código LMP e Median-LMP.	65
Figura 20	Ilustração interna dos músculos da íris.	68
Figura 21	Sistema óptico central, cruzamento das fibras do nervo óptico no quiasma.	68
Figura 22	Estrutura do dispositivo proposto para aquisição de amostras da íris .	69

Figura 23	Estímulos de luz durante o processo de aquisição das amostras por sequência de vídeo.	70
Figura 24	Procedimento de digitalização da sequência de vídeo	70
Figura 25	Amostras da base de dados LAVI Iris Video DB2 apresentando erros. .	72
Figura 26	Exemplo de duas imagens de íris do “dispositivo 2” da base de dados CASIA-Iris V2.	73
Figura 27	Exemplo de duas imagens da base de dados Notre Dame ND-Iris-Template-Aging-2008–2010.	74
Figura 28	Exemplo de duas amostras da base de dados UBIRIS V1.	74
Figura 29	Exemplo de duas amostras da base de dados UBIRIS V2.	75
Figura 30	Exemplo de duas amostras da base de dados CASIA-Iris-Distance. . . .	76
Figura 31	Exemplos de amostras da base de dados CASIA-Iris-Distance com os olhos detectados pela biblioteca OpenCV.	77
Figura 32	Conjuntos de amostras de íris normalizadas em diferentes resoluções. .	78
Figura 33	Metodologia abordada para comparação das amostras: (a) Amostras de íris com a pupila contraída, foram comparadas apenas com amostras de íris com a pupila contraída, (b) Amostras de íris com a pupila contraída, foram comparadas apenas com amostras de íris com a pupila dilatada, (c) Amostras de íris com a pupila dilatada, foram comparadas apenas com amostras de íris com a pupila dilatada, (d) Amostras de íris com a pupila dilatada, foram comparadas apenas com amostras de íris com a pupila contraída, (e) Amostras de íris com a pupila contraída foram comparadas com os dois subconjuntos (dilatadas e contraídas) e vice-versa.	79
Figura 34	Ilustração de uma amostra de íris com o ruído anatômico detectado pelo método de Daugman.	80
Figura 35	Metodologia abordada para eliminação do ruído anatômico nos descritores de textura.	80
Figura 36	Fases do processo de classificação de amostras.	82
Figura 37	Curva DET para base de dados LAVI Subconjunto-1.	89
Figura 38	Curva DET para base de dados LAVI Subconjunto-2.	91
Figura 39	Curva DET para base de dados LAVI Subconjunto-3.	92
Figura 40	Curva DET para o método de Daugman utilizando amostras de 20×240 <i>pixels</i>	93
Figura 41	Distribuição das amostras Intra-classe x Inter-classe referente ao método de Daugman.	94
Figura 42	Tempo de execução “um-para-muitos” para cada método utilizando a base de dados completa (LAVI Subconjunto-3).	95
Figura 43	Curva DET para base de dados UBIRIS V1.	96

Figura 44	Tempo de execução “um-para-muitos” para cada método utilizando a base de dados completa (UBIRIS V1).	97
Figura 45	Curva DET para base de dados CASIA-Iris V2.	99
Figura 46	Tempo de execução “um-para-muitos” para cada método utilizando a base de dados completa (CASIA-Iris V2).	100
Figura 47	Curva DET para base de dados ND-Iris-Template-Aging-2008–2010.	101
Figura 48	Tempo de execução “um-para-muitos” para cada método utilizando a base de dados completa (ND-Iris-Template-Aging-2008–2010).	102
Figura 49	Curva DET para base de dados UBIRIS V2.	103
Figura 50	Tempo de execução “um-para-muitos” para cada método utilizando a base de dados completa (UBIRIS V2).	105
Figura 51	Curva DET para base de dados CASIA-Iris-Distance.	106
Figura 52	Tempo de execução “um-para-muitos” para cada método utilizando a base de dados completa (CASIA-Iris-Distance).	107
Figura 53	Desempenho dos métodos avaliados medidos pela “eficiência”.	108
Figura 54	Desempenho dos métodos avaliados medidos pela “eficácia”.	109

Lista de tabelas

Tabela 1	Especificações da câmera utilizada no protótipo desenvolvido	69
Tabela 2	Número de amostras de treinamento/teste utilizadas para a sintonização do β em cada base de dados.	83
Tabela 3	Parâmetros β para o LMP otimizados para cada base de dados.	84
Tabela 4	Parâmetros β para o LMP2 otimizados para cada base de dados.	84
Tabela 5	Parâmetros β para o Median-LMP otimizados para cada base de dados.	84
Tabela 6	Parâmetros β para o MM-LMP otimizados para cada base de dados.	84
Tabela 7	Tempo de execução “um-para-um” medido em milissegundos (ms) utilizando o Subconjunto-3.	88
Tabela 8	Sensibilidade (%) obtida com o Subconjunto-1 (dilatada vs dilatada)	89
Tabela 9	Sensibilidade (%) obtida com o Subconjunto-2 (contraída vs contraída)	90
Tabela 10	Sensibilidade (%) obtida com o Subconjunto-3 (contraída vs dilatada)	92
Tabela 11	Sensibilidade (%) obtida pela comparação de todas as amostras da base de dados UBIRIS V1.	97
Tabela 12	Sensibilidade (%) obtida pela comparação de todas as amostras da base de dados CASIA-Iris V2.	98
Tabela 13	Sensibilidade (%) obtida pela comparação de todas as amostras da base de dados ND-Iris-Template-Aging-2008–2010.	101
Tabela 14	Sensibilidade (%) obtida pela comparação de todas as amostras da base de dados UBIRIS V2.	104
Tabela 15	Sensibilidade (%) obtida pela comparação de todas as amostras da base de dados CASIA-Iris-Distance.	106
Tabela 16	Percentual de diferença ao se comparar íris com pupilas dilatadas (LAVI Subconjunto-1) vs íris com pupilas contraídas (LAVI Subconjunto-2).	112
Tabela 17	Descrição completa da base de dados LAVI Iris Video DB2	127
Tabela 18	Parâmetros do algoritmo de Masek para cada base de dados	133

Tabela 19	Resultados obtidos antes/após aplicação da metodologia proposta para descarte do ruído anatômico	134
Tabela 20	Sensibilidade obtida pelos métodos avaliados.	136
Tabela 21	Imagens selecionados a partir da base de dados CASIA-Iris V2	139
Tabela 22	Imagens selecionados a partir da base de dados Notre Dame ND-Iris-Template-Aging-2008–2010	142
Tabela 23	Imagens selecionados a partir da base de dados UBIRIS V1	146
Tabela 24	Imagens selecionados a partir da base de dados UBIRIS V2	149
Tabela 25	Imagens selecionados a partir da base de dados CASIA-Iris-Distance .	153

Lista de siglas

BMP *Bitmap*

CLBP *Completed Modeling of Local Binary Pattern*

CLMP *Color Local Mapped Pattern*

CSLBP *Centersymmetric Local Binary Pattern*

DET *Detection Error Tradeoff*

EER *Equal Error Rate*

FAR *False Acceptance Rate*

FN *Falsos Negativos*

FRR *False Rejection Rate*

FPGA *Field Programmable Gate Array*

GLCM *Gray Level Cooccurrence Matrix*

HD *Hamming Distance*

IAAD *Iris at a Distance*

IOM *Iris on the move*

JPG *Joint Photographic Experts Group*

LAVI *Laboratório de Visão Computacional*

LBP *Local Binary Pattern*

LBP^{ri} *LBP with rotation invariant*

LBP^{riu2} *LBP with rotation invariant uniform 2 pattern code*

LDSMT *Local Difference SignMagnitude Transform*

LED *Light Emitting Diode*

LFP *Local Fuzzy Pattern*

LLBP *Local Line Binary Pattern*

LMP *Local Mapped Pattern*

LMPg *Local Mapped Pattern gaussian*

LMP_h *Local Mapped Pattern heaviside*

LMP_s *Local Mapped Pattern sigmoidal*

LMP_t *Local Mapped Pattern triangular*

MATLAB *MATrix LABoratory*

MBP *Median Binary Pattern*

MBLBP *MultiBlock LBP*

MLMP *Median Local Mapped Pattern*

MMLMP *Modified Median Local Mapped Pattern*

NIR *Near infrared*

OpenCV *Open Source Computer Vision Library*

PSO *Particle Swarm Optimization*

PTU *Pan tilt Unit*

PTZ *PanTiltZoom*

RGB *Red, Green and Blue*

ROC *Receiver Operating Characteristic*

RNA *Redes Neurais Artificiais*

sLMP *Sampled LMP*

TCP *Transformada de Componente Principal*

TIFF *Tagged Image File Format*

TU *Texture Unit*

VP Verdadeiro Positivo

WFOV *Wide Field Of View*

WLD *Weber Local Descriptor*

XOR Ou exclusivo

Sumário

1	Introdução	29
1.1	Contexto e definição do problema	29
1.2	Justificativa e hipótese	30
1.3	Objetivos	31
1.4	Contribuições	31
1.5	Organização da Tese	31
2	Fundamentação teórica	33
2.1	Considerações Iniciais	33
2.2	Descritores de textura	34
2.2.1	Abordagem estatística	35
2.2.2	Abordagem estrutural	36
2.2.3	Abordagem espectral	36
2.3	Descritores de textura local	37
2.3.1	LBP - Local Binary Pattern	37
2.3.2	CLBP - Completed Modeling of Local Binary Pattern	41
2.3.3	WLD - Weber Local Descriptor	42
2.3.4	LMP - Local Mapped Pattern	45
2.4	Identificação biométrica de íris	48
2.5	Trabalhos relacionados	49
2.6	Medidas de desempenho em sistemas biométricos	56
2.7	Método de Daugman	59
2.8	Considerações finais	61
3	Descritores propostos para textura de íris	62
3.1	Considerações iniciais	62
3.2	Median Local Mapped Pattern (Median-LMP)	63
3.3	Modified Median Local Mapped Pattern (MM-LMP)	65

3.4	Considerações finais	66
4	Material e Metodologia	67
4.1	Considerações iniciais	67
4.2	Bases de dados	69
4.2.1	Base de dados LAVI Iris Video DB2	69
4.2.2	Base de dados CASIA-Iris V2	72
4.2.3	Base de dados ND-Iris-Template-Aging-2008–2010	73
4.2.4	Base de dados UBIRIS V1	73
4.2.5	Base de dados UBIRIS V2	74
4.2.6	Base de dados CASIA-Iris-Distance	75
4.3	Processamento de imagem e segmentação	77
4.4	Extração das características e classificação da íris	81
4.5	Metodologia para treinamento das amostras	82
4.6	Considerações finais	85
5	Resultados e Discussão	86
5.1	Considerações iniciais	86
5.2	Resultados obtidos com as bases de dados	88
5.2.1	Resultados de desempenho para a base de dados LAVI Iris Video DB2	88
5.2.2	Resultados de desempenho para a base de dados UBIRIS V1 . . .	95
5.2.3	Resultados de desempenho para a base de dados CASIA-Iris V2 .	98
5.2.4	Resultados de desempenho para a base de dados ND-Iris-Template- Aging-2008–2010	100
5.2.5	Resultados de desempenho para a base de dados UBIRIS V2 . . .	103
5.2.6	Resultados de desempenho para a base de dados CASIA-Iris-Distance	105
5.3	Resultados de “eficiência” e “eficácia”	107
5.4	Considerações finais	110
6	Conclusão	111
6.1	Contribuições	114
6.2	Sugestões de trabalhos futuros	114
6.3	Trabalhos publicados	115
	Referências	116
	Apêndices	125
	APÊNDICE A Descrição da base de dados LAVI Iris Video DB2	127

APÊNDICE B	Parâmetros do algoritmo Masek	133
APÊNDICE C	Resultados com a eliminação do ruído anatômico	134
APÊNDICE D	Resultados com descritores circulares	135
Anexos		137
ANEXO A	Especificação da base de dados CASIA-Iris V2	139
ANEXO B	Especificação da base de dados ND-Iris-Template-Aging-2008–2010	142
ANEXO C	Especificação da base UBIRIS V1	146
ANEXO D	Especificação da base UBIRIS V2	149
ANEXO E	Especificação da base de dados CASIA-Iris-Distance	153

Introdução

1.1 Contexto e definição do problema

O termo Biometria que vem do Grego, *Bios* (Vida) *Metron* (Medida), Medida da Vida, refere-se ao uso de técnicas e métodos para reconhecer uma pessoa com base em características biológicas ou comportamentais que possam identificar inequivocamente um indivíduo dentre todos os outros. Os sistemas biométricos são propostos para garantir maior segurança no campo de autenticação de dados, uma vez que são considerados superiores em relação aos meios convencionais de autenticação como: cartões de identidade e senhas alfanuméricas.

Existem diferentes métodos biométricos, baseados em diversas peculiaridades, tais como: impressão digital, face, voz, íris, assinatura manuscrita, entre outras. Os avanços da eletrônica e informática observados nas últimas décadas têm sido determinantes para que a biometria exerça um papel cada vez mais importante para a segurança da sociedade em diversas aplicações como: controle de acesso a hospitais, aeroportos, agências bancárias, tribunais judiciais, etc.

Os primeiros estudos envolvendo a íris no campo da biometria datam a partir de 1936, com as conclusões do oftalmologista Frank Burch. No entanto, a peculiaridade foi explorada por meio de experimentos somente em 1993 pelo cientista John Daugman (DAUGMAN, 1993), sendo seu método patenteado no ano seguinte (DAUGMAN, 1994). Notavelmente comprovada em pesquisas científicas, a íris é considerada uma das características mais intrínsecas do ser humano, as estatísticas apontam que a chance de existir uma íris com os mesmos traços no mundo é da ordem de 1 em 4 bilhões. Dessa maneira, a íris tem se mostrado cada vez mais promissora para sistemas de reconhecimento biométrico (DAUGMAN, 1993).

Por se tratar de uma característica relativamente pequena e peculiar, o processo de aquisição da íris se torna bastante delicado. Câmeras infravermelhas são utilizadas para inibir o reflexo proporcionado pela luz visível, que pode prejudicar a observação da região de interesse. Além disso, outros aspectos podem influenciar diretamente no desempenho

desses sistemas, tais como: distância entre a íris e o dispositivo de aquisição da imagem, movimentação dos olhos em direção oposta ao campo de visão da câmera, resolução da amostra capturada, e dilatação e contração da pupila; este último causado pela variação de luz no ambiente de aquisição da imagem.

1.2 Justificativa e hipótese

Os sistemas biométricos em sua maioria utilizam o conceito de aquisição de peculiaridades em modo cooperativo, exigindo a participação efetiva do usuário em condições de iluminação controlada. A utilização deste princípio permite adquirir amostras com boa qualidade, pois são coletadas manualmente obedecendo um posicionamento pré-estabelecido pelo administrador do sistema. Devido a este cenário as chances de haver erros são mínimas, já que o processo de aquisição pode ser repetido até que o usuário seja identificado (CATARINO, 2009) (CARREIRA, 2009).

Embora o ambiente cooperativo seja confiável, este é visto como um procedimento invasivo, causando certa rejeição por parte do usuário. Pensando neste problema uma nova categoria de sistemas biométricos têm sido investigada, os sistemas não cooperativos. Estes estão relacionados ao processo de aquisição automático de peculiaridades, capturadas a uma certa distância sem a participação efetiva do usuário. A grande vantagem é que, estes sistemas abrem novas fronteiras de aplicação, como por exemplo identificação de pessoas desaparecidas, terroristas, criminosos entre outras com fins de identificação não cooperativa. No entanto, é natural que se obtenha amostras não centradas ou desfocadas, devido à não participação do usuário (CATARINO, 2009) (CARREIRA, 2009).

Levando-se em consideração que a luminosidade do ambiente seja variante em sistemas não cooperativos, é natural que em sistemas de reconhecimento de íris a pupila tenda a se contrair em situações com alta luminosidade, e de forma contrária, onde falte iluminação, tenda a se dilatar. Desse modo, pode-se considerar que os padrões visíveis da íris sofrem alterações com as ações involuntárias de dilatação e contração, uma vez que os padrões formados pela textura da íris se comprimem em estado de dilatação e se dilatam durante a contração da pupila.

Os métodos atuais para reconhecimento de íris ignoram o problema da variação do tamanho da pupila. No método de John Daugman por exemplo, é presumido a correção deste problema por meio da etapa de normalização, que determina para cada ponto da íris um par de coordenadas (r, θ) (DAUGMAN, 1993). No entanto, se a pupila dilata o raio (r) reduz e, conseqüentemente os padrões de textura são modificados. Partindo-se desta hipótese, não se tem conhecimento na literatura científica, de qualquer método que seja eficiente e eficaz para a classificação de texturas de íris sob os efeitos de contração e dilatação da pupila. Há somente um estudo realizado por Hollingsworth, Bowyer e Flynn (2008) que conclui que os efeitos proporcionados pela dilatação e contração da pupila

comprometem o desempenho de classificação da íris.

1.3 Objetivos

O objetivo geral desta tese é avaliar o comportamento da textura da íris humana, sob efeito da dilatação e contração da pupila, no reconhecimento biométrico. Conforme estudos anteriormente publicados, o método de John Daugman é eficiente quando as íris avaliadas de um mesmo indivíduo, não foram submetidas à contração e dilatação da pupila, ou seja, foram adquiridas em ambientes cooperativos com iluminação constante. Para aplicações em ambientes não cooperativos, como por exemplo reconhecimento de íris a distância, e com iluminação variável, a abordagem proposta por John Daugman tem sua eficiência reduzida. Por isso, os objetivos específicos desta tese foram: 1) obter uma base de imagens em ambiente cooperativo e controlado mas que simule condições que podem ser obtidas na aquisição de íris em ambientes não cooperativos tais como a dilatação e a contração da pupila; 2) propor um novo descritor de textura local que tenha um bom desempenho no reconhecimento de textura de íris sob contração e dilatação da pupila; 3) avaliar o desempenho de classificação das texturas assim obtidas comparando-se o desempenho do descritor proposto com os descritores de textura locais existentes na literatura tais como: *Local Binary Pattern* (LBP), *Completed Modeling of Local Binary Pattern* (CLBP), *Median Binary Pattern* (MBP), *Weber Local Descriptor* (WLD) e o *Local Mapped Pattern* (LMP), além do tradicional método de John Daugman.

1.4 Contribuições

Como contribuições desta tese tem-se:

- a) Proposta de novos descritores de textura local para imagens digitais: *Median Local Mapped Pattern* (Median-LMP) e *Modified Median Local Mapped Pattern* (MM-LMP);
- b) A avaliação do desempenho de diferentes descritores para textura de íris, além da comprovação de que o método de John Daugman, largamente utilizado na literatura e em sistemas comerciais de reconhecimento de íris, perde eficiência e eficácia quando o ambiente é não cooperativo.

1.5 Organização da Tese

Além deste capítulo introdutório, o presente trabalho apresenta outros 6 capítulos, nos quais os temas estão distribuídos na seguinte maneira:

Capítulo 2: Fundamentação teórica; neste capítulo são descritos os fundamentos e aplicações dos descritores de textura local para sistemas biométricos de íris. Além

disso, é apresentada uma revisão bibliográfica dos principais trabalhos que abordam o reconhecimento da íris em ambiente cooperativo e não cooperativo.

Capítulo 3: Descritores propostos para textura de íris; neste capítulo são descritos a teoria da nova abordagem para o reconhecimento da íris sob variação da textura, causada pela deformação das trabéculas da íris.

Capítulo 4: Material e metodologia; neste capítulo são apresentados os materiais utilizados para o desenvolvimento do trabalho e a metodologia abordada para a execução dos experimentos.

Capítulo 5: Resultados e discussão; neste capítulo os resultados experimentais são mostrados e amplamente discutidos.

Capítulo 6: Conclusões; neste capítulo são comentadas as contribuições científicas obtidas assim como as perspectivas futuras para o presente trabalho.

Fundamentação teórica

Neste capítulo são apresentados alguns métodos que analisam a textura de uma imagem. Estes métodos podem ser aplicados para se obter uma descrição dos atributos da íris, a partir da textura. Ainda neste capítulo, são discutidos os principais trabalhos acadêmicos que envolvem a identificação pessoal de íris em ambiente cooperativo e não cooperativo.

2.1 Considerações Iniciais

A palavra textura é de origem latina e pode ser empregada em diferentes contextos. Em visão computacional especificamente, sua definição é bastante particular, podendo ter variações conforme o cenário de aplicação. Essa dificuldade reflete em numerosas definições encontradas na literatura, as mais clássicas encontram-se listadas abaixo:

- a) (**HARALICK, 1979**): “Uma imagem de textura é descrita pelo número e tipos de suas primitivas e a organização espacial ou disposição de suas primitivas”
- b) (**SKLANSKY, 1978**): “Uma região em uma imagem possui textura constante se um conjunto de estatísticas locais ou outras propriedades locais são constantes, variando suavemente ou aproximadamente periódico”
- c) (**TAMURA; MORI; YAMAWAKI, 1978**): “A estrutura da textura é simplesmente atribuída aos padrões repetitivos em que os elementos ou primitivas são dispostos com uma regra de posicionamento”

Devido a grande variedade de aplicações com textura em imagens reais, é possível definir três problemas principais no campo de visão computacional: Classificação, Segmentação e Síntese de texturas (GONÇALVES, 2013). A definição dessas categorias estão descritas abaixo:

- a) **Classificação**: pode ser compreendida como um mapeamento de entrada das características presentes na imagem, com o objetivo de produzir uma saída que deva ser categorizada à uma textura de mesma classe.

- b) **Segmentação**: consiste em agrupar diferentes regiões de texturas em unidades homogêneas.
- c) **Síntese**: extrai as características principais da imagem para se obter uma representação simplificada da textura.

Além da textura ser definida por diferentes categorias, pode-se dividi-las em duas modalidades: estáticas e dinâmicas. Na abordagem estática a textura é representada por uma única imagem, com padrões aleatórios em 2D (duas dimensões). Exemplos de texturas estáticas incluem imagens de tecido, parede, tabuleiros, mármore entre outros. A textura dinâmica é representada por um conjunto de características tridimensionais (x, y, z) sendo z o eixo de variação dos *frames* de vídeo, ou seja, texturas de imagens que estejam em movimento. Alguns exemplos de texturas dinâmicas incluem imagens em sequência, compreendidas pelo domínio espaço-temporal, como: ondas do mar, fogo, fumaça, escada rolante, pessoas caminhando, entre outras (GONÇALVES, 2013).

2.2 Descritores de textura

A análise de textura é considerada uma das tarefas mais complexas dentro da área de processamento de imagens digitais. Nesta etapa, um conjunto de características é definido por meio de uma métrica para representar de maneira efetiva cada região da imagem. Esta representação permite gerar um mapeamento global de um padrão de primitivas existentes na textura, de modo a ser utilizado em processos de mais alto nível, tal como a classificação (PEDRINI; SCHWARTZ, 2007; GONZALES; WOODS, 2000).

A textura contém informações sobre a distribuição espacial e a variação de luminosidade. Além disso, o arranjo estrutural das superfícies e relações entre regiões vizinhas agregam em sua descrição. Devido a essa complexidade, a análise de textura envolve um conjunto de *pixels*, no qual estão distribuídos no “espaço de textura”, denominado como *TEXTure ELement (Texel)*, que é composto por um conjunto de coordenadas paramétricas. No entanto, os padrões de textura podem apresentar variações aleatórias, como “texturas finas” e “texturas ásperas” (PEDRINI; SCHWARTZ, 2007). Desse modo, a relação entre *Texels* deve ser suficientemente boa para diferenciar várias texturas (GONZALES; WOODS, 2000).

Segundo Gonzales e Woods (2000), existem três abordagens que podem ser definidas para extrair descritores de textura: Estatística, Estrutural e Espectral. No entanto, não há um consenso na literatura que padronize esta divisão, pois existem técnicas que geram novas categorias como, por exemplo, Nixon e Aguado (2008) que definem os métodos de análise de textura, como: Estatística, Espectral e Abordagem combinatória. Já em Materka e Strzelecki (1998) os métodos são divididos em: Estrutural, Estatística, baseado em modelos e em transformadas. Em linhas gerais pode-se dizer que o desafio maior está

na escolha de um modelo que capture todas as características visuais significativas da textura.

De maneira individual, é apresentada nas próximas seções uma visão geral das abordagens: estatística, estrutural e espectral.

2.2.1 Abordagem estatística

A abordagem estatística para descrição de textura leva em consideração a distribuição dos níveis de cinza de uma imagem. Para tal representação, são utilizadas algumas medidas estatísticas, tais como: média, variância, desvio padrão, assimetria, curtose, etc. Além disso, um histograma pode ser calculado a partir das medidas de energia, entropia, valor mínimo/máximo e moda (PEDRINI; SCHWARTZ, 2007). No entanto, segundo (GONZALES; WOODS, 2000, p. 363) “medidas de textura calculadas apenas a partir do histograma sofrem a limitação de não carregarem informação sobre a posição relativa dos *pixels* em relação uns aos outros”.

Pensando nisso, Haralick, Shanmugam e Dinstein (1973) propõem um método baseado numa abordagem estatística obtida por meio da construção da matriz de co-ocorrência. O método denominado por *Gray Level Co-occurrence Matrix* (GLCM) utiliza dois parâmetros: a distância e a direção entre os *pixels* vizinhos. Os autores sugeriram ainda que, a partir das matrizes sejam extraídas quatorze medidas: variância, segundo momento angular, energia, contraste, correlação, homogeneidade, momento inverso da diferença, soma da média, soma da variância, soma da entropia, diferença da variância, diferença da entropia, medida de informação da correlação e coeficiente de correlação máxima.

Diversas abordagens foram propostas para a matriz de co-ocorrência, dentre elas a construção de uma matriz de co-ocorrência tridimensional para descrição de texturas coloridas (DACHENG et al., 2002). Além da função de auto-correlação, Haralick (1979) aponta outras abordagens na literatura para a extração e caracterização de textura, tais como: transformadas ópticas, transformadas digitais, bordas texturais, elementos estruturantes, probabilidade de co-ocorrência espacial de níveis de cinza, comprimento de corrida de nível de cinza e modelos auto-regressivos.

No reconhecimento de íris a abordagem estatística tem sido proposta, como em Patil, Patil e Patil (2016) que utiliza a *Gray Level Co-occurrence Matrix* (GLCM) e a *Hausdorff Dimension* para extrair características da íris. Os autores realizaram experimentos com 10 indivíduos, sendo 3 amostras por classe. A partir da GLCM foram extraídas características de textura por meio de algumas medidas, como: energia, contraste, entropia, coeficiente de correlação e homogeneidade. Aplicando-se a *Hausdorff Dimension* foram obtidas características de forma, mensuradas pelo(a): desvio padrão, média, perímetro do comprimento do eixo menor, comprimento do eixo principal, consistência e excentricidade. Os resultados demonstraram viabilidade de uso do método proposto, tendo obtido um percentual de 97,5 % de eficiência.

2.2.2 Abordagem estrutural

A abordagem estrutural é baseada no conceito de que as texturas podem ser representadas pela repetição de primitivas ou padrões. Um vocabulário de *Texels* e a relação destes elementos espaciais são utilizados para definir as características de textura. Estas, podem ser expressas em termos de adjacência, distância mais próxima ou periodicidade. A principal vantagem de se utilizar esta abordagem está no fato de que ela provê uma boa representação simbólica da textura (GONZALES; WOODS, 2000; PEDRINI; SCHWARTZ, 2007). No entanto, a utilização desta abordagem é mais apropriada para síntese de textura do que análise de textura.

Embora a abordagem estrutural não seja tão utilizada para análise de texturas, devido a grande variabilidade de micro e macro estruturas, existem algumas aplicações que exigem a definição de formas e tamanhos dos atributos (VIEIRA, 2013). Neste caso, a morfologia matemática é uma ferramenta poderosa para análise de textura estrutural (GONZALES; WOODS, 2000). Além disso, pode-se destacar a análise de micro-estruturas ósseas como uma aplicação desta abordagem (MATERKA; STRZELECKI, 1998).

2.2.3 Abordagem espectral

As abordagens apresentadas anteriormente operam sob o “espaço de textura”, ou seja, diretamente nos *pixels* da imagem. Já na abordagem espectral a análise é realizada sob as propriedades presentes no espectro de frequência, obtidas por meio das transformadas de Fourier, Gabor e *wavelets* (GONZALES; WOODS, 2000).

Na transformada de Fourier, o espectro apresenta uma concentração maior de energia no centro do plano para texturas ásperas, devido a sua característica homogênea. De forma contrária, a energia do espectro para texturas finas se apresenta de forma espalhada pelo plano de frequências (GONZALES; WOODS, 2000; PEDRINI; SCHWARTZ, 2007). Desse modo, é possível interpretar características de textura como, frequência e tamanho utilizando-se apenas o espectro, algo relativamente complexo para abordagens baseada no domínio espacial.

Como ressaltado em abordagens anteriores, a localização espacial é uma informação relevante para descrição de texturas. Neste aspecto, Gabor (1946) apresenta um conjunto de filtros capazes de representar tanto o tempo quanto a frequência de um sinal, denominado como “filtro de Gabor”. Este filtro foi utilizado por Daugman (1993) para descrever os padrões de textura da íris, que será apresentado na Seção 2.7 deste capítulo.

A transformada *wavelets* permite obter características de textura a partir de algumas sub-imagens resultantes do processo de decomposição, que apresentam escala e frequência distintas. Além da vantagem de se trabalhar com multiresolução de texturas, é possível também extrair estatísticas das sub-imagens geradas a partir do processo de decomposição por meio de matrizes de co-ocorrência (GONZALES; WOODS, 2000).

2.3 Descritores de textura local

Os descritores de textura descrevem uma metodologia para análise das propriedades da superfície de um objeto. O mesmo conceito é aplicado para os descritores de textura local, no entanto, estes métodos realizam esta atividade analisando-se vizinhanças pré-definidas da imagem para se obter o código de cada uma delas com valores denominados *Texture Unit* (TU). A seguir são apresentados alguns destes descritores.

2.3.1 LBP - Local Binary Pattern

A primeira proposta para análise de texturas locais em imagens digitais foi apresentada por Wang e He (1990). O método denominado *Texture Unit* (TU) é aplicado a uma vizinhança 3×3 da imagem, que substitui os valores vizinhos por até três níveis (0, 1 e 2), possibilitando gerar 3^8 (6561) códigos. Para tal abordagem, utiliza-se como parâmetro o valor do *pixel* central da vizinhança V_0 (Figura 1(a)), para se obter a representação dos *pixels* vizinhos V_i (Figura 1(b)).

Figura 1: Cálculo do *Texture Unit* em uma vizinhança 3×3 .

Fonte: (VIEIRA, 2013)

Desse modo, o *pixel* vizinho V_i assume o valor $E_i = 0$ se for menor que V_0 , caso contrário E_i assume o valor 2, e se ambos forem iguais E_i assume o valor 1. Para se obter o código

TU (Equação 1), multiplica-se os valores obtidos (Figura 1(c)) pelos pesos atribuídos pela matriz de peso (Figura 1(d)) fazendo-se o somatório do resultado (Figura 1(e)) (VIEIRA, 2013).

$$N_{TU} = \sum_{i=1}^8 E_i \cdot 3^{i-1} \quad (1)$$

A partir dessa idéia, Ojala, Pietikäinen e Harwood (1996) apresentaram uma nova proposta simplificando os níveis de representação da região de uma imagem para a base 2, ou seja, somente dois valores (0 e 1), possibilitando gerar códigos de 2^8 (256) níveis. Conforme mostra a Equação 2, o método proposto denominado *Local Binary Pattern* (LBP) utiliza o *pixel* central V_0 como parâmetro de limiarização (Figura 2(a)), sendo que o *pixel* vizinho V_i (Figura 2(b)) assume o valor $E_i = 0$ quando for menor que V_0 , caso contrário $E_i = 1$. Os valores vizinhos resultantes da limiarização, são multiplicados por uma matriz de peso de mesma escala (Figura 2(d)), e somados para se obter o código LBP (Figura 2(e)) (VIEIRA, 2013).

Figura 2: cálculo do LBP em uma vizinhança 3×3

Fonte: (VIEIRA, 2013)

$$N_{LBP} = \sum_{i=1}^8 E_i \cdot 2^{i-1} \quad (2)$$

Após o término desta etapa, é calculado o histograma de toda imagem a partir dos códigos LBP gerados. Este procedimento visa representar a frequência dos códigos LBP em um vetor de características, que será objeto de comparação com outras amostras durante o processo de classificação (VIEIRA, 2013).

Mais tarde, Ojala, Pietikainen e Maenpaa (2002) identificaram uma limitação do uso do LBP em imagens rotacionadas e em multi-escala. Os autores apresentaram uma nova abordagem utilizando elementos circulares da vizinhança do *pixel* central, que a chamaram de LBP^{ri} . Tal proposta permite definir um conjunto de amostras P , com um perímetro circular e raio R , para representar uma vizinhança circular da imagem. A Figura 3 ilustra três exemplos de vizinhança que podem ser utilizadas pelo método, alterando o valor de P e R (PIETIKAINEN et al., 2011).

Figura 3: Exemplos de vizinhanças circulares para representação de micro-padrões em imagens usando LBP

Fonte: (PIETIKAINEN et al., 2011)

Quando a amostra se encontra rotacionada, cada código LBP deve ser rotacionado a uma posição de referência, conforme a Equação 3. Dessa maneira, ri representa a “invariância de rotação” e a função $ROR(x; i)$ (Equação 5) representa a mudança circular do número binário x (Equação 4) i vezes para direita ($|i| < P$). Sendo assim, o código de invariância é calculado sucessivamente até se obter um valor mínimo (PIETIKAINEN et al., 2011) (FILHO, 2012).

$$LBP_{P,R}^{ri} = \min(ROR(LBP_{P,R}, i) | i = 0, 1, \dots, P-1) \quad (3)$$

$$x = \sum_{k=0}^{P-1} 2^k a_k, a_k \in \{0, 1\} \quad (4)$$

$$ROR(x, i) = \begin{cases} \sum_{k=1}^{P-1} 2^{k-1} a_k & i > 0 \\ x & i = 0 \\ ROR(x, P+1) & i < 0 \end{cases} \quad (5)$$

2.3.1.1 Aplicações do LBP em Reconhecimento de íris

O LBP tem se destacado na literatura pela sua diversidade em aplicações, como por exemplo: na Medicina (XIANCHUAN; QI, 2009), na inspeção visual (NOVAK; HOCENSKI, 2005), no sensoriamento remoto (SONG; YANG; LI, 2010) e no reconhecimento facial (SINGH; MAURYA; MITTAL, 2012). Contudo, trabalhos com imagens de íris utilizando LBP e suas variantes não são numerosos na literatura (MUSCI et al., 2013).

O trabalho proposto por He et al. (2011) apresenta uma abordagem para extração de características da íris utilizando o LBP. Os experimentos foram realizados utilizando-se as bases de dados CASIA-Iris versão 1 e 3. As amostras normalizadas¹, utilizando a metodologia de Daugman (1993) (Seção 2.7 deste capítulo), porém sem realizar o descarte das regiões contendo oclusões de pálpebras e cílios (Figura 4a). Foi aplicado o $LBP_{P,R}^i$ nas amostras, com $P = 8, R = 1$; $P = 8, R = 2$; $P = 16, R = 2$ e $P = 16, R = 4$ respectivamente, conforme ilustrado na Figura 4. Uma metodologia denominada *Chunked Encoding* é responsável por dividir a informação extraída pelo LBP em blocos de dimensão fixa (Figura 4f), ponderando a cada bloco informações globais e locais. A similaridade entre duas amostras é calculada pela Distância de Hamming.

Figura 4: Extração das características da íris utilizando os operadores $LBP_{P,R}^i$

Fonte: (HE et al., 2011)

O resultado obtido com a utilização da base de dados CASIA-Iris v1 foi 99.60% (acurácia) com 0.26% EER, muito próximo de Daugman 99.61% (acurácia). Já utilizando-se a base de dados CASIA-Iris v3, a acurácia abaixou para 99.27% com 0.54% EER.

¹O termo “normalizada” se refere à região da íris transformada de coordenadas cartesianas para coordenadas polares, obtido pelo processo de normalização do algoritmo de Daugman

2.3.2 CLBP - Completed Modeling of Local Binary Pattern

Existem diversas variações do LBP propostas na literatura, isto ocorre devido ao seu bom desempenho para discriminação de texturas em imagens, e também pela diversidade de aplicação. De maneira resumida, algumas dessas variações são: o *center-symmetric* LBP (CSLBP) (HEIKKILÄ; PIETIKÄINEN; SCHMID, 2009), o *Local Line Binary Pattern* (LLBP) (PETPON; SRISUK, 2009), *Multi-Block* LBP (MB-LBP) (ZHANG et al., 2007) e *Completed Modeling of Local Binary Pattern* (CLBP) (GUO; ZHANG; ZHANG, 2010).

O CLBP provê uma abordagem completa do LBP, em que além de se utilizar a informação contextual do *pixel* central em relação aos seus vizinhos, também é representada por uma transformada local da diferença sinal-magnitude *Local Difference Sign-Magnitude Transform* (LDSMT). Dessa maneira, para cada *pixel* central g_c é calculada a diferença entre g_c e seus vizinhos P uniformemente espaçados por um perímetro circular, definido por $d_p = g_p - g_c$. A diferença d_p é decomposta nos componentes de magnitude (m_p) e sinal (s_p), definido pela Equação 6 (BAGESTEIRO, 2015).

$$mp = |dp|$$

$$s_p = \begin{cases} 1, & \text{se } d_p \geq 0 \\ -1, & \text{se } d_p < 0 \end{cases} \quad (6)$$

Assim, três operadores são definidos na proposta de Guo, Zhang e Zhang (2010): o CLBP_S com a mesma definição do operador original LBP, o CLBP_M definido na Equação 7 e o CLBP_C (BAGESTEIRO, 2015).

$$CLBP_M_{P,R} = \sum_{p=0}^{P-1} t(m_p - c) 2^p$$

$$t(x, c) = \begin{cases} 1, & \text{se } x \geq c \\ 0, & \text{se } x < c \end{cases} \quad (7)$$

Na Equação 7, R determina o raio da vizinhança local e c define um limiar de maneira adaptativa, obtido originalmente pelo valor médio de m_p de toda imagem. Por fim, no operador CLBP_C é obtido um código binário por meio da limiarização global entre o *pixel* central e seus vizinhos. A Equação 8 define o cálculo para se obter este operador, onde c_I é a média dos níveis de cinza de toda imagem (BAGESTEIRO, 2015).

$$CLBP_C_{P,R} = t(g_c - c_I)$$

$$t(x, c_I) = \begin{cases} 1, & \text{se } x \geq c_I \\ 0, & \text{se } x < c_I \end{cases} \quad (8)$$

Após a extração destes três vetores de características, Guo, Zhang e Zhang (2010) propuseram algumas combinações entre eles. Ao combinar os modelos centrais (C) e de magnitude (M), é gerado o CLBP_M/C. Ao combinar o CLBP_S e CLBP_M, em duas dimensões, é obtido o CLBP_S/M. Combinando os três operadores, CLBP_S, CLBP_M e CLBP_C os autores se propuseram fazer isso de duas maneiras: com um histograma 3D chamado CLBP_S/M/C e, com um histograma 2D pela concatenação do CLBP_S/C e CLBP_M/C, representado como CLBP_S_M/C.

2.3.2.1 Aplicações do CLBP em Reconhecimento de íris

Há um grande número de trabalhos publicados na literatura utilizando-se o descritor CLBP, parte deles voltados para imagens médicas (OWJIMEHR; DANYALI; HELFROUSH, 2014), o reconhecimento de face humana (SINGH; MAURYA; MITTAL, 2012) e, para texturas invariantes a rotação (HU; LONG; ALREGIB, 2016). No entanto, aplicações que envolvam o reconhecimento de íris são pouco exploradas, podendo citar o trabalho de Tapia, Perez e Bowyer (2014).

O enfoque principal do trabalho proposto por Tapia, Perez e Bowyer (2014) é investigar métodos capazes de extrair características da íris para a identificação do gênero do usuário. A identificação de gênero vem sendo explorada para aplicações inteligentes de interface de usuário, análise forense, coleta de estatísticas demográficas para o *marketing*, etc. Normalmente os trabalhos que envolvem este tipo de abordagem utilizam a face humana como peculiaridade, e para tal proposta os autores propuseram a análise da textura da íris, em específico extrair informações de manchas, áreas, bordas, pontas de borda e curvas. Para a realização dos experimentos foram utilizadas amostras de íris da base de dados Notre Dame ND-Iris-0405. A Figura 5 ilustra algumas amostras de íris com pálpebras e cílios segmentadas de olhos femininos.

A partir dos resultados obtidos, os autores concluíram que o CLBP se mostrou pouco eficiente para esta abordagem, apresentando resultados superiores apenas quando foram combinadas com características uniformes do LBP. Contudo, foi obtido um percentual de acerto de 96.67% para gêneros masculinos e, 86.00% para femininos.

2.3.3 WLD - Weber Local Descriptor

Um método para descrição de textura local foi proposto por Chen et al. (2010), denominado *Weber Local Descriptor* (WLD). O método se baseia na extração de duas componentes da imagem: “diferencial de excitação” e “orientação”. Do mesmo modo que o descritor LBP, este método utiliza P amostras vizinhas definidas por um raio R a partir do *pixel* central (VIEIRA, 2013).

Considerando uma imagem I em escala de cinza com dimensão $M \times N$, em que uma

Figura 5: Amostras de íris do gênero feminino da base de dados Notre Dame ND-Iris-0405.

Fonte: (TAPIA; PEREZ; BOWYER, 2014)

região local 3×3 é representada por p elementos vizinhos de p_n

$$\begin{bmatrix} p_1 & p_2 & p_3 \\ p_4 & p_n & p_5 \\ p_6 & p_7 & p_8 \end{bmatrix}, \quad (9)$$

o “diferencial de excitação” ξ_n é dado por

$$\xi_n = \tan^{-1} \left(\frac{1}{p_n} \sum_{i=1}^8 p_i - p_n \right) \quad (10)$$

e a orientação do gradiente γ_n é dada por

$$\gamma_n = \tan^{-1} \left(\frac{p_4 - p_5}{p_7 - p_2} \right), \quad (11)$$

para todo $n = 1, \dots, MN$ pixels da imagem I (VIEIRA, 2013).

Na Equação 10 o numerador contendo a diferença de intensidade representa a variação de estímulo, ao passo que o denominador p_n representa o estímulo inicial. O “diferencial de excitação” ξ_n varia dentro do intervalo da função arco tangente, $\xi_n \in [-\pi/2, \pi/2]$. As regiões da imagem com alta variação de frequência correspondem ao “diferencial de excitação” ξ_n próximo de $-\pi/2$ e $\pi/2$, considerando que, os valores em torno de zero correspondem à variações de baixa frequência (VIEIRA, 2013).

A “orientação” é a segunda componente utilizada pelo método e representa a orientação do gradiente, e também se encontra no intervalo $[-\pi/2, \pi/2]$. No entanto, estes valores são deslocados para se variar $[0, 2\pi]$ pela análise dos sinais do numerador e denominador da função arco tangente, definida na Equação 11 (VIEIRA, 2013).

A Figura 6 apresenta um exemplo do cálculo das componentes do descritor WLD, em que ambas as componentes foram obtidas da Figura 6(a). O resultado do “diferencial de excitação” é ilustrado na Figura 6(b), já a componente de orientação do gradiente é apresentada na Figura 6(c).

Figura 6: Exemplos das componentes do WLD obtidas por duas imagens.

Fonte: Adaptado de (CHEN et al., 2010)

Após se obter as duas componentes, os autores propuseram a representação da textura por meio de um histograma, obtido por um processo denominado “quantização do vetor” (CHEN et al., 2010). Neste procedimento, as componentes “diferencial de excitação” e “orientação do gradiente” são introduzidas em uma matriz de duas dimensões para se obter o histograma final. Cada coluna da matriz corresponde a uma “orientação” e cada linha corresponde a um “diferencial de excitação”. Sendo assim, a intensidade de cada célula na matriz corresponde às frequências de um certo intervalo de “diferencial de excitação” para uma “orientação do gradiente” (VIEIRA, 2013).

2.3.3.1 Aplicações do WLD em Reconhecimento de íris

Este descritor de textura tem sido empregado com sucesso em aplicações de reconhecimento de expressões faciais, como abordado no trabalho de Liu, Zhang e Liu (2014),

por Wang et al. (2013) e em Hussain et al. (2014). No entanto não foi encontrado na literatura nenhum trabalho que explore a análise da textura da íris com este descritor, somente uma nova abordagem baseada no WLD para extração de características da íris bovina (SUN; ZHAO; YANG, 2013).

2.3.4 LMP - Local Mapped Pattern

Embora o *Texture Unit* (TU) e o *Local Binary Pattern* (LBP) possuam grande potencial para classificação de textura em imagens, ambos compartilham suas desvantagens. O descritor TU tem um custo computacional alto, visto que para cada *pixel* tem-se 6561 possibilidades de códigos. Utilizando o LBP o custo computacional é relativamente menor, porém há um aumento da sensibilidade a ruído², o que proporciona perda de informação (VIEIRA, 2013).

Frente a estes problemas, uma possível solução é a utilização da lógica *fuzzy*, técnica capaz de representar apropriadamente as incertezas e imprecisões do processo de aquisição de imagens. Algumas abordagens para análise de textura utilizando lógica *fuzzy* foram propostas na literatura, podendo citar os trabalhos de Caponetti et al. (2006), Iakovidis, Keramidas e Maroulis (2008), Boaventura (2010), Chierici et al. (2013).

Na proposta de Boaventura (2010), por exemplo, é utilizado o conceito de números *fuzzy* para detecção de bordas em imagens. Com base no potencial desta metodologia, uma nova abordagem para análise de micro-padrões em imagens foi proposto por Vieira (2013), nomeado como *Local Fuzzy Pattern* (LFP). Diferentemente dos trabalhos citados anteriormente, em que utilizam as regras *fuzzy* para se obter o código característico dos padrões, Vieira (2013) propõe a utilização dos conjuntos *fuzzy* para representar uma certa região, na qual cada *pixel* pode ser interpretado diretamente como um número *fuzzy*. Sendo assim, além de se reduzir o custo computacional a metodologia proporciona maior precisão na descrição das características da imagem (VIEIRA, 2013).

O código LBP, conforme proposto por Ojala et al. (2001), é gerado pela Equação 12 sendo o resultado da soma dos pesos onde o valor de $S(g_c, g_i) = 1$ (Figura 7(d)), neste exemplo: $LBP_{code} = 1 + 0 + 0 + 8 + 0 + 32 + 0 + 128 = 169$. A vizinhança dos *pixels* é apresentada na Figura 8.

$$LBP = \sum_{i=1}^8 S(g_c, g_i) 2^{i-1}, \quad S(g_c, g_i) = \begin{cases} 1, & \text{se } g_i \geq g_c \\ 0, & \text{se } g_i < g_c \end{cases} \quad (12)$$

A abordagem LBP mapeia uma estrutura de nível de cinza do pixel, dentro de uma vizinhança, para um histograma de 256 *bins*. No entanto esta formulação está limitada a uma vizinhança 3×3 , conforme descrito anteriormente. Com o intuito de desenvolver o

²O termo *ruído* em processamento de imagens é caracterizado por uma função de densidade de probabilidade $p(z)$, apresentando ocorrências de *pixels* isolados com intensidades diferentes de uma determinada região da imagem. (PEDRINI; SCHWARTZ, 2007).

Figura 7: *Local Binary Pattern*: a) Padrão local b) Resultado da limiarização c) Matriz de Pesos d) Código LBP.

Fonte: (OJALA et al., 2001)

g_1	g_2	g_3
g_4	g_c	g_5
g_6	g_7	g_8

Figura 8: Notação de uma vizinhança de *pixels* 3×3

método LBP para operar em uma vizinhança $W \times W$ e mapear o código resultante para um histograma de *bins* B , foi proposto por Vieira et al. (2012) equacionar o LBP conforme definido na Equação 13, em que f_g é a função de Heaviside (função degrau), mostrada na Equação 14, B é o número de *bins* do histograma e $M(i)$ é a matriz de pesos, ilustrada na Figura 7(c).

$$LBP = \text{round} \left(\frac{\sum_{i=1}^w f_g M(i)}{\sum_{i=1}^w M(i)} (B - 1) \right) \quad (13)$$

$$f_g = H[g_i - g_c] = \begin{cases} 1, & \text{se } [g_i - g_c] \geq 0 \\ 0, & \text{se } [g_i - g_c] < 0 \end{cases} \quad (14)$$

A partir da equação proposta, a função f_g tornou-se a “função de mapeamento” de uma estrutura de *pixel* em nível de cinza, representada localmente por uma vizinhança contendo um código específico no histograma, que originou o LMP, proposto naquele trabalho.

Na metodologia LMP, a função de Heaviside (Equação 14) utilizada na Equação 13 pode ser substituída por qualquer função de mapeamento. Além disso, a matriz de pon-

deração pode ser escolhida empiricamente e o parâmetro B pode ser otimizado (NEGRI; GONZAGA, 2014) (FERRAZ; JUNIOR; GONZAGA, 2014) (FERRAZ et al., 2014).

Objetivando a análise de textura, foi sugerida a utilização de uma aproximação da função de Heaviside, uma curva logística, ou uma curva sigmóide como apresentado na Equação 15, onde β é a inclinação da curva. A função sigmóide, cujo gráfico é uma curva em forma de “*S-Shaped*”, aparece em uma grande variedade de contextos, como as funções de transferência de muitas Redes Neurais Artificiais (RNA). Sua ubiquidade não é por acaso: as curvas estão entre as mais simples curvas não-lineares, permitindo um equilíbrio entre o comportamento linear e não-linear (NEGRI; GONZAGA, 2014) (FERRAZ; JUNIOR; GONZAGA, 2014) (FERRAZ et al., 2014).

$$f_g = \frac{1}{1 + e^{\frac{-[g_i - g_c]}{\beta}}} \quad (15)$$

A matriz de ponderação utilizada pelo LBP reforça a posição de pixel dentro da vizinhança. Isto torna o LBP não adequado para análise de texturas rotacionadas. Com a intenção de gerar um descritor de textura robusto às mudanças na rotação da imagem, foi então proposta a matriz de ponderação conforme apresentado na Equação 16.

$$M(i) = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (16)$$

Assim, cada padrão local definido por uma vizinhança $W \times W$ será mapeado para um *bin* no histograma h_b usando a Equação 17. A Figura 9 ilustra uma comparação entre o código LBP e LMP, adquirido por uma vizinhança de 3×3 , considerando $B = 256$ *bins* (NEGRI; GONZAGA, 2014).

$$h_b = \text{round} \left(\frac{\sum_{i=1} \left(\frac{1}{1 + e^{\frac{-[g_i - g_c]}{\beta}}} M(i) \right)}{\sum_{i=1}^w M(i)} (B - 1) \right) \quad (17)$$

A partir da Equação 13 pode-se utilizar qualquer função de mapeamento, como a curva sigmóide, a qual denomina-se o método LMP-s; se for utilizada a função de mapeamento triangular simétrica, define-se como LMP-t, e se for utilizada a função de Gauss, o descritor é chamado de LMP-g. Também pode-se chamar de LMP-h se for adotada a função de Heaviside (NEGRI; GONZAGA, 2014) (FERRAZ; JUNIOR; GONZAGA, 2014) (FERRAZ et al., 2014).

Assim como o LBP^{ri} , o *Sampled* (sLMP) foi desenvolvido para representar texturas invariantes à rotação e em multi-escala. A metodologia foi proposta inicialmente para o LFP por Chierici et al. (2013), e adaptada para o LMP, na qual é utilizado um conjunto de amostras P , por uma vizinhança circular R . Sendo assim, o código sLMP de uma

Figura 9: Comparação entre o código LBP e LMP em um padrão local de vizinhança 3×3 .

Fonte: (NEGRI; GONZAGA, 2014)

vizinhança $W \times W$ é obtido a partir de sucessivas rotações da imagem até se obter um valor mínimo. A função de mapeamento abordada foi a sigmóide, em que o valor de β ideal é estimado de forma empírica, após fase de treinamento.

2.3.4.1 Aplicações do LMP em Reconhecimento de íris

Embora o LMP tenha demonstrado ótimos resultados para diferentes tipos de textura em imagens digitais, o mesmo não tem sido explorado para texturas de íris. Este foi um dos fatores que motivou o desenvolvimento desta pesquisa, tendo como objetivo principal a avaliação de desempenho deste descritor em amostras de íris sob variação do tamanho da pupila.

2.4 Identificação biométrica de íris

A Biometria oferece uma solução natural e confiável para o problema de identificação pessoal, estabelecendo a identidade de uma pessoa com base em características biológicas ou comportamentais. Essas características podem ser obtidas a partir de diversas

peculiaridades, tais como: impressão digital, face, veias da mão, íris entre outros. Desse modo, as características biométricas constituem um forte “elo” entre o indivíduo e a sua identidade, o que permite não serem facilmente perdidas, compartilhadas ou forjadas.

A identificação pessoal por meio da análise de textura da íris foi inicialmente investigada em 1936 pelo oftalmologista Frank Burch, que sugeriu a íris como uma peculiaridade para sistemas biométricos. A teoria foi documentada em 1949 por James Daggarts. No entanto, a patente foi registrada apenas em 1987 pelos oftalmologistas Aran Safir e Leonard Flom, que basearam-se no conceito de que duas íris não são iguais, nem mesmo seu próprio par (ACKERMAN, 2013). A partir deste conceito novos estudos foram realizados com o objetivo de se investigar metodologias para extração de características visuais das trabéculas da íris, visando o processo automático de identificação biométrica. Algumas dessas metodologias são descritas de maneira detalhada no próximo capítulo.

Há uma grande variedade de sistemas biométricos baseados na estrutura da íris e já comercializados. Esses sistemas exigem a participação efetiva do usuário no momento da aquisição de uma amostra, e por isso são considerados como sistemas cooperativos. A partir da evolução da eletrônica e da informática é possível propor novas metodologias que não exijam a cooperação do usuário, sendo possível então, a identificação a distância. Apesar de muitas abordagens de reconhecimento de íris cooperativo obterem baixas taxas de erro, definido como *Equal Error Rate* (EER), estas funcionam sob condições de iluminação favoráveis, tendo como pré-requisito imagens com percentual baixo de ruído anatômico³. Para estas condições, é necessária a participação efetiva do usuário, tornando-se um procedimento invasivo. Portanto, é possível estabelecer algumas vantagens do reconhecimento de íris não cooperativo:

- a) **Segurança:** como não é necessária a concordância do usuário, os dispositivos podem estar fixados em locais estratégicos para identificação sem o conhecimento do mesmo;
- b) **Comodidade:** não é necessário posicionar os olhos próximo ao dispositivo, nem mesmo repetir o processo de aquisição para se obter uma amostra dentro dos padrões estabelecidos;
- c) **Aplicações:** os sistemas não cooperativos podem operar a uma distância maior que os sistemas cooperativos.

2.5 Trabalhos relacionados

Uma das primeiras abordagens para a aquisição automática de imagens de íris não cooperativa foi proposta em 1996 no trabalho de Hanna et al. (1996). Os autores desenvolveram um sistema para localização e aquisição da imagem da íris a aproximadamente

³O termo *ruído anatômico* se refere a artefatos que não façam parte da íris delimitada pelas fronteiras da pupila e esclera, tais como: oclusões por pálpebras/cílios e reflexos especulares.

1 metro de distância da câmera. O sistema é composto por duas lâmpadas incandescentes que ilumina o rosto do usuário no momento da aquisição da imagem. Os reflexos especulares produzidos pelas lâmpadas são utilizados para direcionar o campo de visão da câmera na região dos olhos, obtendo-se assim uma imagem para o pré-processamento no algoritmo de John Daugman. A proposta parece ter demonstrado um bom desempenho, porém é necessária uma iluminação adequada do ambiente para a localização do olho.

O sistema “*Iris on the move (IOM)*” foi proposto por Matey et al. (2006) visando o controle de acesso automático de usuário em movimento. O equipamento de digitalização das imagens é composto por um portal contendo sensores que ativam a captura de uma amostra da face quando o usuário passa por ele. Uma câmera sensível ao infravermelho é utilizada para aquisição das imagens, modelo Pulnix TM-4000CL, com resolução de até 2048×2048 *pixels*.

A imagem da face é capturada à uma distância de 3 metros, conforme é ilustrado na Figura 10(b) (direita). A partir do volume da face é realizado um pré-processamento da imagem para se obter a localização da região ocular Figura 10(b) (esquerda), e posteriormente a segmentação da íris. Em média, é obtida uma amostra da íris com resolução de 200×150 *pixels*, da qual são extraídos os atributos por meio do algoritmo de Daugman, licenciado pela *Iridian Technologies* (MATEY et al., 2006). Para se obter um bom desempenho é necessário que o usuário caminhe pelo portal com velocidade limitada a até 1m/s.

(a) Sistema de aquisição de imagem da íris

(b) Imagens da íris capturada pelo dispositivo

Figura 10: Aquisição da amostra de íris pelo *IOM System*.

Fonte: Adaptado de (MATEY et al., 2006)

No trabalho de Phillips et al. (2009) é proposta uma base de dados a partir de sequências de vídeos de íris, utilizando o dispositivo “*Iris on the move*” para aquisição das amostras. A base denominada *Multi-Biometric Grand Challenge database* possui 110 classes, contendo 1 amostra de vídeo por classe, com aproximadamente 300 *frames*. Cada *frame* possui uma resolução espacial de 640×480 *pixels*, que correspondem à região ocular de um dos olhos. Sendo assim, a base de dados contém no total 600 *frames* por classe,

300 do olho esquerdo e 300 do olho direito.

Ainda utilizando amostras do sistema “*Iris on the move (IOM)*”, é proposta por Jillela, Ross e Flynn (2011) uma análise da base de dados *Multi-Biometric Grand Challenge database* por meio da sequência de *frames* da íris em movimento. Foi observado que as sequências de vídeo contém *frames* de baixa resolução, devido as condições dinâmicas e não cooperativas na etapa de aquisição. Desta forma, o autor propõe a utilização da Transformada de Componente Principal (TCP) para reconstruir os dados. A metodologia proposta utiliza 6 *frames* por classe de baixa resolução, escolhidos de forma empírica, na qual foi calculada a magnitude do componente principal para cada *frame*. Após este procedimento, é realizada a fusão entre o *frame* resultante da TCP com o *frame* original, obtendo-se uma imagem de alta resolução. Para avaliar a proposta o autor utilizou o algoritmo de Daugman antes e após a aplicação da metodologia proposta. A partir dos experimentos foi reduzida a taxa de erro (EER) de 6.09% para 1.76% com íris do lado direito, e de 5.45% para 1.48% com íris do lado esquerdo.

No trabalho proposto por Dong, Sun e Tan (2009), é abordado o desenvolvimento de um dispositivo para aquisição de imagens de íris a uma distância de 3 metros. O dispositivo utiliza o sistema *Pan-Tilt-Zoom (PTZ)* para rastrear, focalizar e capturar imagens estáticas da face em alta resolução (2352×1728 *pixels*), utilizando iluminação infravermelha. A Figura 11(b) ilustra uma amostra obtida a partir do processo de aquisição pelo usuário ilustrado na Figura 11(a). Baseado no dispositivo, foi construída uma base de dados denominada CASIA-Iris-Distance, desenvolvida em conjunto com a Academia Chinesa de Ciências do Instituto de Automação, a qual encontra-se disponível para uso acadêmico (DATABASE, 2011) (DONG; SUN; TAN, 2009).

(a) processo de aquisição da amostra

(b) amostra capturada pelo dispositivo

Figura 11: Aquisição da amostra de íris pelo *IOM System*.

Fonte: Adaptado de (DONG; SUN; TAN, 2009)

Utilizando-se a base de dados CASIA-Iris-Distance, é proposto por Arora, Londhe e Acharya (2012) um método para classificação das amostras de íris a distância. Na metodologia de Arora, Londhe e Acharya (2012) são utilizadas as duas íris (esquerda e

direita) em conjunto para se obter um melhor desempenho na classificação das amostras. Os autores aplicam o algoritmo de Daugman para um conjunto de 100 amostras, divididas em 20 classes. A partir dos resultados obtidos, os autores concluíram que a utilização das duas íris não foi significativa para determinar um melhor desempenho, em que o limiar de decisão foi o de 0.40 com Taxa de Falsa Aceitação $FAR = 2.8556$ e Taxa de Falsa Rejeição $FRR = 32.9059$.

A metodologia proposta por Souza (2012) seleciona amostras de íris a distância com baixa ausência de ruído anatômico. O percentual de ruído anatômico de uma amostra é calculado a partir da área de isolamento de pálpebras e cílios quando se utiliza o algoritmo de Daugman. Os resultados demonstraram que amostras contendo no máximo 40% de ruído anatômico são consideradas aptas à etapa de classificação, sendo que a partir deste nível o sistema descarta as amostras com este tipo de ruído. A metodologia pode ser aplicada por meio de *frames* de vídeo, nos quais é selecionado um conjunto de amostras com um grau de confiabilidade aceitável. A partir da base de dados CASIA-Iris-Distance foi obtida a acurácia de 22,52% antes da aplicação da metodologia, e após foi obtida 65,66%. A metodologia foi aplicada também a uma base de dados não cooperativa, construída pelo autor a partir de um dispositivo móvel. A base de dados é formada por seqüências de vídeos conforme ilustra a Figura 12, e foi desenvolvida para avaliar a metodologia proposta. Os experimentos com esta base de dados foram baseados em um conjunto de 10 *frames*, divididos por 25 classes, obtendo-se uma acurácia de 32,06% antes da metodologia, e após 73,19%.

Figura 12: Exemplo de amostras capturadas a distância por seqüência de vídeo.

Fonte: (SOUZA, 2012)

Alguns sistemas de reconhecimento de íris não cooperativos usam as duas ilumina-

ções, infravermelha e visível. Por exemplo, o *Eagle-Eyes* proposto por Bashir et al. (2008) realiza a aquisição de amostras de íris por diferentes ângulos a uma distância de até 6 metros. A metodologia abordada pelo autor visa rastrear o movimento do usuário utilizando o rastreamento de face na banda visível, de onde são coletadas informações precisas da posição do rosto do usuário. Essas informações são passadas como parâmetros para outra câmera sensível ao infravermelho, que focaliza a região ocular e captura uma amostra a distância de um dos olhos. As movimentações dinâmicas das câmeras são realizadas de forma automática, pelo sistema *Pan-Tilt-Unit* (PTU). Assim como proposto por Matey et al. (2006), o *Eagle-Eyes* foi construído para ser capaz de lidar com quantidades moderadas de movimento, com caminhada de baixa velocidade.

A proposta de Proença (2009) foi apresentar um protótipo para aquisição de imagens de íris a distância na banda visível. Para construir o protótipo o autor utilizou uma câmera modelo Canon EOS 5D, posicionada sob um tripé a uma distância de 4 a 8 metros. A câmera foi fixada em um ambiente fechado para se obter um controle de iluminação moderado durante a formação da base de dados UBIRIS V2 (PROENÇA et al., 2010). A Figura 13(a) ilustra o processo de aquisição da amostra por meio do protótipo construído, na qual é ilustrado na Figura 13(b) um exemplo de 4 amostras da base de dados UBIRIS V2 (PROENÇA et al., 2010).

Figura 13: Dispositivo utilizado para formação da base de dados UBIRIS V2.

Fonte: Adaptado de (PROENÇA et al., 2010)

Para avaliar a base de dados UBIRIS V2, foi apresentada no trabalho de Proença (2009) uma análise detalhada do foco, movimento, ângulo, oclusões, área utilizada, dilatação pupilar e níveis de pigmentação da íris. Estas informações foram essenciais para se obter uma boa segmentação das imagens, garantindo que o nível de ruído anatômico não interfira na etapa de classificação. A Transformada de Fourier foi utilizada neste trabalho para verificar amostras com borramento (movimento) e reflexo especular na superfície da íris. O conjunto de amostras segmentadas foram divididas e classificadas em três ca-

tegorias: amostras sem qualidade (somente ruidosas), amostras com mínima qualidade (maioria ruidosas + boa qualidade) e amostras com boa qualidade. Dessa maneira, é possível estimar a qualidade das amostras por meio da segmentação das áreas com/sem oclusão, como é ilustrado na Figura 14. A partir destes experimentos foi obtido $EER = 0.1777$ usando amostras sem qualidade, $EER = 0.0943$ utilizando amostras com mínima qualidade e $EER = 0.0520$ selecionando somente amostras com boa qualidade.

Figura 14: Exemplo de amostras da base UBIRIS V2 segmentadas.

Fonte: (PROENÇA, 2009)

A abordagem de Villar, Ives e Matey (2010) foi certamente uma das mais desafiadoras neste seguimento, os autores desenvolveram um sistema de reconhecimento de íris de longa distância, denominado *Iris-at-a-Distance* (IAAD). O protótipo tem suporte para aquisição de imagens em até 30 metros de distância e foi desenvolvido a partir de uma câmera *wide-field-of-view* (WFOV), acoplada sob uma plataforma de movimentação *Pan-Tilt*. A câmera WFOV é utilizada somente para detectar a face e os olhos, por meio da biblioteca OpenCv, utilizando o método Cascata de Haar. Acima da câmera WFOV, foi acoplado um telescópio de 8 polegadas para aquisição da imagem da íris a distância. A imagem é capturada a partir da informação vinda de um sensor a laser, acoplado ao protótipo para determinar a distância exata do usuário. As informações vindas da câmera WOFV por detecção de face e olhos são passadas para a plataforma, que realiza o ajuste vertical e horizontal da região da íris, para que o telescópio capture uma imagem. A Figura 15(a) ilustra o protótipo construído e o processo de aquisição da amostra é apresentado na Figura 15(b), a partir do software implementado na Figura 15(c).

O software desenvolvido possui rotinas de pré-processamento e classificação por meio do algoritmo de Daugman. Para avaliar o desempenho do protótipo foram capturadas 20 amostras, sendo estas com o usuário posicionado a uma distância de 29 metros. Em outra ocasião, a mesma amostra do usuário foi coletada a partir de um dispositivo cooperativo, o *IrisAccess 4000*, e comparada com as amostras obtidas a partir do protótipo. A Figura 16(a) ilustra a amostra capturada pelo dispositivo *IrisAccess 4000* e seu respectivo código de íris (Iriscode) na Figura 16(c), calculado pelo método de Daugman. A

Figura 15: Protótipo para aquisição de amostras de íris a 30 metros de distância.

Fonte: Adaptado de (VILLAR; IVES; MATEY, 2010)

Figura 16(b) ilustra uma amostra do mesmo usuário capturada pelo protótipo, em que foi classificada como positiva a partir da comparação entre o código de íris da Figura 16(c) com o código da Figura 16(d). Infelizmente os autores não descrevem os resultados obtidos a partir das amostras coletadas a distância.

Figura 16: Amostras de mesma classe classificadas como genuína pelo sistema.

Fonte: Adaptado de (VILLAR; IVES; MATEY, 2010)

Uma nova metodologia para o reconhecimento da íris baseada em características dinâmicas foi proposta por Costa (2010). As características são coletadas por meio de um protótipo que captura uma sequência de vídeo. O protótipo construído possui semelhança com um binóculo, sendo que do lado esquerdo foi posicionada uma câmera sensível ao in-

fravermelho próximo para captura de imagens da íris, e do lado direito uma luz branca. A fase de coleta dura em média 35 segundos, na qual são coletados 1000 *frames*. Durante este período, o olho direito recebe estímulos de luz branca em tempos determinados pelo software, e no olho esquerdo é capturado o vídeo.

A ideia principal dos estímulos é produzir dilatação e contração da pupila durante o processo de aquisição do vídeo. Por meio do reflexo consensual é possível adquirir no olho esquerdo o mesmo comportamento do olho direito estimulado pela luz. Sendo assim, a partir das ações da pupila é possível estimar o diâmetro, circularidade, tempo e taxa de contração/dilatação. Além dessas características é possível estimar por meio da textura alguns atributos, como correlação, segundo momento angular, entropia, contraste e momento da diferença inverso. Para complementar o vetor de características, foram extraídos dos níveis de cinza da imagem a média, desvio padrão e variância. No total, são utilizadas 12 características por amostra, sendo que a similaridade entre elas foi obtida pela distância euclidiana.

Para a realização dos experimentos foram utilizadas 114 classes, contendo 1 amostra de vídeo por classe. Os resultados apontaram que é possível identificar biometricamente um indivíduo pelas características dinâmicas da íris, com um percentual de acerto de 83,33%.

2.6 Medidas de desempenho em sistemas biométricos

A aquisição de amostras biométricas é realizada por dispositivos eletrônicos contendo sensores de digitalização. Por este motivo, é necessário que o usuário repita o procedimento uma ou mais vezes caso não seja identificado pelo sistema. A maioria dos sistemas biométricos armazenam duas ou mais características no banco de dados, com a finalidade de aumentar a precisão. Em linhas gerais, a classificação de uma amostra ocorre de duas formas:

- a) **um-para-um** - o usuário se identifica como sendo genuíno por meio de uma identidade e como forma de comprovação apresenta sua característica biométrica, sendo então realizada uma comparação entre 1 amostra do banco de dados com 1 amostra coletada naquele instante. O custo computacional desta metodologia é considerado baixo.
- b) **um-para-muitos** - o usuário não se identifica, apenas apresenta sua característica biométrica para que o sistema fique encarregado de buscar no banco de dados uma amostra com similaridade próxima a esta apresentada. O custo computacional desta metodologia é considerado alto, visto que o algoritmo irá procurar dentro do banco uma amostra similar para identificá-lo.

A etapa de classificação é considerada uma das etapas mais importantes de um sistema biométrico. Para determinar o grau de similaridade entre duas amostras é necessário

que seja realizada a calibragem, processo pelo qual visa distribuir o grau de similaridade obtido entre as amostras do banco de dados, e decidir um critério de aceitação e rejeição. Em outros termos, a calibragem pode ser chamada de “ambiente de decisão” (BRAVO, 2006; CARNEIRO, 2010).

Baseado neste contexto, é dado um exemplo: um usuário João fornece uma amostra B ao sistema biométrico, que é armazenada no banco de dados em $Q = S(B)$. Posteriormente, em outra situação, uma nova amostra B' é capturada pelo sistema, em que é calculado o *template* $Q' = S(B')$. Desta forma, é possível definir duas hipóteses H_0 e H_1 , em que:

H_0 : B' é classificada como João, baseado no resultado da comparação com a amostra B .
 H_1 : B' não é classificada como João, baseado no resultado da comparação com a amostra B .

Sendo assim, a medida de similaridade entre os *templates* é calculada por $s_m = \text{Sim}(Q, Q')$, definida pelo limiar de decisão Td , em que, se $s_m \geq Td$ escolhe-se a hipótese H_0 identificando a amostra como sendo de João, senão, se $s_m < Td$ acata-se a hipótese H_1 e não classifica a amostra como sendo de João (BRAVO, 2006).

Quando se decide por H_0 sendo na verdade H_1 , ocorreu uma falsa aceitação. Se se decide por H_1 sendo na realidade H_0 , ocorreu uma falsa rejeição (BRAVO, 2006). Sendo assim, define-se:

- a) **Falsa aceitação** - é uma falha do sistema biométrico, na qual foi classificado um usuário desconhecido como sendo genuíno.
- b) **Falsa rejeição** - é uma falha do sistema biométrico, na qual foi rejeitado um usuário genuíno como sendo impostor.

Define-se $Q = Q'$, quando B e B' formam um par casado, caso contrário B e B' são definidos como um par não-casado. Para se obter um parâmetro do número de pares casados e não casados é realizada a distribuição por meio de histogramas ou densidades, conforme ilustra a Figura 17, na qual EER é o ponto em que as frequências de FAR e FRR são iguais. Assim, pares casados correspondem à distribuição intra-classe e pares não-casados à distribuição inter-classe (BRAVO, 2006) (CARNEIRO, 2010).

A Taxa de Falsa Aceitação (FAR), é definida pela probabilidade de ocorrência de impostores aceitos, calculada a partir de:

$$FAR = \frac{NFA}{NIIA},$$

na qual, NFA é o número de falsas aceitações e NIIA o número de tentativas de identificação de impostores.

A Taxa de Falsa Rejeição (FRR), é estimada pela probabilidade de ocorrência de genuínos rejeitados, calculada a partir de:

Figura 17: Distribuição dos pares casados e não casados.

Fonte: Adaptado de (CARNEIRO, 2010)

$$FRR = \frac{NFR}{NEIA},$$

em que, NFR é o número de falsas rejeições e NEIA o número de tentativas de identificação de usuários genuínos.

Com base nos valores de FAR e FRR, obtém-se uma medição global da taxa de erros e, resumidos em uma única curva denominada *Detection Error Tradeoff* (DET). A curva DET é uma variante da curva *Receiver Operating Characteristics* (ROC), e tem sido amplamente utilizada para apresentar as características de desempenho dos sistemas biométricos (MARTIN et al., 1997).

Conforme ilustrado na Figura 17, o limiar define a precisão do sistema biométrico. A escolha do melhor limiar é definida conforme aplicação, e estes estão divididos em três grupos:

- a) **Aplicações Cíveis** - Este grupo de aplicações utiliza o critério de minimização da frequência FAR e FRR, utilizando-se a EER. Dessa maneira, o equilíbrio das duas taxas garante uma melhor segurança e conveniência.
- b) **Sistemas de alta segurança** - Este grupo utiliza FAR muito baixa, se possível nula. A idéia principal é reduzir a possibilidade de acesso de impostores, porém deixa o sistema biométrico muito sensível à classificação, exigindo maior cooperação do usuário na etapa de aquisição.
- c) **Aplicações Forenses** - A análise forense é uma área de investigação, em que não se conhece quem é o suspeito. Nestes casos são utilizadas baixos valores de FRR, cujo o objetivo é prevalecer ao máximo a possibilidade do usuário ser um genuíno do que um falso genuíno. Na prática, este critério visa apontar dois ou mais indivíduos como genuínos, para que estes sejam investigados por meio de

outros critérios. A curva DET apresentada na Figura 18 ilustra os critérios de definição do melhor limiar conforme a aplicação abordada.

Figura 18: Pontos de decisão em sistemas biométricos ilustrado pela curva DET.

2.7 Método de Daugman

Em 1987 os oftalmologistas Leonard Flom e Aran Safir observaram em diversas texturas de íris padrões que poderiam ser utilizados para identificação de seres humanos (ACKERMAN, 2013). A partir desta descoberta alguns métodos para classificação das características da íris foram propostos na literatura, como o método de Wildes et al. (1994), o de Boles e Boashash (1998), de Ma et al. (2004) e o método de Daugman (1993).

John Daugman, pesquisador do Laboratório de Computação da Universidade de Cambridge (UK) desenvolveu o primeiro algoritmo computacional para classificação das características da íris (DAUGMAN, 1993). O algoritmo é dividido em 4 fases, (I) localização e segmentação da região de interesse, (II) normalização da estrutura, (III) descrição e (IV) classificação dos padrões aleatórios da íris.

Na primeira fase o autor propõe a utilização de um operador íntegro diferencial para localizar as fronteiras entre a íris/esclera e íris/pupila, formalmente descrita pela Equação 18 (DAUGMAN, 1993).

$$\max_{(r,x_0,y_0)} \left| G_\sigma(r) * \frac{\partial}{\partial r} \oint_{r,x_0,y_0} \frac{I(x,y)}{2\pi r} ds \right| \quad (18)$$

em que, $G_\sigma(r)$ faz a suavização do gradiente utilizando o filtro Gaussiano. O contorno entre as fronteiras (r, x_0, y_0) é obtido pela derivada na direção r , somadas pelas inten-

sidades da imagem ao longo de um arco circular ∂s de raio r e coordenadas de centro (x_0, y_0) .

Após a localização e contorno das fronteiras, faz-se a normalização da região, processo que visa minimizar as variações da estrutura da íris, proporcionadas pelas dilatações. Desta forma, a região de interesse em coordenadas cartesianas $I(x, y)$, é representada em coordenadas polares $I(r, \theta)$, cuja origem se encontra na região central da pupila. A forma em que se define este processo é descrito pelas Equações 19 a 21.

$$I(x(r, \theta), y(r, \theta)) \rightarrow I(r, \theta) \quad (19)$$

$$x(r, \theta) = (1 - r)x_p(\theta) + rx_s(\theta) \quad (20)$$

$$y(r, \theta) = (1 - r)y_p(\theta) + ry_s(\theta) \quad (21)$$

Para descrever as características existentes na textura da íris, o autor propõe o Filtro de Gabor 2D, descrito pela Equação 22. Basicamente, utiliza-se os parâmetros α e β , variando com o inverso da frequência ω , para se obter um conjunto de filtros centralizados, por meio da projeção de blocos de dimensões fixas. O código da íris é obtido pela compactação dos dados da imagem decomposta na etapa anterior, e é representado por um conjunto de 2.048 *bits*.

$$H(r, \theta) = e^{-j\omega(\theta_0 - \theta)} e^{-(r_0 - r)/\alpha^2} e^{-(\theta_0 - \theta)/\beta^2} \quad (22)$$

Por fim, a classificação de duas amostras por seus respectivos códigos, é obtida pela Distância de Hamming. O cálculo é realizado por operadores booleanos, nos quais XOR faz a detecção de discordâncias entre os pares de *bits* e AND descarta do teste os *bits* corrompidos por ruído anatômico. A forma como descreve este processo é representado formalmente pela Equação 23.

$$HD = \frac{\sum[A \otimes B] \cap maskA \cap maskB}{\sum[maskA \cap maskB]} \quad (23)$$

Como a imagem da íris pode apresentar variações rotacionais no momento da aquisição da amostra, Daugman (1993) sugeriu um método para corrigir o desalinhamento dos *bits* durante a comparação dos vetores de característica. O método realiza o deslocamento de dois *bits* na direção horizontal (esquerda ou direita) de um dos vetores, obtendo-se a cada deslocamento um valor correspondente de distância de Hamming. O número de deslocamentos a serem realizados na etapa de comparação é determinado pela diferença angular máxima entre duas imagens da mesma íris. Ao final do processo, a menor distância de Hamming é considerada para a tomada de decisão.

2.8 Considerações finais

Neste capítulo foi apresentada uma revisão teórica sobre os descritores de textura e a biometria de íris. Na primeira parte do capítulo foram abordados os principais descritores de textura local, que definem uma metodologia para análise de micro padrões. Levando-se em conta que o LBP gera uma quantidade menor de códigos em relação ao TU, pode-se afirmar que o tempo de processamento dele deve ser menor. O CLBP se apresenta como uma versão melhorada do LBP, as componentes de magnitude e a diferença de sinal são agregadas no algoritmo para se aumentar o poder de discriminação, no entanto o custo computacional é aumentado devido ao tamanho dos vetores de característica. Já o WLD se mostra um descritor de textura poderoso e, tem um desempenho melhor do que o LBP para os diferentes tipos de texturas. Outro método que se mostra superior ao LBP é o LMP, pelo fato de se utilizar funções de mapeamento mais adequadas para a representação de regiões locais, tornando-o mais robusto para texturas com ruído.

Na segunda parte do capítulo, foram apresentados dois tipos de sistemas biométricos baseados na estrutura da íris: os sistemas cooperativos, com base na aquisição de amostras com distância pré-definida e iluminação controlada e; os não cooperativos, ou a distância, que adquire amostras sob iluminação variada a distâncias maiores que 1 metro. O primeiro utiliza imagens com boa qualidade para extração da textura e, o último trabalha com imagens de baixa resolução e alto nível de ruído anatômico. Além disso, foram apresentados diversos problemas que podem ocorrer nestes sistemas biométricos, um deles direcionado ao foco desta tese, sendo os movimentos involuntários da pupila (contração e dilatação), causados pela variação de luz no ambiente de aquisição da imagem da íris (COSTA, 2010). Este problema pode ocorrer em ambos os sistemas, pois as respostas pupilares são causadas por vários motivos, tais como: baixa/alta incidência de luz no ambiente (HOLLINGSWORTH; BOWYER; FLYNN, 2008), uso de bebidas alcoólicas/drogras (ARORA et al., 2012) e o estado emocional (CARVALHO, 2010). Na grande maioria dos casos, os métodos tradicionais para reconhecimento de íris não fornecem resultados satisfatórios para este último problema (HOLLINGSWORTH; BOWYER; FLYNN, 2008).

No próximo capítulo, uma nova metodologia baseada no LMP é proposta para análise da textura da íris, em específico este método é apresentado como uma nova abordagem para texturas de íris sob contração e dilatação da pupila, adquiridas por exemplo em ambiente não cooperativo.

Descritores propostos para textura de íris

Neste capítulo serão apresentados dois novos descritores de textura local para análise da textura da íris, nomeados como: *Median Local Mapped Pattern* (Median-LMP) e *Modified Median Local Mapped Pattern* (MM-LMP).

3.1 Considerações iniciais

A maioria dos trabalhos encontrados na literatura sobre o reconhecimento de íris tentam resolver os problemas causados por reflexos especulares (PROENÇA, 2009), cor (RADU, 2013), oclusões devido às pálpebras ou cílios (SOUZA, 2012), e baixa resolução devido à distância (MATEY et al., 2006). No entanto, é importante ressaltar que em sistemas de reconhecimento de íris o problema de dilatação e contração da pupila degrada o desempenho desses sistemas (HOLLINGSWORTH; BOWYER; FLYNN, 2008). Além disso, amostras coletadas a uma certa distância e com variação de luminosidade estão sujeitas à degradação por ruído anatômico e, principalmente por ruídos digitais, que são afetados durante o processo de aquisição e transmissão da imagem. Os principais fatores que ocasionam o aparecimento de ruído digital em imagens digitais são: qualidade do sensor, iluminação do ambiente, movimentação do objeto de cena e temperatura local. Dentre os principais tipos de ruído, destacam-se o ruído impulsivo, exponencial, gaussiano, uniforme, entre outros (PEDRINI; SCHWARTZ, 2007).

O trabalho de Hafiane, Seetharaman e Zavidovique (2007), motivou o desenvolvimento de um novo descritor para textura de íris que seja robusto ao ruído e ao problema de degradação pela dilatação e contração da pupila, aspectos estes encontrados com maior frequência em sistemas não cooperativos. Em Hafiane, Seetharaman e Zavidovique (2007) é proposto um descritor de textura invariante à rotação *Median Binary Pattern* (MBP) com base no LBP. A proposta dos autores foi utilizar o valor mediano como referência à limiarização, mapeando cada *pixel* da imagem para um novo valor binário de 9 *bits*.

O método proposto nesta tese é chamado de *Median Local Mapped Pattern* (Median-LMP), e foi desenvolvido com base no LMP. A idéia principal do descritor é utilizar o valor mediano da vizinhança local como elemento de comparação entre os vizinhos, o que no LMP utiliza-se o valor do *pixel* central. Isso permite uma melhor representação da textura e a geração de um código mais robusto, resistente ao ruído devido à comparação ser realizada com o valor da Mediana da vizinhança e não com o valor do *pixel* central, que pode ser ruidoso, contaminando o código de textura gerado. Além disso, uma modificação na matriz de pesos do Median-LMP é proposta como um novo descritor, denominado *Modified Median Local Mapped Pattern* (MM-LMP).

3.2 Median Local Mapped Pattern (Median-LMP)

O LMP inicial considera a soma das diferenças de cada nível de cinza de uma determinada vizinhança em torno do *pixel* central como um padrão local que pode ser mapeado para um histograma usando uma função de mapeamento. É importante notar que, nos mesmos trabalhos previamente publicados sobre o descritor LMP, na matriz de ponderação $M(i)$ o peso central é também “um” e não “zero” (CHIERICI et al., 2013; FERRAZ; JUNIOR; GONZAGA, 2014). O mesmo conceito foi abordado pela metodologia WLD fornecendo um “filtro de média” durante o mapeamento (CHEN et al., 2010).

Como o LMP é um método paramétrico, usando a função de mapeamento sigmoidal, a curva de inclinação β na Equação 17 deve ser ajustada (ou sintonizada) visando o melhor desempenho de cada base de dados de textura. O valor ótimo de β (inclinação da curva) é sintonizado utilizando-se um conjunto de treino. A comparação entre duas amostras é realizada por meio da distância Chi-quadrado para avaliar o melhor ajuste entre os dois histogramas. Uma amostra de consulta pode ser considerada corretamente classificada desde que tenha a distância mais próxima a partir da amostra de treinamento da mesma classe (VIEIRA, 2013).

Um dos pontos mais fortes mencionados em trabalhos anteriores sobre o descritor LMP é o seu baixo custo computacional associado a um alto desempenho (CHIERICI et al., 2013; FERRAZ; JUNIOR; GONZAGA, 2014). Entretanto, pequenas diferenças quando se comparam os padrões, devido ao ruído ou mudança de iluminação podem introduzir erros, principalmente se o valor do *pixel* central mudar de um padrão para outro. Hafiane, Seetharaman e Zavidovique (2007) observaram o mesmo fenômeno e propuseram um novo descritor baseado no LBP, denominado *Median Binary Pattern* (MBP), resultando em um método mais robusto para os erros causados pela comparação com o *pixel* central.

Com base no MBP e levando-se em consideração que o LMP possui melhor desempenho do que LBP para texturas genéricas, é proposto nesta tese um novo descritor de textura chamado *Median Local Mapped Pattern* (Median-LMP) para a discriminação de textura de íris com variação do tamanho da pupila. A “mediana” (M_d) é uma medida de posição

separatriz, pois divide o conjunto de dados em duas partes iguais, com o mesmo número de elementos. Se o conjunto de dados tem um número ímpar de elementos, a mediana está situada no centro do conjunto, e pode ser obtida pela Equação 24. Se o conjunto de dados tem um número par de elementos, a mediana é dada pela média dos dois elementos situados no centro, conforme define a Equação 25 (LARSON; NETO, 2010).

$$\text{se } n \text{ é ímpar, } E_{M_d} = (n + 1)/2 \quad (24a)$$

$$M_d = X_{E_{M_d}} \quad (24b)$$

$$\text{se } n \text{ é par, } E_{M_d} = n/2 \quad (25a)$$

$$M_d = (X_{E_{M_d}} + X_{E_{M_d}+1})/2 \quad (25b)$$

Em sistemas de processamento de imagem o filtro da mediana reduz eficazmente o ruído conhecido como “sal e pimenta”, preservando o contorno e pequenos detalhes da imagem (GONZALES; WOODS, 2000). O processo de filtragem por meio do “filtro da mediana” consiste em substituir o nível de cinza de cada *pixel* pela mediana dos níveis de cinza vizinhos daquele *pixel* (PEDRINI; SCHWARTZ, 2007; GONZALES; WOODS, 2000). Sendo assim, a imagem filtrada proporciona um melhor desempenho para as etapas posteriores ao processamento da imagem, como por exemplo a descrição dos atributos, apresentada no capítulo anterior.

É importante lembrar que a imagem da íris adquirida a uma distância em um ambiente não cooperativo pode ser afetada por ruído. O mesmo ocorre nas bases de dados adquiridas sob iluminação controlada, visto que as principais fontes de ruído surgem no processo de aquisição e transmissão. Segundo Gonzales e Woods (2000) o ruído pode estar associado a condições ambientais, qualidade do sensor, temperatura, etc.

Por isso, é proposto utilizar o valor mediano de uma vizinhança $W \times W$ como o elemento de comparação, isto é, foi alterado o g_c na Equação 15 pelo valor mediano da vizinhança analisada. Além disso, adotou-se também a matriz de ponderação $M(i)$ como um “filtro de média”, estabelecendo o peso central como “um”.

A Figura 19(a) mostra um exemplo de uma região de textura local afetada pelo ruído no *pixel* central Figura 19(b). Aplicando o descritor LMP Figura 19(c), o código gerado por este padrão vai ocupar o *bin* “14” no histograma. Ao utilizar a proposta Median-LMP Figura 19(d), o ruído irá ser descartado e o código gerado será mais representativo, resultando em um descritor de textura mais robusto. Assim, o histograma vai ser mais representativo e a textura tem maior chance de ser classificada corretamente.

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

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

(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 1 1
10 255 30	0 1 0.5	1 1 1
100 15 20	1 0 0	1 1 1

$$Median-LMP_{code} = round\left(\frac{1+1+0+0+1+0.5+1+0+0}{9}(256-1)\right) = 128$$

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

Figura 19: Comparação entre o código LMP e Median-LMP.

3.3 Modified Median Local Mapped Pattern (MM-LMP)

A maioria dos descritores de textura propostos na literatura incluem uma matriz de ponderação como um filtro de suavização para obtenção do código. Por exemplo, o descritor WLD combina a saída de dois filtros (f_{00} e f_{01}) antes do mapeamento do código. Já no descritor LMP é utilizada uma matriz de média com pesos igual a “um”. Para obtenção do código binário nos descritores LBP, CLBP e MBP, cada posição da matriz limiarizada é multiplicada por uma matriz de pesos formada por “potência de dois”, ou seja, $w = [2^0, 2^1, 2^2, 2^3, 2^4, 2^5, 2^6, 2^7]$, e sua representação pode ser visualizada abaixo:

$$M(i) = \begin{bmatrix} 1 & 2 & 4 \\ 8 & 0 & 16 \\ 32 & 64 & 128 \end{bmatrix} \quad (26)$$

Observando as variações do LBP, a maioria delas adota a mesma matriz de pesos. Por esta razão, levantou-se uma hipótese do uso dessa matriz no Median-LMP, ou seja, em

vez de um “filtro de média” com todos os pesos iguais a um, é proposto a “potência de dois” como ilustrado na Equação 26. Isso é justificado devido ao fato de que o Median-LMP já possui um “filtro de mediana” incluído, evitando o uso de um “filtro de média” em associação. Com essa modificação denominou-se o descritor proposto como *Modified Median Local Mapped Pattern* (MM-LMP), com referência ao “código binário”. Para fins de avaliação de desempenho, a mesma matriz de pesos foi paralelamente utilizada no descritor LMP, tendo sido denominada esta variação como LMP2.

3.4 Considerações finais

Neste capítulo apresentou-se dois novos descritores de textura, o *Median Local Mapped Pattern* (Median-LMP) baseado no LMP e *Modified Median Local Mapped Pattern* (MM-LMP), uma variação do Median-LMP com referência ao LBP. Os métodos propostos foram desenvolvidos para a descrição de padrões da textura da íris, em específico para amostras de íris coletadas em ambiente não cooperativo, contendo variações no diâmetro da pupila e ruídos digitais.

Para fins de comparação de desempenho, é apresentada no próximo capítulo a metodologia desenvolvida para avaliação quantitativa dos descritores de textura propostos e os apresentados no capítulo anterior.

Material e Metodologia

4.1 Considerações iniciais

Os olhos fazem parte do conjunto de órgãos que dão o sentido à visão. Sua estrutura é bastante complexa, composta por inúmeras células, que agregam a função de transformar uma cena real (óptica) em impulsos nervosos. Os impulsos são transportados pelo nervo óptico até o cérebro, por meio de sinais eletroquímicos, que se encarrega de fazer a interpretação da cena (PAMPLONA, 2007).

Dentre as membranas existentes no sistema ocular, a íris possui característica circular e pigmentação colorida. Grande parte dessa membrana é composta por fibras musculares lisas, dispostas em diferentes sentidos. Um grupo dessas fibras possui círculos concêntricos próximos à pupila, denominado “*esfíncter da pupila*”. A contração das fibras do *esfíncter da pupila* determina *miose*, ou seja, diminuição do diâmetro da pupila, proporcionada por alta incidência de luz. O oposto acontece com o outro grupo de fibras musculares, que possuem formação radiada e compõem os músculos dilatadores, na qual a sua contração recebe o nome de *midríase*, ou seja, dilatação da pupila, proporcionada por baixa incidência de luz (FERRARI, 2008). A Figura 20 ilustra as ações proporcionadas pelas fibras presentes na íris, sendo que na Figura 20(a) tem-se a íris sob condições normais de iluminação, na Figura 20(b) sob iluminação intensa (*miose*) e Figura 20(c) sob pouca iluminação (*midríase*).

A retina é estimulada pela luz que atravessa a pupila (Figura 21(a)) por meio de células altamente sensíveis, os cones e bastonetes. A transmissão dos sinais é realizada pelo nervo óptico, que percorre pela região do quiasma óptico, conforme ilustra Figura 21(b). No quiasma óptico ocorre o cruzamento entre as fibras médias dos nervos ópticos, de maneira que as fibras do lado esquerdo se direcionem para o lado direito e vice-versa. Esta estruturação faz com que os estímulos aplicados a um dos olhos, sejam apresentados da mesma forma ao olho oposto. Esta função fisiológica é definida pelo nome de “Reflexo consensual” (COSTA, 2010).

O Reflexo consensual é uma função responsável pela sincronização dos movimentos

Figura 20: Ilustração interna dos músculos da íris.

Fonte: (STANFIELD; GERMANN, 2006)

Figura 21: Sistema óptico central, cruzamento das fibras do nervo óptico no quiasma.

Fonte: Adaptado de (BEAR; PARADISO, 2002)

proporcionados pelos olhos. Sendo assim, o comportamento das fibras musculares da íris funcionam de forma síncrona, ou seja, se houver dilatação ou contração no olho esquerdo, o mesmo movimento se repetirá no olho direito (COSTA, 2010).

Neste trabalho, como já mencionado, é proposto investigar a influência do tamanho da pupila na textura da íris. Para esta finalidade, foi utilizada a base de dados LAVI Iris Video DB2 ¹ desenvolvida pelo Laboratório de Visão Computacional (LAVI-USP) e, a partir dela foram selecionados *frames* de vídeo com a pupila dilatada e contraída. Para avaliar este cenário foi desenvolvida uma metodologia para comparação das amostras utilizando os descritores de textura local. As próximas seções detalham todo material utilizado para realização dos experimentos e a metodologia abordada.

¹<http://imagem.sel.eesc.usp.br/iris/>

4.2 Bases de dados

4.2.1 Base de dados LAVI Iris Video DB2

A base de dados LAVI Iris Video DB2 foi desenvolvida com base no Reflexo consensual, conforme utilizado na metodologia proposta por Costa (2010). O dispositivo ilustrado na Figura 22, captura uma sequência de vídeo da região da íris por um tempo determinado pelo administrador. O olho esquerdo recebe estímulos luminosos visíveis (luz branca), em intervalos de tempo específicos controlados por computador, enquanto a imagem do olho direito é capturada e digitalizada em uma sequência de vídeo sob iluminação *near infrared* (NIR). Os dois lados do dispositivo relacionado com o olho esquerdo e direito são opticamente isolados um do outro.

Figura 22: Estrutura do dispositivo proposto para aquisição de amostras da íris

A sequência de vídeo obtido sob iluminação NIR é sincronizada com os pulsos “luz visível” (um LED branco foi empregado) aplicada ao outro olho. Assim, é possível extrair as características dos quadros durante a contração da pupila ou dilatação sem a interferência de reflexos de luz a partir da íris, pupila e esclera. Seus movimentos são induzidos pelo estímulo de luz aplicada ao outro olho e, devido ao reflexo consensual, repetido pelo olho cuja imagem está sendo digitalizada sem a interferência de reflexos de luz visíveis.

O dispositivo foi construído a partir de duas câmeras multi-espectrais, sensível à radiação infravermelho - ADG-080GE, cuja especificações são apresentadas na Tabela 1.

Tabela 1: Especificações da câmera utilizada no protótipo desenvolvido

Descrição	Especificação
Fabricante:	JAI
Modelo:	ADG-080GE
Família:	JAI C3
Canais CCD:	1 (banda colorida) e 1(banda infravermelha)
Nº frames:	30 fps
Taxa de Renovação:	85 fps
Resolução da câmera:	1024 × 768 <i>pixels</i>
Tamanho do pixel:	4,65mm
Sistema de cor na banda visível:	RGB 24-bit/30-bit ou 10-bit/8-bit
Sistema de cor em modo infravermelho:	12-bit/10-bit/8-bit

A base de dados LAVI Iris Video DB2 é composta por sequências de vídeos de imagens de íris de olhos do lado direito, uma vez que os olhos esquerdos foram estimulados por pulsação de luz branca. Para a formação da base, participaram 53 usuários (classes) com idade entre 19 e 59 anos, de ambos os sexos, dispostas por 2 até 4 sequências de vídeo por classe, totalizando 166 sequências. As amostras foram coletadas de forma aleatória, algumas no mesmo dia, outras em dias diferentes. No momento em que o usuário posiciona seus olhos no protótipo, ocorre *midríase*, pois no local posicionado há ausência de luz, o que faz com que a pupila se dilate (Figura 23(a),(c),(e)). Os estímulos à íris são proporcionados pela luz branca e acontecem no olho esquerdo, em intervalos definidos de forma previamente estabelecida pelo software de aquisição. Neste momento, ocorre *miose* (Figura 23(b),(d)) até que o intervalo estabelecido seja cumprido, de forma que a pupila se mantenha contraída durante este processo. Dessa maneira, após os estímulos volta a ocorrer *midríase* e vice-versa, fazendo com que a sequência de vídeo seja constituída por vários *frames* da íris com a pupila dilatada e outros *frames* com a pupila contraída. A Figura 24 ilustra uma pessoa sob o processo de digitalização da imagem da íris.

Figura 23: Estímulos de luz durante o processo de aquisição das amostras por sequência de vídeo.

Figura 24: Procedimento de digitalização da sequência de vídeo

Fonte: (DB2, 2014)

O procedimento adotado simula, em ambiente controlado e cooperativo, a ocorrência de fatos que se apresentam em ambiente não cooperativo, ou seja, as contrações e dilatações da pupila mediante os pulsos de luz branca representam a ação do olho quando em iluminação não controlada. Os intervalos entre os estímulos de luz podem ser modificados por parâmetros pré-estabelecidos no software operacional. Cada amostra de vídeo foi coletada com duração de 1 minuto e 7 segundos, e os estímulos proporcionados pela luz branca foram estabelecidos em intervalos distintos, conforme ilustra a Figura 23.

No primeiro intervalo (Figura 23(a)) a luz branca foi desativada por 18 segundos, obtendo-se 280 *frames* com a pupila dilatada. O próximo intervalo (Figura 23(b)) tem duração de 10 segundos com exposição da luz branca, em que foram obtidos 210 *frames* com a pupila contraída. O terceiro intervalo (Figura 23(c)) com duração de 20 segundos foi realizado com a ausência de luz branca, obtendo-se 242 *frames* com a pupila dilatada. No próximo intervalo (Figura 23(d)) a luz branca é novamente ativada por 10 segundos, adquirindo-se 178 *frames* com a pupila contraída. Por último, é desativada a luz branca por 9 segundos resultando em 90 *frames* com a pupila dilatada. A descrição completa da base de dados LAVI Iris Video DB2 é apresentada no Apêndice A.

As sequências de vídeo podem apresentar *frames* contendo características inadequadas para etapa de classificação. Diferente das imagens estáticas, que são capturadas em fração de segundo, as sequências de vídeo demandam um tempo maior de captura, o que gera um desconforto por parte do usuário. Além disso, os estímulos proporcionados pela luz branca podem em um primeiro momento causar reações adversas ao usuário, como por exemplo piscar ou fechar completamente os olhos. Em suma, os erros que podem ser apresentados em um *frame* para ser considerado inadequado podem ser observados na Figura 25.

Depois de analisar as sequências de vídeo da base de dados LAVI Iris Video DB2, foram descartados todos os vídeos apresentando estes erros. Para realização desta tarefa, foi criada uma rotina em Matlab para extrair os *frames* de cada sequência de vídeo. Os *frames* apresentando erros conforme a Figura 25(a), foram descartados do teste manualmente, calculando-se os histogramas e verificando a distribuição dos *bins*, e os demais erros foram observados visualmente. Assim, utilizou-se o vídeo de 36 classes (usuários), incluindo 1 sequência de vídeo por classe e, a partir deles, foram selecionados 50 *frames* durante o tempo de contração e 50 *frames* durante o tempo de dilatação, totalizando 3.600 amostras de íris.

Para a seleção das amostras de íris com a pupila dilatada utilizou-se o seguinte critério: 20 amostras do período (a); 20 amostras do período (c) e 10 amostras do período (e), conforme ilustrado na Figura 23. Das amostras com a pupila contraída, foram selecionadas 25 amostras do período (b) e 25 do período (d), conforme apresentado na Figura 23. A relação das amostras selecionadas pode ser visualizada com mais detalhes no Apêndice A.

(a) Amostras sem focalização e contraste

(b) Amostras com reflexo do LED na textura

(c) Amostras com oclusões de pálpebras e cílios

(d) Amostras com erros de segmentação

Figura 25: Amostras da base de dados LAVI Iris Video DB2 apresentando erros.

4.2.2 Base de dados CASIA-Iris V2

A CASIA-Iris V2 é fornecida pelo Instituto de Automação da Academia de Ciências Chinesa. Ela inclui dois subconjuntos capturados com dois dispositivos diferentes: Irisspass-h desenvolvido pela OKI e chamado de “dispositivo 1”, e o CASIA-IrisCamV2 desenvolvido por eles mesmos chamado de “dispositivo 2”. Ambos os subconjuntos incluem um pacote com 1200 imagens digitalizadas na banda infravermelha. Cada subconjunto está dividido em 60 classes diferentes com resolução espacial de 640×480 *pixels*, no formato BMP, e foram capturados em curta distância (DATABASE, 2004).

Apesar desta base de dados não ter sido formada especificamente para análise da textura sob variação do tamanho da pupila, parte do subconjunto selecionado para os experimentos tem essas características. O subconjunto selecionado é formado por 600 imagens, divididos em 60 classes, contendo 10 amostras por classe. A Figura 26 apresenta duas amostras de íris do CASIA-IrisCAM V2 com diferentes tamanhos da pupila e, a relação de amostras selecionadas é apresentada no Anexo A.

(a) Amostra com a pupila contraída (arquivo 0018_015.bmp)

(b) Amostra com a pupila dilatada (arquivo 0018_009.bmp)

Figura 26: Exemplo de duas imagens de íris do “dispositivo 2” da base de dados CASIA-Iris V2.

4.2.3 Base de dados ND-Iris-Template-Aging-2008–2010

A base de dados Notre Dame ND-Iris-Template-Aging-2008–2010 foi obtida por meio do dispositivo LG4000, que se trata de um sensor comercial licenciado pela IrisAccess (IRISACCESS, 2011), capaz de capturar imagens de íris de ambos os lados. As imagens foram adquiridas com iluminação infravermelha, possuem resolução espacial de 640×480 *pixels* e estão disponíveis no formato TIFF. O conjunto de amostras é formado por 11.776 imagens de íris, divididas em 3 sessões, na qual cada sessão foi adquirida em anos diferentes: 2008, 2009 e 2010. No ano de 2008 foram coletadas amostras de 88 usuários, já no ano de 2009 foram utilizados 157 pessoas e, no ano de 2010 utilizou-se apenas 40 usuários. Durante os 3 anos do desenvolvimento da base de dados, foram utilizados os mesmos usuários para a coleta das amostras, isso permite estudos relacionados à mudanças na característica da íris ao longo do tempo (FENKER; BOWYER, 2012).

Para a realização dos experimentos, foram selecionadas 780 imagens, obtendo-se 130 classes, divididas em 6 amostras por classe. A partir de cada classe, selecionou-se 3 amostras da sessão de 2008 e 3 de 2009, sendo consideradas apenas as íris do lado esquerdo. Apesar desta base de dados ter sido desenvolvida de maneira cooperativa, foram obtidas 54 amostras de 9 classes com variação no diâmetro pupilar. No Anexo B é apresentada a relação completa das imagens selecionadas e, na Figura 27 são ilustradas duas amostras de mesma classe com diferentes tamanhos de pupila.

4.2.4 Base de dados UBIRIS V1

A base de dados UBIRIS V1 é composta por 1877 imagens coletadas de 241 pessoas em duas sessões distintas, adquiridas com iluminação visível. Sua principal característica é a incorporação de imagens com vários fatores de ruído anatômico, permitindo assim a avaliação dos métodos de reconhecimento de íris. Além disso, outra característica que

(a) Amostra com a pupila dilatada (arquivo 05176d740.tiff)

(b) Amostra com a pupila contraída (arquivo 05176d352.tiff)

Figura 27: Exemplo de duas imagens da base de dados Notre Dame ND-Iris-Template-Aging-2008–2010.

pode ser explorada em pesquisas nesta base de dados é a cor ou pigmentação da íris, já que as amostras foram digitalizadas na banda visível (RADU, 2013). As imagens possuem resolução espacial de 800×600 *pixels*, em formato JPG, e foram adquiridas a uma distância de 20 centímetros da câmera (PROENÇA; ALEXANDRE, 2005).

Para realização dos experimentos foram selecionadas 720 imagens do grupo “Sessão 1”, obtendo-se 144 classes, divididas em 5 amostras por classe. Devido as imagens terem sido adquiridas em modo cooperativo e sob iluminação controlada, poucas amostras continham variações no diâmetro da pupila, sendo selecionadas apenas 5 classes com essas características, conforme o exemplo ilustrado na Figura 28. A relação completa das amostras selecionadas é apresentada no Anexo C.

(a) Amostra com a pupila contraída (arquivo Img_74_1_4.jpg)

(b) Amostra com a pupila dilatada (arquivo Img_74_1_5.jpg)

Figura 28: Exemplo de duas amostras da base de dados UBIRIS V1.

4.2.5 Base de dados UBIRIS V2

A base de dados UBIRIS V2 foi adquirida de maneira não cooperativa utilizando 261 usuários, divididos em 522 classes de ambos os lados da íris, totalizando em 11.102 amos-

tras com resolução de 400×300 *pixels*. As amostras foram capturadas de forma estática, porém simulando um ambiente não cooperativo, a qual os usuários foram orientados a realizar movimentações da cabeça em diferentes ângulos. Levando-se em conta o cenário não cooperativo, essa simulação permite a obtenção de amostras com fatores de ruído mais próximas da realidade. Por este motivo, selecionou-se 882 imagens a partir do grupo “Sessão 1”, divididas em 147 classes, sendo 6 amostras por classe. Este subconjunto foi selecionado manualmente de modo a obter amostras com variação no tamanho na pupila. Um exemplo de duas amostras selecionadas é ilustrado na Figura 29 e, a relação completa das amostras selecionadas para os experimentos é apresentada no Anexo D.

Figura 29: Exemplo de duas amostras da base de dados UBIRIS V2.

4.2.6 Base de dados CASIA-Iris-Distance

A base de dados CASIA-Iris-Distance foi desenvolvida com foco em estudos biométricos multi-modais, ou seja, aqueles que utilizam de duas ou mais peculiaridades para se obter a identidade do usuário (DATABASE, 2011). Neste caso, a base de dados possui padrões de: face, pele e de íris. Isso é possível devido a captura de uma imagem do volume da face em alta resolução (2352×1728 *pixels*), por meio de um sistema de imagem multi-câmera (DONG; SUN; TAN, 2009). As amostras foram digitalizadas utilizando a iluminação infravermelha, obedecendo uma distância de 3 metros em relação ao dispositivo. A base de dados foi construída a partir de 142 usuários, formada por 284 classes (íris direita e esquerda), totalizando 2.567 amostras de íris. Em razão das amostras terem sido coletadas de maneira não cooperativa, foi observado que grande parte delas contém variações no diâmetro da pupila. A Figura 30 ilustra um exemplo de variação do tamanho da pupila em duas amostras da base de dados CASIA-Iris-Distance.

Como a base de dados é formada por imagens faciais, foi necessário criar uma metodologia para a localização dos olhos, antes do pré-processamento da íris. Existem diversas técnicas que podem ser empregadas para esta tarefa, entre elas o método de Viola e

(a) Amostra original da base de dados (arquivo S4023D00.jpg)

(b) Amostra original da base de dados (arquivo S4023D18.jpg)

(c) Região aproximada dos olhos com a pupila dilatada (arquivo S4023D00.jpg)

(d) Região aproximada dos olhos com a pupila contraída (arquivo S4023D18.jpg)

Figura 30: Exemplo de duas amostras da base de dados CASIA-Iris-Distance.

Jones (2004), que foi aprimorado por Lienhart e Maydt (2002), que adicionaram “Haar-like features” e Imagens Integrais diagonais, sendo esta versão utilizada neste trabalho. Para tal localização, foi utilizada a biblioteca de código aberto de visão computacional OpenCV para se obter a região dos olhos nas imagens (BRADSKI, 2000). A classe `CascadeClassifier` implementa um classificador de objetos em cascata de Haar e, foi utilizada em conjunto com o arquivo `haarcascade_eye.xml`, que fornece os pesos necessários para a localização do objeto. Neste trabalho utilizou-se os pesos originais previamente treinados pelo classificador, que está disponível na biblioteca. Dessa maneira, o classificador retorna a imagem de entrada com as regiões dos olhos esquerdo e direito contornadas, conforme exemplos apresentados na Figura 31.

A partir da localização obtida pelo classificador, apenas amostras de íris de olhos esquerdos foram selecionadas para realização dos experimentos. A utilização de um dos lados dos olhos é justificada pelo fato de que nas outras bases de dados é fornecida apenas essa configuração. Além disso, o uso de ambos os lados da íris não seria justo para fins de comparação, visto que este procedimento aumentaria o poder de discriminação em cada

Figura 31: Exemplos de amostras da base de dados CASIA-Iris-Distance com os olhos detectados pela biblioteca OpenCV.

classe. Sendo assim, um subconjunto de 710 imagens de íris com tamanhos diferentes de pupila foram selecionadas a partir da base dados, obtendo-se 142 classes e, 5 amostras por classe. A relação completa das amostras selecionadas é especificada no Anexo E.

4.3 Processamento de imagem e segmentação

Para avaliar os padrões de textura da íris sob os efeitos de dilatação e contração da pupila, um pré-processamento das imagens de cada base de dados foi realizado utilizando-se a técnica de normalização proposta por John Daugman, que foi implementada por Masek e Kovesi (2003). Esta tarefa foi executada com o auxílio da ferramenta MATLAB na versão 7.12.0 R2011a, sob o Sistema operacional Windows 8 64bits, configuração do processador i7-920 2.67GHz, memória RAM 4GB e placa de vídeo dedicada NVIDIA Geforce 210 1GB. Além disso, alguns parâmetros foram modificados no algoritmo de Masek e Kovesi (2003) para atender às necessidades do conjunto de amostras da base de dados utilizada, como estimativas do tamanho do raio da pupila e da íris. Estas definições foram importantes para se obter um melhor desempenho na etapa de segmentação das amostras de cada base de dados, minimizando os erros apresentados na Figura 25d. Os parâmetros definidos nesta etapa estão descritos em detalhes no Apêndice D.

As amostras da base de dados LAVI Iris Video DB2 possuem resolução espacial de 1024×768 *pixels*, quantizadas em 8 *bits*. Para diminuir o tempo de processamento na fase de segmentação as amostras foram redimensionadas para 512×384 *pixels* por meio da função *imresize* no MATLAB, com fator de redução de 0.5 utilizando o método “*nearest*”.

A partir das amostras normalizadas foram gerados cinco subgrupos com imagens em diferentes resoluções: 20×240 , 30×360 , 40×480 , 50×600 e 60×720 *pixels*, con-

forme é ilustrado na Figura 32. Para isso, foram modificados os parâmetros “*radial_res*” e “*angular_res*” no algoritmo de Masek e Kovesi (2003), o que transforma as coordenadas cartesianas da região de interesse (anel da íris) em coordenadas polares conforme a resolução especificada. Estes subgrupos foram gerados para se obter uma avaliação do desempenho dos descritores com texturas de íris em diferentes resoluções.

Figura 32: Conjuntos de amostras de íris normalizadas em diferentes resoluções.

Para avaliar a influência do tamanho da pupila no reconhecimento de íris foi criada uma metodologia para execução dos experimentos na base de dados LAVI Iris Video DB2. Assim, os experimentos foram organizados da seguinte forma:

- a) LAVI Subconjunto-1: Experimentos entre amostras com a pupila dilatada Figura 33(c) e 33(d).
- b) LAVI Subconjunto-2: Experimentos entre amostras com a pupila contraída Figura 33(a) e 33(b).
- c) LAVI Subconjunto-3: Experimentos entre amostras com a pupila dilata e contraída (base de dados completa) 33(e).

Figura 33: Metodologia abordada para comparação das amostras: (a) Amostras de íris com a pupila contraída, foram comparadas apenas com amostras de íris com a pupila contraída, (b) Amostras de íris com a pupila contraída, foram comparadas apenas com amostras de íris com a pupila dilatada, (c) Amostras de íris com a pupila dilatada, foram comparadas apenas com amostras de íris com a pupila dilatada, (d) Amostras de íris com a pupila dilatada, foram comparadas apenas com amostras de íris com a pupila contraída, (e) Amostras de íris com a pupila contraída foram comparadas com os dois subconjuntos (dilatadas e contraídas) e vice-versa.

Durante os experimentos foi detectada nas amostras normalizadas uma característica que possivelmente pudesse proporcionar perda de desempenho nos descritores avaliados. Essa característica está presente na maioria das amostras, refere-se a uma região da amostra com ruído anatômico, ocasionado pela oclusão de pálpebra e cílios. No método de Daugman, essas regiões são eliminadas no processo de comparação, fazendo discordância de pares de *bits* por meio da operação XOR. Isso ocorre porque a região contendo ruído anatômico é detectada antes da etapa de normalização, veja um exemplo na Figura 34(a). Dessa maneira, essa região passa a ser representada por um nível de cor (preto) na imagem normalizada, ou seja, uma região homogênea conforme apresentado na Figura 34(b).

(a) Regiões de pálpebras e cílios delimitadas

(b) Amostra (a) Após a etapa de normalização

Figura 34: Ilustração de uma amostra de íris com o ruído anatômico detectado pelo método de Daugman.

Ao aplicar os descritores de textura na amostra normalizada os valores que representam ruídos anatômicos estariam sendo agregados ao histograma com demais regiões contendo micro-padrões (reais), ocasionando em uma discrepância na comparação das amostras. Para resolver este problema, uma metodologia foi criada para descartar o ruído nos códigos de cada descritor. Para isso, foi desenvolvida uma função em Matlab para computar o histograma dos códigos, no qual se utilizou apenas as frequências dos níveis de cinza que estão fora da região delimitada pelo ruído.

Figura 35: Metodologia abordada para eliminação do ruído anatômico nos descritores de textura.

Uma ilustração da metodologia proposta é apresentada na Figura 35, sendo que na Figura 35(a) é obtido o código pelo descritor a partir da amostra normalizada e, computado o seu histograma na Figura 35(b) (esquerda). O ruído destacado em vermelho no código

da Figura 35(a) foi mapeado para o *bin* “0” do histograma, que pode ser visualizado de maneira ampliada no histograma da Figura 35(b) (direita). De maneira geral, para amostras que foram afetadas pelo ruído anatômico, em média 80% dos valores mapeados para o *bin* “0” representam o ruído anatômico e, apenas 20% deles são micro-padrões (reais). Sendo assim, após a aplicação da metodologia proposta na base de dados LAVI Iris Video DB2, foi obtido um aumento significativo na sensibilidade de cada subconjunto, que pode ser visualizado no Apêndice C. Partindo-se deste princípio, a metodologia foi abordada para todos os descritores de textura avaliados.

4.4 Extração das características e classificação da íris

O passo seguinte consiste em extrair as características da íris utilizando-se os descritores de textura. Além da abordagem proposta por Daugman, foram incluídos nos experimentos os descritores de textura: LBP, CLBP, MBP, WLD, LMP e, os descritores propostos neste trabalho: Median-LMP e MM-LMP. Vale ressaltar que, para “todas as bases de dados” a técnica de normalização foi aplicada para se obter os subgrupos de amostras normalizadas, conforme apresentado na Figura 32. Sendo assim, os descritores foram aplicados em cada um dos cinco subgrupos de amostras, gerando os histogramas correspondentes a partir da distribuição das frequências de níveis de cinza dos códigos de cada descritor. A partir do código, foi utilizada a distância qui-quadrado para se obter a similaridade entre as amostras, definida pela Equação 27.

$$X^2(A, M) = \frac{1}{2} \sum_{b=1}^B \frac{(A_b - M_b)^2}{(A_b + M_b)}, \quad (27)$$

na qual, A é a amostra de busca, M é a amostra armazenada na base, B é o número de posições dos histogramas de comparação, A_b é a frequência do nível de cinza de A , e M_b é a frequência do nível de cinza de M .

O método de amostragem validação cruzada *leave-one-out* foi utilizado para o treinamento e teste das amostras. Neste estimador é utilizado um conjunto de k amostras, na qual uma amostra é retirada para o teste e as demais $k - 1$ amostras são utilizadas para o treinamento. Este procedimento é realizado n vezes até que todo o conjunto seja completado. Como medida de desempenho foi calculada a Taxa de acerto ou Sensibilidade (S), definida pela Equação 28.

$$S = \frac{VP}{VP + FN}, \quad (28)$$

em que, (VP) corresponde ao número de Verdadeiros Positivos, ou o número de amostras corretamente classificadas, e (FN) o número de Falsos Negativos, ou as amostras erroneamente classificadas, para todas as amostras de consulta. Para exemplificar o processo de classificação considerando os descritores abordados, é ilustrado na Figura 36 um

diagrama com as etapas envolvidas. Para que o método de Daugman se encaixe neste diagrama é necessário trocar a medida de desempenho qui-quadrado pela distância de Hamming.

Figura 36: Fases do processo de classificação de amostras.

4.5 Metodologia para treinamento das amostras

Como descrito no capítulo anterior, o primeiro passo para aplicação dos descritores propostos Median-LMP, MM-LMP e dos descritores LMP e LMP2 é o treinamento do parâmetro da função de mapeamento. Em trabalhos publicados anteriormente utilizando o descritor LMP, a função de mapeamento “sigmóide” apresentou melhores resultados para diversos tipos de textura (FERRAZ; JUNIOR; GONZAGA, 2014) (NEGRI; GONZAGA, 2014) (FERRAZ et al., 2014). Partindo-se deste princípio, a mesma função foi utilizada neste trabalho, sendo necessário o ajuste da inclinação da curva sigmóide (β) e o número de *bins* do histograma (B) para cada descritor, conforme Equação 15 e Equação 17.

Para cada β é gerada a matriz de confusão das distâncias qui-quadrado, obtidas a partir da comparação entre as amostras. Os melhores valores para os parâmetros são alcançadas logo que a sensibilidade (S) (ver Equação 28) é máxima utilizando todas as amostras de textura do conjunto de treino, com validação cruzada *leave-one-out*. A sensibilidade S do sistema foi calculada a partir da diagonal principal da matriz de confusão.

Optou-se neste trabalho em escolher o número de *bins* $B = 256$ sem qualquer otimização. O parâmetro β foi sintonizado de maneira independente para cada base de dados, otimizando o seu valor por meio do algoritmo de Otimização por Enxame de Partículas (PSO) no intervalo de 0.4-2.4.

O PSO foi proposto por Kennedy e Eberhart (1995) para solucionar problemas de otimização, ou seja, encontrar a melhor solução para um determinado problema. Cada partícula é inicializada de maneira aleatória no espaço de busca e, também é atribuída uma velocidade para que elas possam se movimentar pelo espaço criando forças de atração. Assim, cada partícula armazena a melhor solução encontrada até aquele dado momento ($pbest$) e, a melhor solução encontrada até aquele momento levando-se em conta todas as partículas ($gbest$). A cada iteração os valores de $pbest$ e $gbest$ são atualizados até que o resultado desejado seja obtido ou, quando o número de iterações previamente definido no algoritmo for atingido.

Para sintonizar o parâmetro β na base de dados LAVI Iris Video DB2, selecionou-se 50 amostras por classe do Subconjunto-1, 10 amostras foram separadas para o treinamento e 40 amostras para teste/validação. O mesmo conceito foi adotado para o Subconjunto-2 e, a partir do Subconjunto-3 selecionou-se 10 amostras do Subconjunto-1 e 2 para treinamento, e 40 amostras do Subconjunto-1 e 2 para teste/validação. Já para as outras bases de dados o conjunto de treinamento/teste foi definido conforme a Tabela 2. A Tabela 3 apresenta os valores de β otimizado na sensibilidade máxima (S) obtida pelo descritor LMP, na Tabela 4 os valores obtidos pelo descritor LMP2, na Tabela 5 os valores obtidos pelo descritor proposto Median-LMP e, na Tabela 6 os valores obtidos pelo descritor proposto MM-LMP.

Tabela 2: Número de amostras de treinamento/teste utilizadas para a sintonização do β em cada base de dados.

Base de dados	nº de amostras por classe (treinamento)	nº de amostras por classe (teste/validação)
Notre Dame	2	4
CASIA-Iris V2	4	6
UBIRIS V1	2	3
CASIA-Iris-Distance	2	3
UBIRIS V2	2	4

Tabela 3: Parâmetros β para o LMP otimizados para cada base de dados.

Base de dados	nº amostras	Local Mapped Pattern				
		20×240	30×360	40×480	50×600	60×720
		β	β	β	β	β
LAVI	11900	0.4849	0.4933	0.4908	0.4903	0.4879
ND- Notre Dame	780	0.5352	0.5236	0.5466	0.5967	0.5630
UBIRIS V1	720	0.6738	0.7730	0.7513	0.5823	0.5931
CASIA-Iris V2	600	0.6808	0.5261	0.5734	0.5788	0.7817
CASIA-Iris-Distance	710	0.4522	0.4478	0.4888	0.5420	0.5593
UBIRIS V2	882	0.8655	0.8900	0.7054	0.8288	0,7674

Tabela 4: Parâmetros β para o LMP2 otimizados para cada base de dados.

Base de dados	nº amostras	Local Mapped Pattern 2				
		20×240	30×360	40×480	50×600	60×720
		β	β	β	β	β
LAVI	11900	0.4433	0.4169	0.4005	0.4335	0.4322
ND- Notre Dame	780	0.6229	0.6244	0.5880	0.5611	0.5099
UBIRIS V1	720	0.6880	0.6298	0.6621	0.5488	0.4840
CASIA-Iris V2	600	0.7023	0.6244	0.6577	0.5923	0.7044
CASIA-Iris-Distance	710	0.4055	0.4866	0.4622	0.4877	0.5144
UBIRIS V2	882	0.8223	0.8814	0.7879	0.8970	0,6914

Tabela 5: Parâmetros β para o Median-LMP otimizados para cada base de dados.

Base de dados	nº amostras	Median Local Mapped Pattern				
		20×240	30×360	40×480	50×600	60×720
		β	β	β	β	β
LAVI	11900	0.5082	0.5867	0.9653	0.8428	0.4022
ND- Notre Dame	780	0.6176	0.5235	0.6040	1.0762	1.1716
UBIRIS V1	720	0.4694	0.4754	0.4709	0.4418	0.4014
CASIA-Iris V2	600	0.6231	0.5119	0.5250	0.5680	0.6884
CASIA-Iris-Distance	710	0.6630	0.7322	0.6844	0.7134	0.6113
UBIRIS V2	882	0.6735	0.7790	0.5143	0.6768	0.5921

Tabela 6: Parâmetros β para o MM-LMP otimizados para cada base de dados.

Base de dados	nº amostras	Modified Median Local Mapped Pattern				
		20×240	30×360	40×480	50×600	60×720
		β	β	β	β	β
LAVI	11900	0.5465	0.5198	0.5614	0.5830	0.5766
ND- Notre Dame	780	0.5927	0.5580	0.5671	0.5926	0.5330
UBIRIS V1	720	0.5947	0.5466	0.5123	0.5877	0.5529
CASIA-Iris V2	600	0.5413	0.5273	0.5981	0.5723	0.5988
CASIA-Iris-Distance	710	0.6400	0.6308	0.6928	0.6120	0.6315
UBIRIS V2	882	0.7715	0.7166	0.7414	0.7546	0.7008

4.6 Considerações finais

Neste capítulo apresentou-se a metodologia proposta nesta tese para avaliação de descritores de textura em padrões de íris com pupilas dilatadas e contraídas. Além da base de dados LAVI Iris Video DB2, obtida no Laboratório de Visão Computacional (LAVI) da Universidade de São Paulo (USP), amostras de bases cooperativas como: CASIA-Iris V2, Notre Dame ND-Iris-Template-Aging-2008–2010, UBIRIS V1 e não cooperativas: UBIRIS V2 e CASIA-Iris-Distance, foram selecionadas para os experimentos. Após a seleção do material utilizado, observou-se um número menor de amostras com variação no diâmetro pupilar nas bases de dados cooperativa. Além disso, durante a fase de treinamento das amostras a partir dos descritores: Median-LMP, MM-LMP, LMP e LMP2, notou-se que, o parâmetro β não apresentou grande variação entre as bases de dados e os subgrupos analisados, sendo obtido valores entre o intervalo de 0.4-1.0. No próximo capítulo são mostrados os resultados experimentais que validam os descritores de textura propostos nesta tese.

Resultados e Discussão

Neste capítulo são apresentados os resultados obtidos pela aplicação dos descritores propostos em diferentes bases de dados, formadas por amostras de íris com a pupila dilatada e contraída.

Para avaliação dos descritores de textura Median-LMP e MM-LMP, foram realizados testes computacionais para se obter a sensibilidade e tempo de execução e, os resultados são comparados com o método de Daugman e os descritores de textura CLBP, MBP, WLD e LMP.

5.1 Considerações iniciais

Os resultados apresentados e discutidos nas próximas seções referem-se à sensibilidade, ou taxa de acertos obtidos a partir de cada base de dados utilizada. Em todas as tabelas, as células destacadas em cor “cinza escuro” representam o melhor resultado obtido para cada teste, e as células em cor “cinza claro” representam o segundo melhor resultado entre os métodos de comparação. Além da sensibilidade (S) foram avaliados também o tempo de execução e o desempenho de cada método baseado na curva DET. Para o tempo de execução foi levado em consideração o tempo de processamento “um-para-muitos” e o tempo de “um-para-um”, conforme descrito na Seção 2.6 do Capítulo 2 e, para reportar as curvas DET foram calculadas as taxas FAR e FRR, conforme apresentado na Seção 2.6 do Capítulo 2.

O tempo de execução foi medido desde a etapa de extração de características até a classificação das amostras. Por exemplo, o tempo de “um-para-um” é medido a partir da extração de características da amostra de busca, e da amostra alvo, seguido da classificação. Já o tempo de “um-para-muitos” é medido a partir da extração das características da amostra de busca, e seqüencialmente da classificação com todas as outras amostras da base de dados. Para se obter uma comparação entre o método de Daugman e os descritores de textura local, as etapas de localização, segmentação e normalização da es-

trutura da íris foram descartadas do cálculo, utilizando-se apenas as etapas de extração e classificação dos padrões.

É importante ressaltar que, além da resolução espacial das amostras, o tamanho do descritor associado com a complexidade do método é responsável por este tempo de execução. A principal vantagem do método “um-para-um” é a redução do custo computacional, possibilitando sua aplicação em sistemas que exijam menor tempo de resposta. Já o tempo “um-para-muitos” leva em consideração também o tamanho da base de dados. Ele foi utilizado nos experimentos para avaliar a complexidade dos descritores baseado numa busca seqüencial entre um conjunto de amostras.

Para comparação global entre os métodos avaliados, foram definidas neste trabalho duas “métricas não-absolutas”, denominadas como “eficiência” e “eficácia”. Essas métricas são normalmente utilizadas na área de economia e administração, mas exclusivamente neste trabalho foram propostas para se avaliar a relação entre a sensibilidade e o tempo de execução de cada método avaliado. De acordo com Sandroni (1996) o conceito de “eficiência” se resume em fazer as coisas da maneira certa. Neste caso ela foi utilizada como uma unidade de medida, a qual pode ser representada pela conversão dos recursos utilizados em resultados de forma mais econômica (MORAES, 2010). Sendo assim, a “eficiência” ($E1$) de cada método é calculada a partir da Equação 29:

$$E1 = \frac{S}{t_1}, \quad (29)$$

em que, S é a sensibilidade, e t_1 é o tempo de execução para comparação de uma amostra com outra da base “um-para-um”. Ou seja, a “eficiência” mede o desempenho alcançado por cada método para se extrair as características de uma amostra e compará-la com apenas uma amostra da base de dados.

A “eficácia” é a capacidade de produzir uma quantidade desejada do efeito desejado, ou de alcançar os objetivos (MORAES, 2010). Segundo Kirch (2008) “o que é eficiente não é necessariamente eficaz, e o que é eficaz não é necessariamente eficiente”. Dessa maneira, a “eficácia” ($E2$) de cada método é calculada a partir da Equação 30, na qual S corresponde à sensibilidade e, t_2 ao tempo de execução para comparação de uma amostra com todas da base “um-para-muitos”. Neste caso, a “eficácia” mede o desempenho alcançado por cada método para se extrair as características de uma amostra e compará-la com todas as amostras do conjunto.

$$E2 = \frac{S}{t_2} \quad (30)$$

Nesse sentido, a “eficácia” depende do tamanho do descritor (Tabela 7) e de como a base de dados é percorrida. Se a base de dados é indexada, ou seja, rotulada por pequenas características intrínsecas, como por exemplo: cor da íris, circularidade da pupila ou até mesmo o características dinâmicas da pupila (JARDINI, 2007) (COSTA, 2010), uma amostra semelhante pode ser encontrada rapidamente e o valor de eficácia irá mudar.

Na Tabela 7 são apresentados os tempos de execução de “um-para-um” de cada descritor utilizado, no qual o LMP original é o mais rápido entre todos, mas, os descritores propostos neste trabalho Median-LMP e MM-LMP atingiram o segundo lugar. Os tempos foram obtidos a partir da base de dados LAVI Iris Video DB2, utilizando o Subconjunto-3, definido no capítulo anterior.

Tabela 7: Tempo de execução “um-para-um” medido em milissegundos (ms) utilizando o Subconjunto-3.

Descritor de Textura	Tamanho do vetor ^b	Resolução espacial da amostra (<i>pixels</i>)				
		20 × 240	30 × 360	40 × 480	50 × 600	60 × 720
Daugman ^a	—	320	340	380	410	460
MBP	512	71	84	91	108	111
Median-LMP	256	64	74	70	76	83
MM-LMP	256	64	74	70	76	83
LMP	256	58	62	61	63	67
LMP2	256	58	62	61	63	67
WLD	256	110	200	320	480	670
CLBP_ $M_{8,1}^{u2}$	59	100	100	110	110	120
CLBP_ $S_{8,1}^{u2}$	59	100	110	110	120	130
CLBP_ $S/M/C_{8,1}^{u2}$	6962	321	323	329	342	355
CLBP_ $S/M/C_{8,1}^{u2}$	177	120	130	130	140	150
CLBP_ $S/M_{8,1}^{u2}$	3481	240	240	249	250	254
CLBP_ $M/C_{8,1}^{u2}$	118	97	100	100	110	120

^a O tamanho do vetor é indefinido para o método de Daugman porque ele não utiliza a distância Chi-quadrado, mas sim, a distância de Hamming. Originalmente o autor denota o tamanho do vetor em 2048 *bits* (256 bytes).

^b Tamanho dos vetores apresentada em (*bins*).

5.2 Resultados obtidos com as bases de dados

5.2.1 Resultados de desempenho para a base de dados LAVI Iris Video DB2

(a) Experimento-1

Esta base de dados possui 3600 imagens coletadas de 36 pessoas; 1800 imagens com pupilas dilatadas e 1800 imagens com pupilas contraídas. Neste primeiro experimento, as amostras dilatadas foram divididas em dois subgrupos de 900 imagens cada. Todas as 36 classes foram representadas nos dois subgrupos, no entanto, todas as imagens são distintas. A esta configuração foi dado o nome de LAVI Subconjunto-1 e, a comparação das amostras foi realizada da seguinte maneira: cada íris de um subgrupo foi comparada com todas as íris do outro subgrupo.

Descritor de textura	Resolução espacial da amostra (<i>pixels</i>)				
	20×240	30×360	40×480	50×600	60×720
Daugman	95.97	96.00	96.12	96.25	96.43
MBP	96.64	97.64	98.23	97.76	97.52
Median-LMP	95.44	97.00	97.89	97.73	98.13
MM-LMP	98.11	99.29	99.41	99.29	99.47
LMP	92.82	95.70	96.79	96.41	96.76
LMP2	92.00	95.20	96.13	96.05	96.22
WLD	89.41	92.88	96.94	99.70	99.82
CLBP_ $M_{8,1}^{u2}$	88.64	90.17	91.76	92.94	93.23
CLBP_ $S_{8,1}^{u2}$	91.05	90.41	88.29	84.47	81.82
CLBP_ $S/M/C_{8,1}^{u2}$	94.82	93.41	92.41	90.58	89.58
CLBP_ $S_M/C_{8,1}^{u2}$	93.76	92.58	92.41	91.00	90.47
CLBP_ $S/M_{8,1}^{u2}$	94.29	92.70	91.94	89.76	87.17
CLBP_ $M/C_{8,1}^{u2}$	95.11	94.88	96.00	95.82	96.17

Tabela 8: Sensibilidade (%) obtida com o Subconjunto-1 (dilatada vs dilatada)

(a) 20×240 pixels (b) 60×720 pixels

(c) Figura 37(a) ampliada

(d) Figura 37(b) ampliada

Figura 37: Curva DET para base de dados LAVI Subconjunto-1.

A taxa de classificação correta, conhecida como sensibilidade ou taxa de acerto é apresentada na Tabela 8. O descritor proposto neste trabalho MM-LMP supera o método de Daugman em 2,14% levando-se em consideração a resolução espacial das amostras em 20×240 *pixels*, 3,29% nas amostras em 30×360 e 40×480 *pixels*, e 3,04% nas amostras com resolução espacial de 50×600 e 60×720 *pixels*. As curvas DET ilustradas nas Figura 37(a) e Figura 37(b) foram geradas a partir das amostras de baixa resolução (20×240 *pixels*) e maior resolução (60×720 *pixels*) e, apresentam as legendas escritas em ordem do melhor para o pior método em cada resolução de amostra. É importante notar que na maior resolução espacial, o WLD apresentou o melhor desempenho, ou seja, o descritor precisa de “mais informações” ou “amostras de alta resolução”. Essa restrição faz com que o descritor gaste maior tempo de execução para extrair as características na imagem. Outra característica importante observada com o descritor MM-LMP é que o *Equal Error Rate* (EER) é quase a mesmo em ambas as resoluções comparadas.

(b) Experimento-2

No segundo experimento as outras 1800 amostras de íris com a pupila totalmente contraída foram divididas também em dois subgrupos de 900 imagens. Todas as 36 classes foram representadas nos dois subgrupos, mas, todas as imagens são distintas. A esta configuração foi dado o nome de LAVI Subconjunto-2 e, a comparação das amostras foi realizada da seguinte maneira: cada íris de um subgrupo foi comparada com todas as íris do outro subgrupo.

Descritor de textura	Resolução espacial da amostra (<i>pixels</i>)				
	20×240	30×360	40×480	50×600	60×720
Daugman	99.07	99.12	99.20	99.20	99.23
MBP	96.58	97.82	98.17	98.05	97.94
Median-LMP	96.04	97.76	97.49	97.66	98.02
MM-LMP	99.00	99.35	99.35	99.35	99.17
LMP	93.94	95.58	97.29	96.76	96.82
LMP2	91.48	92.30	92.78	91.20	91.70
WLD	90.41	93.76	96.58	98.52	99.35
CLBP_ $M_{8,1}^{u2}$	86.94	90.88	92.82	92.47	93.47
CLBP_ $S_{8,1}^{u2}$	91.64	91.64	90.29	87.11	83.52
CLBP_ $S/M/C_{8,1}^{u2}$	95.94	94.58	92.05	90.17	87.29
CLBP_ $S_M/C_{8,1}^{u2}$	94.82	93.76	93.17	91.64	88.17
CLBP_ $S/M_{8,1}^{u2}$	95.94	94.41	91.88	89.41	86.47
CLBP_ $M/C_{8,1}^{u2}$	94.64	95.76	95.70	95.64	95.58

Tabela 9: Sensibilidade (%) obtida com o Subconjunto-2 (contraída vs contraída)

A sensibilidade ou a taxa de acerto é apresentada na Tabela 9 e, as curvas DET para as amostras em 20×240 e 60×720 *pixels* são ilustradas nas Figura 38(a) e Figura 38(b).

O método do Daugman obteve o melhor desempenho em relação aos outros, levando-se em consideração as amostras com resolução espacial de 20×240 *pixels*, como recomendado pelo autor em seu trabalho (DAUGMAN, 1993). No entanto, o descritor proposto neste trabalho, o MM-LMP, supera o método de Daugman em 0,15% quando as amostras são segmentadas nas seguintes resoluções espaciais: 30×360 , 40×480 e 50×600 *pixels*. Um resultado importante sobre o MM-LMP é a baixa EER (< 0.01) na comparação entre as duas resoluções de amostras. E, mais uma vez, o descritor WLD alcançou o melhor desempenho com amostras em resolução espacial de 60×720 *pixels*.

(a) 20×240 *pixels* (b) 60×720 *pixels*

(c) Figura 38(a) ampliada

(d) Figura 38(b) ampliada

Figura 38: Curva DET para base de dados LAVI Subconjunto-2.

(c) Experimento-3

No terceiro experimento, foi utilizado o LAVI Subconjunto-3 que contém todas as 3600 imagens de íris das 36 pessoas. Por validação cruzada *leave-one-out* cada amostra de íris foi comparada com a base de dados completa ($n - 1$), considerando as amostras dos Subconjuntos-1 e 2.

Descritor de textura	Resolução espacial da amostra (<i>pixels</i>)				
	20×240	30×360	40×480	50×600	60×720
Daugman	93.23	93.41	93.88	94.00	94.12
MBP	96.02	97.47	98.02	97.64	97.50
Median-LMP	93.24	96.66	96.00	96.13	97.78
MM-LMP	98.05	99.02	99.26	99.17	99.17
LMP	90.52	94.44	95.79	95.88	96.08
LMP2	87.44	92.23	93.89	93.23	95.88
WLD	89.20	92.05	95.70	98.85	99.44
CLBP_ $M_{8,1}^{u2}$	83.88	88.08	90.32	91.29	92.14
CLBP_ $S_{8,1}^{u2}$	90.20	90.23	87.70	83.97	80.61
CLBP_ $S/M/C_{8,1}^{u2}$	95.38	93.85	92.35	90.55	88.67
CLBP_ $S_M/C_{8,1}^{u2}$	94.14	92.79	92.67	91.08	89.29
CLBP_ $S/M_{8,1}^{u2}$	95.00	93.20	91.73	89.23	86.32
CLBP_ $M/C_{8,1}^{u2}$	93.88	94.73	95.76	95.50	95.85

Tabela 10: Sensibilidade (%) obtida com o Subconjunto-3 (contraída vs dilatada)

(a) 20×240 pixels (b) 60×720 pixels

(c) Figura 39(a) ampliada

(d) Figura 39(b) ampliada

Figura 39: Curva DET para base de dados LAVI Subconjunto-3.

A partir dos resultados apresentados na Tabela 10 e nas Figuras 39(a) e 39(b) é possível afirmar que, o MM-LMP é o melhor descritor para classificação de textura de íris entre todos os métodos de comparação, superando todos os concorrentes nas quatro primeiras resoluções da amostra. Nota-se também que os desempenhos globais de cada método nas amostras em 20×240 *pixels* foram afetados, apresentando EER (> 0.01). No entanto, quando se utilizou amostras de maior resolução (60×720 *pixels*) os descritores MM-LMP e WLD atingiram EER abaixo de 0.1, demonstrando ser mais robustos.

Com base nos apresentados é possível afirmar que, a deformação da íris causada pela dilatação e contração da pupila afeta diretamente no desempenho do sistema. Observando separadamente o desempenho do método de Daugman nos 3 experimentos realizados (Figura 40), fica claro que a melhor precisão obtida foi com o Experimento-2 (pupilas somente contraídas), com $EER = 0.009$. Os piores resultados foram obtidos com os Experimento-1 e 3, com $EER = 0.034$ e $EER = 0.052$ respectivamente, o que comprova a hipótese deste trabalho. Isso ocorreu porque, as distribuições de probabilidade entre as amostras genuínas (intra-classe) e impostoras (inter-classe) apresentam-se intersectadas nas Figuras 41(a) e 41(b), o que implica em maiores números de falsos positivos (FAR) e falsos negativos (FRR). Ao contrário, na Figura 41(c), as distribuições de similaridades estão bem separadas, favorecendo a obtenção de erros menores.

Figura 40: Curva DET para o método de Daugman utilizando amostras de 20×240 *pixels*.

Figura 41: Distribuição das amostras Intra-classe x Inter-classe referente ao método de Daugman.

Embora a sensibilidade seja uma métrica importante para a avaliação de sistemas biométricos, o tempo gasto pelo usuário para realizar uma operação deve ser levado em consideração. Neste sentido, foi medido o tempo de execução “um-para-muitos” de cada descritor com base no Subconjunto-3 (3600 imagens). A Figura 42 apresenta o tempo necessário (minutos) para encontrar uma amostra de consulta na base de dados por meio da busca seqüencial. Nota-se que os descritores propostos neste trabalho Median-LMP e MM-LMP estão entre os mais rápidos. Apesar da alta sensibilidade alcançada pelo WLD na resolução de 60×720 pixels (99,44%), o tempo para encontrar uma amostra similar dentro do banco de dados também é alto (> 20 minutos), enquanto o MM-LMP gasta menos tempo para executar a mesma tarefa (< 2 minutos). Entre todos os métodos avaliados o CLBP_S/M/C foi o que apresentou o maior tempo de execução (> 39 minutos), seguido pelo WLD (> 20 minutos) e Daugman (> 7 minutos).

Para complementar a avaliação da base de dados LAVI Iris Video DB2, os descritores de textura circulares, tais como: LBP^{ri} , LBP^{riu2} e sLMP, foram também avaliados (SOUZA; VIEIRA; GONZAGA, 2015). Os resultados são apresentados no Apêndice D e, a partir deles é possível notar que tais descritores apresentaram baixa sensibilidade em relação aos métodos avaliados anteriormente. O baixo desempenho obtido por estes métodos está associado à utilização de amostras com resolução espacial pequena, no entanto, quando são aplicados em maior resolução (60×720 pixels) são obtidos bons resultados. Devido a esta limitação, os descritores de textura circulares não foram incluídos nos próximos experimentos, permanecendo somente os descritores Median-LMP, MM-LMP, LMP, CLBP, MBP, WLD e o método de Daugman.

Nas próximas seções, são discutidos os resultados obtidos com a aplicação dos descritores em mais cinco base de dados, sendo duas delas formadas por imagens não cooperativas (UBIRIS V2 e CASIA-Iris-Distance), contendo um grande volume de amostras com variação no diâmetro da pupila. As demais bases de dados: UBIRIS V1, CASIA-Iris V2 e

Figura 42: Tempo de execução “um-para-muitos” para cada método utilizando a base de dados completa (LAVI Subconjunto-3).

ND-Iris-Template-Aging-2008–2010, são classificadas como bases de dados cooperativas, ou seja, adquiridas em curta distância e sob ambiente controlado, o que incluiu amostras com menor percentual de variação no diâmetro pupilar. Embora o objetivo deste trabalho seja avaliar a textura de íris sob variação do tamanho da pupila, as bases de dados cooperativas foram utilizadas para se obter uma avaliação do potencial dos descritores locais para texturas de íris.

5.2.2 Resultados de desempenho para a base de dados UBIRIS V1

Esta base de dados foi construída visando a investigação da robustez de algoritmos de segmentação/reconhecimento de íris com diferentes tipos de ruído. Devido as amostras terem sido coletadas em curta distância e sob iluminação controlada, não há amostras suficientes da mesma classe com pupilas dilatadas e contraídas. No entanto, é uma base de dados que emprega diversos tipos de ruído na textura, o que permite uma avaliação do potencial entre os métodos avaliados.

Avaliando o desempenho dos métodos por meio das curvas DET apresentadas na Figura 43, é possível observar que os descritores propostos Median-LMP e MM-LMP estão

entre o três melhores quando se utilizou amostras de menor resolução (Figura 43(a)). De maneira geral, quando se utilizou amostras com maior resolução espacial (Figura 43(b)) todos os métodos avaliados obtiveram menores EER, exceto o CLBP.

(a) 20×240 pixels (b) 60×720 pixels

(c) Figura 43(a) ampliada

(d) Figura 43(b) ampliada

Figura 43: Curva DET para base de dados UBIRIS V1.

Observando a Tabela 11, as melhores sensibilidades foram alcançadas pelo método de Daugman, com amostras em resolução de 20×240 , 30×360 , 40×480 e 50×600 pixels. No entanto o descritor MM-LMP foi o que apresentou melhor sensibilidade com amostras em resolução de 60×720 pixels, e obteve a segunda colocação nas demais resoluções espaciais.

Descritor de textura	Resolução espacial da amostra (<i>pixels</i>)				
	20×240	30×360	40×480	50×600	60×720
Daugman	96.31	96.36	96.43	96.51	96.98
MBP	79.24	80.26	81.28	82.30	83.32
Median-LMP	88.83	89.85	90.87	91.89	92.91
MM-LMP	93.55	94.57	95.59	96.13	97.15
LMP	78.81	79.83	80.85	81.87	82.89
LMP2	77.82	78.84	79.86	80.88	83.55
WLD	54.21	67.44	78.22	84.44	95.22
CLBP_ $M_{8,1}^{u2}$	36.86	45.75	40.67	41.94	40.67
CLBP_ $S_{8,1}^{u2}$	72.45	75.00	58.47	62.28	55.92
CLBP_ $S/M/C_{8,1}^{u2}$	82.62	73.73	76.26	76.26	62.28
CLBP_ $S_{-}M/C_{8,1}^{u2}$	82.62	64.83	63.56	71.18	62.28
CLBP_ $S/M_{8,1}^{u2}$	77.79	70.58	70.58	79.24	60.50
CLBP_ $M/C_{8,1}^{u2}$	66.27	67.71	63.38	66.27	63.38

Tabela 11: Sensibilidade (%) obtida pela comparação de todas as amostras da base de dados UBIRIS V1.

Figura 44: Tempo de execução “um-para-muitos” para cada método utilizando a base de dados completa (UBIRIS V1).

Os “tempos de execução” apresentados na Figura 44, apontam o MM-LMP entre os métodos que consome menor tempo ao pesquisar uma amostra dentro da base de dados

completa (<7 segundos). Embora o método de Daugman tenha alcançado as melhores sensibilidades na maioria dos experimentos, o tempo necessário para encontrar uma amostra similar dentro do banco de dados também é alto (> 1 minuto). Além do método de Daugman, os tempos do WLD (>13 segundos) e CLBP (> 2 minutos) estão entre os três métodos que mais consomem tempo para pesquisar uma amostra dentro da base de dados completa.

5.2.3 Resultados de desempenho para a base de dados CASIA-Iris V2

A base de dados CASIA-Iris V2 foi desenvolvida a partir de câmeras com iluminação *Near Infrared* (NIR) e, a coleta das amostras foram realizadas sob ambiente controlado. A principal característica desta base de dados é a formação de imagens por meio de dispositivos portáteis, tais como: CASIA-IrisCamV2 e Irispass-h. Não são esperados nesta base de dados amostras com diferentes diâmetros pupilares, pois trata-se de uma base de dados cooperativa. No entanto, parte do subconjunto selecionado para os experimentos possui essa característica.

Mais uma vez, o método de Daugman apresentou a melhor taxa de classificação para todos os subgrupos, exceto com o tamanho de amostra em 60×720 *pixels*, na qual o descritor proposto MM-LMP alcançou o melhor sensibilidade, como pode ser visto na Tabela 12. Além disso, o MM-LMP obteve a segunda melhor taxa de classificação para as resoluções espaciais 30×360 , 40×480 e 50×600 *pixels*.

Descritor de textura	Resolução espacial da amostra (<i>pixels</i>)				
	20×240	30×360	40×480	50×600	60×720
Daugman	98.13	98.20	98.23	98.37	98.56
MBP	78.16	81.50	87.05	87.05	92.61
Median-LMP	66.62	79.83	79.27	85.79	89.62
MM-LMP	86.16	89.14	92.22	95.32	99.44
LMP	69.65	80.77	74.10	82.76	91.88
LMP2	66.25	74.99	69.21	73.17	81.66
WLD	55.21	60.23	71.88	80.85	95.21
CLBP_ $M_{8,1}^{u2}$	81.88	60.77	85.10	71.89	81.87
CLBP_ $S_{8,1}^{u2}$	92.99	61.88	81.44	86.09	93.07
CLBP_ $S/M/C_{8,1}^{u2}$	87.43	64.10	79.99	75.65	87.07
CLBP_ $S_M/C_{8,1}^{u2}$	75.21	60.77	64.77	72.76	75.43
CLBP_ $S/M_{8,1}^{u2}$	70.77	58.54	79.75	60.77	71.77
CLBP_ $M/C_{8,1}^{u2}$	78.54	76.32	90.03	77.65	78.07

Tabela 12: Sensibilidade (%) obtida pela comparação de todas as amostras da base de dados CASIA-Iris V2.

Outra característica observada na Figura 45(a), foi que o descritor $CLBP_{8,1}^{u2}$ obteve o segundo melhor desempenho quando se utilizou amostras com resolução espacial de 20×240 pixels, superando o MM-LMP que atingiu a terceira colocação. Observando a curva DET apresentada na Figura 45(b) é possível notar que todos os métodos avaliados obtiveram menores percentuais de EER comparados com os que foram obtidos na Figura 45(a), podendo destacar o descrito MM-LMP e o método de Daugman com EER (< 0.01). Novamente, o método de Daugman e os descritores CLBP e WLD apresentaram o maior tempo de execução, veja Figura 46, sendo considerados os mais lentos para se pesquisar uma amostra dentro da base de dados completa. Ao contrário, o descritor proposto MM-LMP apresenta-se como um dos mais rápidos entre todos os métodos comparados.

(a) 20×240 pixels (b) 60×720 pixels

(c) Figura 45(a) ampliada

(d) Figura 45(b) ampliada

Figura 45: Curva DET para base de dados CASIA-Iris V2.

Figura 46: Tempo de execução “um-para-muitos” para cada método utilizando a base de dados completa (CASIA-Iris V2).

5.2.4 Resultados de desempenho para a base de dados ND-Iris-Template-Aging-2008–2010

A base de dados ND-Iris-Template-Aging-2008–2010 foi desenvolvida pelo Laboratório de Pesquisa de Visão de Computacional da Universidade de Notre Dame. Esta base de dados foi adquirida em um ambiente controlado por equipamento específico de reconhecimento de íris, o Iris Access LG4000. Uma das características principais deste conjunto de dados é a formação de amostras em períodos diferentes, ou seja, ao longo de três anos foram coletadas amostras do mesmo usuário, visando a investigação da mutação das características da íris.

Como as amostras de íris foram coletadas sob iluminação constante e com distância fixa entre o olho e o dispositivo, observou-se um conjunto reduzido de amostras com diâmetros diferentes da pupila da mesma pessoa. Além disso, esta base de dados contém amostras de boa qualidade e com baixo níveis de ruído. O método de Daugman alcançou as melhores sensibilidades em todas as resoluções espaciais (veja Tabela 13) e, manteve o percentual EER (< 0.02), conforme os resultados apresentados nos gráficos das Figuras 47(a) e 47(b).

Descritor de textura	Resolução espacial da amostra (<i>pixels</i>)				
	20×240	30×360	40×480	50×600	60×720
Daugman	99.13	99.22	99.28	99.33	99.41
MBP	77.66	81.22	84.33	85.44	92.66
Median-LMP	86.44	89.33	89.77	89.95	90.14
MM-LMP	91.55	93.66	94.23	95.32	98.77
LMP	83.24	84.44	86.25	86.88	88.14
LMP2	84.33	84.14	85.22	86.66	88.94
WLD	74.06	75.26	81.44	90.23	99.04
CLBP_ $M_{8,1}^{u2}$	82.33	81.22	85.55	82.34	82.32
CLBP_ $S_{8,1}^{u2}$	90.44	86.33	86.45	87.54	94.52
CLBP_ $S/M/C_{8,1}^{u2}$	87.88	88.55	88.44	86.10	87.52
CLBP_ $S_M/C_{8,1}^{u2}$	85.66	81.22	85.22	86.21	85.88
CLBP_ $S/M_{8,1}^{u2}$	81.22	88.99	89.20	90.22	82.22
CLBP_ $M/C_{8,1}^{u2}$	88.99	86.77	90.45	89.17	88.52

Tabela 13: Sensibilidade (%) obtida pela comparação de todas as amostras da base de dados ND-Iris-Template-Aging-2008–2010.

Figura 47: Curva DET para base de dados ND-Iris-Template-Aging-2008–2010.

Por outro lado, o descritor proposto MM-LMP obteve o segundo melhor desempenho, para as amostras com as seguintes resoluções espaciais: 20×240 , 30×360 , 40×480 e 50×600 *pixels*. Já o descritor WLD atingiu a segunda melhor taxa de acerto com amostras na resolução espacial 60×720 *pixels*, sendo superior apenas em 0.27% em relação ao MM-LMP. É importante notar também que, alguns operadores CLBP atingiram ótimos resultados com essa base de dados, obtendo a terceira melhor sensibilidade com amostras em resolução espacial de 20×240 *pixels*, conforme ilustrado na Figura 47(a).

Como observado nos resultados, este foi o melhor desempenho obtido pelo método de Daugman com as bases de dados cooperativas. Não obstante, é importante observar que os tempos de execução de “um-para-muitos” apresentados na Figura 48 para o método de Daugman, é um dos mais altos (> 1 minuto), sendo inferior somente ao CLBP_ $S/M/C_{8,1}^{u2}$ (> 2 minutos). Nota-se também que, o descritor WLD, apesar do seu ótimo desempenho alcançado com amostras em resolução espacial de 60×720 *pixels* (99.04%), encontra-se também nesta estatística (> 1 minuto), mostrando-se lento para a busca de uma amostra dentro da base de dados completa. De maneira oposta, os tempos de execução dos descritores Median-LMP e MM-LMP estão abaixo de 6 segundos, o que os classifica entre os mais rápidos com base em todos os descritores comparados.

Figura 48: Tempo de execução “um-para-muitos” para cada método utilizando a base de dados completa (ND-Iris-Template-Aging-2008–2010).

5.2.5 Resultados de desempenho para a base de dados UBIRIS V2

A base de dados UBIRIS V2 foi desenvolvida para avaliar a viabilidade do reconhecimento de íris em um ambiente mais próximo aos sistemas não cooperativos. Para isso, foram obtidas imagens utilizando a banda visível e sem a cooperação efetiva dos usuários. Uma câmera foi posicionada cerca de 4 a 8 metros de distância do usuário para capturar imagens da região periocular, mantendo-se o foco da câmera para cada um dos olhos. O processo de aquisição das amostras foi realizado em duas etapas, sendo que, em cada uma delas houve variação da distância e intensidade diferente de luz artificial. Devido a este cenário, é encontrado nesta base de dados um grande volume de amostras com diferentes tamanhos de pupilas, proporcionando assim, uma configuração similar ao LAVI Subconjunto-3, da base de dados LAVI Iris Video DB2.

Figura 49: Curva DET para base de dados UBIRIS V2.

Analisando os dados apresentados pelos gráficos na Figura 49, considerando amostras de baixa resolução (Figura 49(a)), a menor EER foi alcançada pelo descritor MM-LMP ($<$

0.04). Além disso, o mesmo descritor apresentou superioridade em relação aos métodos comparados nas seguintes resoluções espaciais: 30×360 , 40×480 e 50×600 *pixels*. A melhor sensibilidade na resolução mais alta (Figura 49(b)) foi atingida pelo descritor WLD e, o MM-LMP alcançou o segundo lugar. Nota-se também que, o método de Daugman não alcançou bons resultados com esta base de dados. Apesar de uma redução de desempenho de todos os métodos comparados, usando esta base de dados, os descritores propostos Median-LMP e MM-LMP atingiram as melhores sensibilidades (veja Tabela 14), apresentando-se promissores para amostras de íris com variação do tamanho da pupila em ambientes realmente não cooperativos.

Descritor de textura	Resolução espacial da amostra (<i>pixels</i>)				
	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	55.80	60.32	61.77	64.88	68.21
MM-LMP	60.18	66.22	68.63	72.33	75.88
LMP	47,71	52,16	53,28	54,75	59,27
LMP2	46,38	49,80	51,64	53,94	56,70
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

Tabela 14: Sensibilidade (%) obtida pela comparação de todas as amostras da base de dados UBIRIS V2.

Outra característica importante observada no gráfico da Figura 50, é que os descritores propostos tem apresentado os menores tempos de execução para busca de uma amostra dentro da base de dados completa (< 10 segundos). Apesar do ótimo desempenho do WLD com amostras de resolução mais alta, o tempo para comparação de “um-para-muitos” é também alto (> 1 minuto). É importante ressaltar também que, além do WLD os descritores CLBP_ $S/M/C_{8,1}^{u2}$, CLBP_ $S/M_{8,1}^{u2}$ e o método Daugman, lideram entre os tempos mais altos para a comparação de “um-para-muitos”.

Figura 50: Tempo de execução “um-para-muitos” para cada método utilizando a base de dados completa (UBIRIS V2).

5.2.6 Resultados de desempenho para 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. Todas as imagens na base de dados foram capturadas a uma distância de ~ 3 metros da câmera, e cada uma delas contém a região frontal da face. Por meio da metodologia proposta no capítulo anterior, foi realizado um pré-processamento nas imagens para se obter a localização da região de interesse (íris), antes da extração e codificação das características.

A partir dos resultados apresentados na Tabela 15, nota-se que as melhores taxas de acerto foram obtidas por meio dos descritores propostos Median-LMP e MM-LMP, até o tamanho de amostras em 50×600 pixels. Quando a amostra tem resolução espacial de 60×720 pixels, o descritor WLD supera o MM-LMP em apenas 1.11%. Os gráficos apresentados na Figura 51 apontam o baixo desempenho do método de Daugman com esta base de dados, alcançando apenas o terceiro lugar (Figura 51(a)). Embora o desempenho de cada método comparado tenha sido baixo com esta base de dados, as menores EER foram obtidas com o descritor MM-LMP, considerando EER (< 0.04) para a resolução mais baixa (Figura 51(a)) e, (< 0.03) para resolução mais alta (Figura 51(b)).

Descritor de textura	Resolução espacial da amostra (<i>pixels</i>)				
	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	69.33	72.14	77.55	80.33	82.77
MM-LMP	74.08	77.50	81.20	84.55	88.77
LMP	58,73	61,25	64,99	66,04	70,25
LMP2	56,99	60,98	63,99	64,73	69,75
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

Tabela 15: Sensibilidade (%) obtida pela comparação de todas as amostras da base de dados CASIA-Iris-Distance.

(a) 20×240 pixels

(b) 60×720 pixels

(c) Figura 51(a) ampliada

(d) Figura 51(b) ampliada

Figura 51: Curva DET para base de dados CASIA-Iris-Distance.

Os tempos de execução de “um-para-muitos” foram medidos também neste experimento, Figura 52. Novamente, os descritores que consomem o maior tempo para comparação de uma amostra de busca com a base de dados completa são $CLBP_S/M/C_{8,1}^{u,2}$ e $CLBP_S/M_{8,1}^{u,2}$. Seguindo dos descritores CLBP, o método de Daugman e o WLD são os que mais consomem tempo de processamento. Os menores tempos de execução foram obtidos com os descritores baseado na abordagem LMP, incluindo os descritores propostos neste trabalho.

Figura 52: Tempo de execução “um-para-muitos” para cada método utilizando a base de dados completa (CASIA-Iris-Distance).

5.3 Resultados de “eficiência” e “eficácia”

Com o objetivo de avaliar o desempenho global de cada algoritmo comparado, foi proposto utilizar os conceitos de “eficiência” e “eficácia” estabelecidos na Equação 29 e na Equação 30. É possível observar na Figura 53 que todos os métodos baseados na abordagem *Local Mapped Pattern* (LMP, LMP2, Median-LMP, MM-LMP) são os mais eficientes, porque o algoritmo para extrair o vetor de características é mais rápido do que outros. Entre todos os métodos comparados o descritor MM-LMP é o mais eficiente para as base de dados UBIRIS V1, UBIRIS V2 e CASIA-Iris-Distance.

Figura 53: Desempenho dos métodos avaliados medidos pela “eficiência”.

Apesar do método de Daugman e da abordagem WLD aplicada para o reconhecimento de íris terem apresentado um excelente desempenho de sensibilidade, estes métodos estão entre os que mais consomem tempo de processamento, e por essa razão sua “eficiência” é muito baixa. O mesmo ocorre com os descritores baseados na abordagem CLBP, devido à

complexidade do algoritmo para geração do vetor de características. Já o descritor MBP tem um algoritmo rápido e apresenta um bom desempenho de sensibilidade, permanecendo entre a média nos gráficos de “eficiência”.

(a) LAVI SUBSET-3

(b) CASIA-Iris V2

(c) UBIRIS V1

(d) ND-Iris-Template-Aging-2008–2010

(e) UBIRIS V2

(f) CASIA-Iris-Distance

■ 20 x 240 ■ 30 x 360 ■ 40 x 480 ■ 50 x 600 ■ 60 x 720

Figura 54: Desempenho dos métodos avaliados medidos pela “eficácia”.

Olhando para os gráficos da Figura 54, é possível ver a diferença entre as duas métricas propostas. De maneira geral, é possível observar que todos os métodos baseados na abordagem *Local Mapped Pattern* (LMP, LMP2, Median-LMP, MM-LMP) obtiveram os maiores valores de “eficácia”.

Entre todos os métodos comparados o descritor MM-LMP é o mais eficaz para as base de dados LAVI SUBSET-3 e UBIRIS V2. Alguns descritores baseados na abordagem CLPB, principalmente quando aplicados em amostras de baixa resolução (20×240 pixels), são eficazes. Isto é, como a “eficácia” depende do tamanho do vetor de característica e de como a base de dados é percorrida, é esperado que os descritores com tamanhos menores de vetor sejam mais eficazes, neste caso, os descritores $CLBP_M_{8,1}^{u2}$, $CLBP_S_{8,1}^{u2}$, $CLBP_S_M/C_{8,1}^{u2}$ e $CLBP_M/C_{8,1}^{u2}$. No entanto, é possível notar que onde a sensibilidade é baixa para o CLBP os valores de “eficácia” são menores, como apresentado nos gráficos da Figura 54(e) e 54(f).

5.4 Considerações finais

Neste capítulo foram apresentados os resultados computacionais para avaliação dos novos descritores de textura propostos para a classificação de padrões de íris sob variação do diâmetro da pupila: o Median-LMP e MM-LMP. Os descritores propostos foram comparados aos descritores de textura local: LMP, CLBP, MBP e WLD, que são descritores recentes na literatura para extração de características em texturas globais. Além disso, uma comparação foi realizada também com o método clássico da literatura para o reconhecimento de íris, o método de Daugman.

Os métodos foram avaliados por meio de medidas quantitativas, tais como: sensibilidade, tempo de execução, eficiência e eficácia. Uma avaliação realizada com a base de dados LAVI Iris Video DB2 mostrou que o desempenho dos descritores é reduzido quando existirem dentro do mesmo conjunto amostras de íris com pupilas contraídas e dilatadas, comprovando a hipótese deste trabalho. Neste sentido, foram realizados experimentos com mais cinco bases de dados: UBIRIS V1, UBIRIS V2, CASIA-Iris V2, CASIA-Iris-Distance e ND-Iris-Template-Aging-2008–2010, que permitiram uma avaliação global do desempenho de cada descritor sob condições variadas, tais como: amostras com ruído, amostras com baixa resolução e amostras com variação no diâmetro pupilar.

Em linhas gerais, o descritor proposto MM-LMP apresentou melhor desempenho para amostras com variação no diâmetro da pupila, principalmente àquelas que foram adquiridas de maneira não cooperativa, sob distâncias maiores e iluminação variada. Além disso, eles se apresentaram entre os mais rápidos de todos os métodos comparados, sendo portanto mais eficientes e eficazes.

Conclusão

O objetivo deste trabalho foi investigar a capacidade de discriminação da textura de íris humana em aplicações biométricas, considerando a dilatação e a contração da pupila. Foram propostos dois novos descritores de textura baseados na abordagem Local Mapped Pattern (LMP), denominados como Median-LMP e MM-LMP, comparando seus desempenhos com os descritores de textura: CLBP, MBP, WLD, LMP e com o método de Daugman. Alguns trabalhos publicados anteriormente concluíram que a textura da íris muda sob contração ou dilatação da pupila (DHIR et al., 2010; ARORA et al., 2012; ORTIZ; BOWYER; FLYNN, 2013; HOLLINGSWORTH; BOWYER; FLYNN, 2008). Este efeito fisiológico pode afetar os sistemas de reconhecimento de íris, reduzindo o desempenho dos métodos convencionais para esta finalidade. Além disso, há um crescente interesse nos chamados sistemas de reconhecimento de íris “a distância”, na qual imagens de íris adquiridas de maneira não cooperativa e sob iluminação não controlada, apresentam diferentes tamanhos de pupilas para a mesma pessoa.

Com base nessas evidências, foi gerada uma base de dados de íris com pupilas dilatadas e contraídas e utilizadas outras cinco bases de dados disponíveis na literatura. Dentre as cinco bases de dados selecionadas para os experimentos, duas pertencem ao grupo de sistemas de reconhecimento de íris “a distância”, a UBIRIS V2 e CASIA-Iris-Distance.

Os resultados obtidos com a base de dados desenvolvida mostraram que quando se comparam apenas amostras de íris de olhos com pupilas contraídas, o número de acertos (medida pela métrica de sensibilidade) é maior do que o obtido apenas com pupilas dilatadas, como pode ser visto na Tabela 16, principalmente para o método de Daugman. A abordagem proposta, denominada MM-LMP, obteve o melhor desempenho e foi praticamente estável tanto para pupilas dilatadas como para pupilas contraídas. Os valores obtidos na Tabela 16 foram gerados subtraindo-se o conteúdo da Tabela 8 do conteúdo da Tabela 9.

A redução do desempenho do método de Daugman pode ser observada também a partir da Tabela 10, no qual foram realizados experimentos com todas as imagens de íris em uma única base de dados. Nesse caso, foram comparadas todas as amostras com pupilas

Descritor de textura	Resolução espacial da amostra (<i>pixels</i>)				
	20×240	30×360	40×480	50×600	60×720
Daugman	3.10	3.12	3.08	2.95	2.80
MBP	-0.06	0.18	-0.06	0.29	0.42
Median-LMP	0.60	0.76	-0.40	-0.07	-0.11
MM-LMP	0.89	0.06	-0.06	0.06	-0.30
LMP	1.12	-0.12	0.50	0.35	0.06
LMP2	-0.52	-2.90	-3.35	-4.85	-4.52
WLD	1.00	0.88	-0.36	-1.18	-0.47
CLBP_ $M_{8,1}^{u2}$	-1.70	0.71	1.06	-0.47	0.24
CLBP_ $S_{8,1}^{u2}$	0.59	1.23	2.00	2.64	1.70
CLBP_ $S/M/C_{8,1}^{u2}$	1.12	1.17	-0.36	-0.41	-2.29
CLBP_ $S_M/C_{8,1}^{u2}$	1.06	1.18	0.76	0.64	-2.30
CLBP_ $S/M_{8,1}^{u2}$	1.65	1.71	-0.06	-0.35	-0.70
CLBP_ $M/C_{8,1}^{u2}$	-0.47	0.88	-0.30	-0.18	-0.59

Tabela 16: Percentual de diferença ao se comparar íris com pupilas dilatadas (LAVI Subconjunto-1) vs íris com pupilas contraídas (LAVI Subconjunto-2).

contraídas e pupilas dilatadas entre si. Ao comparar os resultados da Tabela 9 (apenas pupilas contraídas) com os da Tabela 10 (pupilas contraídas e dilatadas), é possível observar que o MM-LMP atingiu o melhor desempenho seguido pelo descritor MBP. O método de Daugman mostrou maior perda de desempenho (aproximadamente 6%), sendo que, o método proposto MM-LMP permaneceu estável em todas as resoluções espaciais, apresentando uma perda de precisão de $\sim 0,38\%$.

Avaliando os resultados a partir dos métodos comparados, aplicadas às outras bases de dados, é possível concluir que o método de Daugman atingiu a melhor precisão para as bases de dados UBIRIS V1, CASIA V2 e ND-Iris-Template-Aging-2008–2010. No entanto, é importante notar que essas bases de dados são bases com iluminação controlada utilizadas amplamente na literatura, e não há imagens de íris suficientes com pupilas contraídas e dilatadas para a mesma pessoa. Essas bases de dados foram utilizadas neste trabalho, com o objetivo de analisar os pontos fortes e fracos dos descritores propostos e, para se obter uma avaliação do potencial dos descritores locais em texturas de íris. Mas, o descritor proposto MM-LMP apresentou o segundo melhor desempenho para essas bases de dados, e o melhor desempenho utilizando amostras em 60×720 *pixels*, com os conjuntos UBIRIS V1 e CASIA V2.

Uma avaliação foi realizada também com os conjuntos de imagens de íris das bases de dados UBIRIS V2 e CASIA-Iris-Distance. Essas bases de dados forneceram um maior número de amostras com o mesmo comportamento do LAVI Subconjunto-3, ou seja, imagens de íris com pupilas contraídas e dilatadas. Frente a este cenário, observou-se que o método de Daugman apresentou um dos piores desempenhos entre os descritores avaliados, atingindo apenas o terceiro lugar para a base de dados UBIRIS V2 e o quarto para o conjunto CASIA-Iris-Distance. Os descritores Median-LMP e MM-LMP foram os

que atingiram a melhor taxa de sensibilidade na maioria dos experimentos, mantendo-se em primeiro lugar o MM-LMP e em segundo o Median-LMP, para ambas bases de dados. No entanto, é importante notar que o WLD superou os descritores propostos com amostras em resolução espacial de 60×720 *pixels*, não somente nesses experimentos, como em todos realizados.

Outro ponto importante a analisar refere-se ao tempo de execução *um-para-muitos*, que equivale ao tempo estimado para comparar 1 amostra apresentada com todas as outras armazenadas na base de dados. Nesse sentido, dois pontos devem ser avaliados: a complexidade do algoritmo que pode ser medida pelo tempo gasto na geração do vetor de característica; e a dimensionalidade deste vetor medida pelo tempo gasto para a pesquisa sequencial na base de dados. Em uma aplicação em tempo preditivo, como “íris a distância”, a abordagem utilizada deve ter boa taxa de acertos (ou sensibilidade) e, deve ser rápida. Para avaliar essa relação, de sensibilidade e rapidez, duas métricas foram propostas: “eficiência” e “eficácia”. Ao usar o conceito de “eficiência” como fazendo as coisas da maneira mais econômica (MORAES, 2010), conclui-se que todos os métodos baseados na abordagem *Local Mapped Pattern* foram os mais “eficientes”, e o MM-LMP atingiu a maior eficiência para as bases de dados: UBIRIS V1, UBIRIS V2 e CASIA-Iris-Distance.

Considerando-se o conceito de “eficácia” como a capacidade de produzir uma quantidade desejada do efeito desejado, ou para obter sucesso na obtenção de uma determinada meta (MORAES, 2010), os métodos, com base na abordagem LMP, de maneira geral foram os mais “eficazes”, principalmente para as bases de dados contendo um volume maior de amostras com pupilas dilatadas e contraídas, tais como: LAVI Subconjunto-3, UBIRIS V2 e CASIA-Iris-Distance. Tanto a complexidade do algoritmo quanto o tamanho do vetor de características afetam diretamente esses dois tipos de medidas, ou melhor, os desempenhos dos métodos.

Apesar dos métodos $CLBP_S/M/C_{8,1}^{u2}$ e $CLBP_S/M_{8,1}^{u2}$ terem apresentado boa taxa de acertos (sensibilidade) com a base de dados LAVI Iris Video DB2, estes, obtiveram o pior desempenho medido pela “eficiência” e pela “eficácia”, devido a alta dimensionalidade dos vetores de características, respectivamente 6.962 e 3.481 elementos. Sendo assim, é possível afirmar que para o reconhecimento de íris, os descritores baseados na abordagem CLBP apresentam médios valores de “eficácia”, e não são tão “eficientes”. E mais, os descritores baseados na abordagem LMP apresentam ótimos valores de “eficiência” e médios valores de “eficácia”. Já o método de Daugman e o WLD, apesar de seu excelente desempenho (sensibilidade), não são “eficientes” nem “eficazes”, devido à complexidade de seus algoritmos e à alta dimensionalidade dos vetores de características. Particularmente, em relação ao método de Daugman, pode-se concluir que a baixa “eficiência” e “eficácia” estão associadas ao processo de comparação dos vetores, que utiliza um recurso complexo para se obter a similaridade entre eles, denominado “deslocamento de *bits*”.

Com base nos resultados obtidos conclui-se que, é possível realizar-se classificação

de amostras de íris sob variação na textura da mesma. Os descritores propostos neste trabalho apresentaram o melhor desempenho para amostras de íris com pupilas dilatadas e contraídas, o que os apontam como métodos adequados para aplicações biométricas de íris a distância. Além disso, os resultados encorajam a investigação de novos descritores, pois a abordagem *Local Mapped Pattern* possibilita variações no formato da função de mapeamento e na maneira como as diferenças de níveis de cinza podem ser empregadas. Em específico neste trabalho foi escolhida a função de mapeamento sigmoidal, pelo fato de estar sendo amplamente investigada pelo grupo de pesquisa do LAVI - Laboratório de Visão Computacional da EESC-USP, e também devido ao fato de ser a curva suave de transição de estados determinada pela função degrau. Esta característica causa uma maior capacidade de absorver pequenas variações dos padrões locais, fato este impossível de ocorrer com a função degrau utilizada pelos descritores derivados do LBP. No entanto, existem diversas outras funções de mapeamento que podem contribuir para a continuidade deste trabalho, tais como: função Gaussiana, função triangular, função arco tangente já utilizada no descritor WLD e, outras que ainda não foram avaliadas.

6.1 Contribuições

Com base na realização desta pesquisa, esta tese de doutorado contribuiu para:

- a) a proposta de dois novos descritores para extração de características da íris com variação na textura, devido às mudanças comportamentais da membrana da íris.
 - Median Local Mapped Pattern (Median-LMP);
 - Modified Median Local Mapped Pattern (MM-LMP);
- b) a avaliação de desempenho de diferentes descritores locais para a extração de características da íris e a comparação com o método de Daugman, que é, ainda hoje, considerado como o que obtém as melhores taxas de reconhecimento.

6.2 Sugestões de trabalhos futuros

O presente trabalho apresentou uma nova abordagem para extração de características da textura da íris sob os efeitos de dilatação e contração da pupila. Tendo em vista os resultados obtidos, algumas sugestões que podem ser utilizadas para trabalhos futuros estão descritos abaixo:

- a) Avaliar o desempenho dos descritores propostos de forma geral para diferentes tipos de textura;
- b) Realizar experimentos com novas funções de mapeamento para se obter uma avaliação do desempenho dos descritores propostos;
- c) Avaliar o desempenho de todos os métodos comparados com outros classificadores;

- d) Reduzir o valor do parâmetro b (número de bins do histograma) a fim de otimizar o tempo de execução dos descritores propostos;
- e) Realizar experimentos com outras funções de peso do modelo matemático;
- f) Comparar o desempenho dos descritores propostos com o descritor *Color Local Mapped Pattern* (CLMP) (NEGRI; GONZAGA, 2014), para amostras de íris digitalizadas na banda visível (RGB), tais como aquelas das bases de dados: UBIRIS V1 e UBIRIS V2.
- g) Implementar os descritores propostos em plataformas embarcadas ou em FPGA e comparar o seu desempenho (custo computacional) com os outros métodos avaliados;
- h) Utilizar os descritores propostos em conjunto com outros métodos biométricos, implementando-se sistemas biométricos multimodais, tais como: (face + íris), (íris + periocular), (derme + íris) entre outras combinações.

6.3 Trabalhos publicados

[1] SOUZA, J. M. de; VIEIRA, R. T.; GONZAGA, A. Analysis of texture under pupil contraction/dilation for biometric recognition. In: **XI Workshop de Visão Computacional - WVC 2015**. São Carlos, SP, Brazil: USP, 2015. p. 128 – 133. Disponível em: <<http://www.lbd.dcc.ufmg.br/colecoes/wvc/2015/021.pdf>>.

[2] SOUZA, J. M. de; GONZAGA, A. Iris texture recognition under pupil size variation. **Machine Vision and Applications**, 2017. Mar 2017. (Submetido)

Referências

- ACKERMAN, R. K. **Closing the Door on Iris Recognition Vulnerabilities**. AFCEA, 2013. Disponível em: <<https://www.afcea.org/content/?q=node/11607>>. Acesso em: 5 jul. 2016.
- ARORA, S.; LONDHE, N. D.; ACHARYA, A. K. Article: Human identification based on iris recognition for distant images. **International Journal of Computer Applications**, 2012. v. 45, n. 16, p. 32–39, May 2012.
- ARORA, S. et al. Iris recognition under alcohol influence: A preliminary study. In: **5th ICB - International Conference on Biometrics**. [S.l.: s.n.], 2012. p. 336–341.
- BAGESTEIRO, L. D. **Classificação de padrões radiológicos por blocos em imagens não segmentadas de tomografia computadorizada**. Dissertação (Mestrado) — Universidade Federal do Paraná, 2015.
- BASHIR, F. et al. Eagle-eyes: A system for iris recognition at a distance. In: **2008 IEEE Conference on Technologies for Homeland Security**. Waltham, MA, USA: IEEE, 2008. p. 426–431.
- BEAR, B. W. C. M. F.; PARADISO, M. A. **Neurociências: desvendando o sistema nervoso**. 2. ed. Porto Alegre: Artmed, 2002.
- BOAVENTURA, I. A. G. **Números fuzzy em processamento de imagens digitais e suas aplicações na detecção de bordas**. Tese (Doutorado) — Universidade de São Paulo, 2010.
- BOLES, W. W.; BOASHASH, B. A human identification technique using images of the iris and wavelet transform. **IEEE Transactions on Signal Processing**, 1998. v. 46, n. 4, p. 1185–1188, 1998.
- BRADSKI, G. **Open Source Computer Vision Library**. 2000. Disponível em: <<http://opencv.org/>>. Acesso em: 21 out. 2016.
- BRAVO, J. C. L. **Autenticação Pessoal baseada no som da assinatura**. Dissertação (Mestrado) — Universidade Estadual de Campinas, 2006.
- CAPONETTI, L. et al. Texture segmentation with local fuzzy patterns and neuro-fuzzy decision support. In: **Proceedings of the 10th International Conference on Knowledge-Based Intelligent Information and Engineering Systems - Volume**

Part II. Berlin, Heidelberg: Springer-Verlag, 2006. (KES'06), p. 340–347. ISBN 3-540-46537-5, 978-3-540-46537-9.

CARNEIRO, M. B. P. **Reconhecimento de Íris utilizando algoritmos Genéticos e Amostragem não-uniforme.** Tese (Doutorado) — Universidade Federal de Uberlândia, 2010.

CARREIRA, R. P. de O. **Concepção de um Sistema Alternativo de Reconhecimento de Íris Cooperativo.** Dissertação (Mestrado) — Universidade da Beira Interior, 2009.

CARVALHO, S. Q. da C. **Atratividade facial e expressões emocionais: Existe Relação com o diâmetro da pupila?** Dissertação (Mestrado) — Universidade Federal do Paraíba, 2010.

CATARINO, F. M. I. F. **Segmentação da íris em imagens com ruído.** Tese (Doutorado) — Universidade da Beira Interior, 2009.

CHEN, J. et al. Wld: A robust local image descriptor. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 2010. v. 32, n. 9, p. 1705–1720, Sept 2010. ISSN 0162-8828.

CHIERICI, C. et al. A new approach for analyzing rotated textures. **Anais IX WVC Workshop de Visão Computacional**, 2013. Junho 2013. ISSN 2175-6120.

COSTA, R. M. da. **Uma nova abordagem para reconhecimento biométrico baseado em características dinâmicas da íris humana.** Tese (Doutorado) — Universidade de São Paulo, 2010.

DACHENG, T. et al. A set of novel textural features based on 3d co-occurrence matrix for content-based image retrieval. In: **Information Fusion, 2002. Proceedings of the Fifth International Conference on.** [S.l.: s.n.], 2002. v. 2, p. 1403–1407 vol.2.

DATABASE, C. I. I. **CASIA-IrisV2 - CASIA Iris Image Database.** Academia Chinesa de Ciências do Instituto de Automação, 2004. Disponível em: <<http://biometrics.idealtest.org>>. Acesso em: 26 set. 2016.

_____. **CASIA-IrisV4 - CASIA Iris Image Database.** Academia Chinesa de Ciências do Instituto de Automação, 2011. Disponível em: <<http://biometrics.idealtest.org>>. Acesso em: 8 jan. 2016.

DAUGMAN, J. High confidence visual recognition of persons by a test of statistical independence. **IEEE Trans. Pattern Anal. Mach. Intell.**, 1993. v. 15, n. 11, p. 1148–1161, 1993.

_____. **Biometric personal identification system based on iris analysis.** Google Patents, mar. 1 1994. US Patent 5,291,560. Disponível em: <<https://www.google.com/patents/US5291560>>.

DB2, L. I. V. **The iris database LAVI Iris Video DB2.** Universidade de São Paulo, 2014. Disponível em: <<http://imagem.sel.eesc.usp.br/iris/>>. Acesso em: 8 jan. 2014.

- DHIR, L. et al. **Effect of cataract surgery and pupil dilation on iris pattern recognition for personal authentication**. 2010. v. 24, n. 6, p. 1006–1010, June 2010. Disponível em: <<http://opus.bath.ac.uk/19417/>>.
- DONG, W.; SUN, Z.; TAN, T. A design of iris recognition system at a distance. In: **Chinese Conference on Pattern Recognition**. Nanjing, China: **IEEE**, 2009. v. 2, p. 1–5.
- FENKER, S. P.; BOWYER, K. W. Analysis of template aging in iris biometrics. In: **2012 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops**. [S.l.: s.n.], 2012. p. 45–51. ISSN 2160-7508.
- FERRARI, G. L. **Pupílometria dinâmica: Aplicação na detecção e avaliação da neuropatia autônoma diabética e estudo da correlação entre a resposta temporal da pupila ao estímulo visual e a glicemia**. Tese (Doutorado) — Universidade Tecnológica Federal do Paraná, 2008.
- FERRAZ, C. T.; JUNIOR, O. P.; GONZAGA, A. Feature description based on mean local mapped pattern. In: **X Workshop de Visão Computacional - WVC 2014**. Uberlândia, MG, Brazil: UFMG, 2014. p. 32 – 37. Disponível em: <<http://www.lbd.dcc.ufmg.br/colecoes/wvc/2014/006.pdf>>.
- FERRAZ, C. T. et al. Object recognition based on bag of features and a new local pattern descriptor. **International Journal of Pattern Recognition and Artificial Intelligence**, 2014. v. 28, n. 08, p. 1455010, 2014. Disponível em: <<http://www.worldscientific.com/doi/abs/10.1142/S0218001414550106>>.
- FILHO, P. L. de P. **Reconhecimento de espécies florestais através de imagens macroscópicas**. Tese (Doutorado) — Universidade Federal do Paraná, 2012.
- GABOR, D. **Theory of communication**. Institution of Electrical Engineering, 1946. Disponível em: <<https://books.google.com.br/books?id=kvJSAAAAMAAJ>>.
- GONÇALVES, W. N. **Análise de texturas estáticas e dinâmicas e suas aplicações em biologia e nanotecnologia**. Tese (Doutorado) — Universidade de São Paulo, 2013.
- GONZALES, R. C.; WOODS, R. E. **Processamento de Imagens Digitais**. 1. ed. São Paulo: Editora Blucher, 2000.
- GUO, Z.; ZHANG, L.; ZHANG, D. A completed modeling of local binary pattern operator for texture classification. **IEEE Transactions on Image Processing**, 2010. v. 19, n. 6, p. 1657–1663, June 2010. ISSN 1057-7149.
- HAFIANE, A.; SEETHARAMAN, G.; ZAVIDOVIQUE, B. Median binary pattern for textures classification. In: **Proceedings of the 4th International Conference on Image Analysis and Recognition**. Berlin, Heidelberg: Springer-Verlag, 2007. (ICIAR'07), p. 387–398. ISBN 3-540-74258-1, 978-3-540-74258-6. Disponível em: <<http://dl.acm.org/citation.cfm?id=2394970.2395010>>.
- HANNA, K. et al. A system for non-intrusive human iris acquisition and identification. In: **IAPR Workshop Mach. Vision Appl.** [S.l.: s.n.], 1996. p. 200–203.
- HARALICK, R. M. Statistical and structural approaches to texture. **Proceedings of the IEEE**, 1979. v. 67, n. 5, p. 786–804, May 1979. ISSN 0018-9219.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, 1973. SMC-3, n. 6, p. 610–621, Nov 1973. ISSN 0018-9472.

HE, Y. et al. Iris feature extraction method based on lbp and chunked encoding. In: **Natural Computation (ICNC), 2011 Seventh International Conference on**. [S.l.: s.n.], 2011. v. 3, p. 1663–1667. ISSN 2157-9555.

HEIKKILÄ, M.; PIETIKÄINEN, M.; SCHMID, C. Description of interest regions with local binary patterns. **Pattern Recognition**, 2009. v. 42, n. 3, p. 425 – 436, 2009. ISSN 0031-3203. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0031320308003282>>.

HOLLINGSWORTH, K.; BOWYER, K.; FLYNN, P. The importance of small pupils: A study of how pupil dilation affects iris biometrics. In: **Biometrics: Theory, Applications and Systems, 2008. BTAS 2008. 2nd IEEE International Conference on**. [S.l.: s.n.], 2008. p. 1–6.

HU, Y.; LONG, Z.; ALREGIB, G. Completed local derivative pattern for rotation invariant texture classification. In: **2016 IEEE International Conference on Image Processing (ICIP)**. [S.l.: s.n.], 2016. p. 3548–3552.

HUSSAIN, M. et al. Computationally efficient invariant facial expression recognition. **IEEE Trans. Pattern Anal. Mach. Intell.**, 2014. v. 3, n. 2, p. 61–68, 2014.

IAKOVIDIS, D.; KERAMIDAS, E.; MAROULIS, D. Fuzzy local binary patterns for ultrasound texture characterization. In: CAMPILHO, A.; KAMEL, M. (Ed.). **Image Analysis and Recognition**. Springer Berlin Heidelberg, 2008, (Lecture Notes in Computer Science, v. 5112). p. 750–759. ISBN 978-3-540-69811-1. Disponível em: <http://dx.doi.org/10.1007/978-3-540-69812-8_74>.

IRISACCESS. **LG 4000 Camera**. Online, 2011. Disponível em: <<http://www.lgiris.com>>. Acesso em: 8 jan. 2017.

JARDINI, E. de A. **MFIS: algoritmo de reconhecimento e indexação em base de dados de impressões digitais em espaço métrico**. Tese (Doutorado) — Universidade de São Paulo, 2007.

JILLELA, R.; ROSS, A.; FLYNN, P. Information fusion in low-resolution iris videos using principal components transform. In: **Applications of Computer Vision (WACV), 2011 IEEE Workshop on**. [S.l.: s.n.], 2011. p. 262–269. ISSN 1550-5790.

KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: **Neural Networks, 1995. Proceedings., IEEE International Conference on**. [S.l.: s.n.], 1995. v. 4, p. 1942–1948 vol.4.

KIRCH, W. **Encyclopedia of Public Health**. [S.l.]: Springer, 2008. (Encyclopedia of Public Health, v. 1-2). ISBN 9781402056130.

LARSON, B. F. R.; NETO, H. V. **Estatística aplicada**. 4. ed. São Paulo, RJ: Pearson Prentice Hall, 2010. 406 p.

- LIENHART, R.; MAYDT, J. An extended set of haar-like features for rapid object detection. In: **Image Processing. 2002. Proceedings. 2002 International Conference on**. [S.l.: s.n.], 2002. v. 1, p. I-900–I-903 vol.1. ISSN 1522-4880.
- LIU, S.; ZHANG, Y.; LIU, K. Facial expression recognition under partial occlusion based on weber local descriptor histogram and decision fusion. In: **Control Conference (CCC), 2014 33rd Chinese**. [S.l.: s.n.], 2014. p. 4664–4668.
- MA, L. et al. Efficient iris recognition by characterizing key local variations. **Image Processing, IEEE Transactions on**, 2004. v. 13, n. 6, p. 739–750, June 2004. ISSN 1057-7149.
- MARTIN, A. et al. The det curve in assessment of detection task performance. In: . [S.l.: s.n.], 1997. p. 1895–1898.
- MASEK, L.; KOVESI, P. **MATLAB Source Code for a Biometric Identification System Based on Iris Patterns**. The School of Computer Science and Software Engineering, The University of Western Australia, 2003. Disponível em: <<http://www.csse.uwa.edu.au/~pk/studentprojects/libor/sourcecode.html>>. Acesso em: 27 jan. 2015.
- MATERKA, A.; STRZELECKI, M. **Texture analysis methods – a review**. [S.l.], 1998.
- MATEY, J. et al. Iris on the move: Acquisition of images for iris recognition in less constrained environments. **Proceedings of the IEEE**, 2006. v. 94, n. 11, p. 1936 –1947, nov. 2006.
- MORAES, G. **Sistema de Gestão de Riscos - Princípios e Diretrizes**. [S.l.]: Gerenciamento Verde Consultoria, 2010. ISBN 9788599331286.
- MUSCI, M. et al. Padrões binários locais na classificação de imagens de sensoriamento remoto. **Anais do XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR IX WVC Workshop de Visão Computacional**, 2013. Abril 2013.
- NEGRI, T. T.; GONZAGA, A. **Color Texture Classification under Varying Illumination**. In: **X Workshop de Visão Computacional - WVC 2014**. Uberlândia, MG, Brazil: UFMG, 2014. p. 61 – 66. Disponível em: <<http://www.lbd-dcc.ufmg.br/colecoes/wvc/2014/0011.pdf>>.
- NIXON, M.; AGUADO, A. S. **Feature Extraction & Image Processing, Second Edition**. 2nd. ed. [S.l.]: Academic Press, 2008. ISBN 0123725380, 9780123725387.
- NOVAK, I.; HOCENSKI, Z. Texture feature extraction for a visual inspection of ceramic tiles. In: **Industrial Electronics, 2005. ISIE 2005. Proceedings of the IEEE International Symposium on**. [S.l.: s.n.], 2005. v. 3, p. 1279–1283 vol. 3.
- OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. **Pattern Recognition**, 1996. v. 29, n. 1, p. 51–59, jan. 1996. ISSN 00313203. Disponível em: <[http://dx.doi.org/10.1016/0031-3203\(95\)00067-4](http://dx.doi.org/10.1016/0031-3203(95)00067-4)>.

OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, 2002. v. 24, n. 7, p. 971–987, Jul 2002. ISSN 0162-8828.

OJALA, T. et al. Texture discrimination with multidimensional distributions of signed gray-level differences. **Pattern Recognition**, 2001. v. 34, n. 3, p. 727 – 739, 2001. ISSN 0031-3203. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0031320300000108>>.

ORTIZ, E.; BOWYER, K.; FLYNN, P. A linear regression analysis of the effects of age related pupil dilation change in iris biometrics. In: **Biometrics: Theory, Applications and Systems (BTAS), 2013 IEEE Sixth International Conference on**. [S.l.: s.n.], 2013. p. 1–6.

OWJIMEHR, M.; DANYALI, H.; HELFROUSH, M. S. Fully automatic segmentation and classification of liver ultrasound images using completed lbp texture features. In: **2014 22nd Iranian Conference on Electrical Engineering (ICEE)**. [S.l.: s.n.], 2014. p. 1956–1960. ISSN 2164-7054.

PAMPLONA, V. F. **Estudo sobre a íris humana para síntese de imagens fotorealísticas**. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul, 2007.

PATIL, A. M.; PATIL, D. S.; PATIL, P. S. Article: Iris recognition using gray level co-occurrence matrix and hausdorff dimension. **International Journal of Computer Applications**, 2016. v. 133, n. 8, p. 29–34, January 2016. Published by Foundation of Computer Science (FCS), NY, USA.

PEDRINI, H.; SCHWARTZ, W. **Análise de imagens digitais: princípios, algoritmos e aplicações**. São Paulo, SP: Thomson Learning, 2007. 528 p. ISBN 9788522105953.

PETPON, A.; SRISUK, S. Face recognition with local line binary pattern. In: **Image and Graphics, 2009. ICIIG '09. Fifth International Conference on**. [S.l.: s.n.], 2009. p. 533–539.

PHILLIPS, P. J. et al. Overview of the multiple biometrics grand challenge. In: **Proceedings of the Third International Conference on Advances in Biometrics**. Berlin, Heidelberg: Springer-Verlag, 2009. (ICB '09), p. 705–714. ISBN 978-3-642-01792-6. Disponível em: <http://dx.doi.org/10.1007/978-3-642-01793-3_72>.

PIETIKAINEN, M. et al. **Computer Vision Using Local Binary Patterns**. London: Springer Verlag, 2011. (Computational imaging and vision). ISBN 978-0-85729-747-1. Disponível em: <<http://opac.inria.fr/record=b1133835>>.

PROENÇA, H. 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, 2009. p. 9 –15.

PROENÇA, H.; ALEXANDRE, L. UBIRIS: A noisy iris image database. In: **13th International Conference on Image Analysis and Processing - ICIAP 2005**. Cagliari, Italy: Springer, 2005. LNCS 3617, p. 970–977.

PROENÇA, H. et al. **The UBIRIS.v2: A Database of Visible Wavelength Images Captured On-The-Move and At-A-Distance**. **IEEE Trans. PAMI**, 2010. v. 32, n. 8, p. 1529–1535, August 2010.

RADU petru. A colour iris recognition system employing multiple classifier techniques. **ELCVIA Electronic Letters on Computer Vision and Image Analysis**, 2013. v. 12, n. 2, 2013. ISSN 1577-5097. Disponível em: <[http://elcvia.cvc.uab.es/article-view/520](http://elcvia.cvc.uab.es/article/view/520)>.

SANDRONI, P. **Dicionário de administração e finanças**. [S.l.]: Best Seller, 1996. ISBN 9788571235007.

SINGH, S.; MAURYA, R.; MITTAL, A. Application of complete local binary pattern method for facial expression recognition. In: **Intelligent Human Computer Interaction (IHCI), 2012 4th International Conference on**. [S.l.: s.n.], 2012. p. 1–4.

SKLANSKY, J. Image segmentation and feature extraction. **Systems, Man and Cybernetics, IEEE Transactions on**, 1978. v. 8, n. 4, p. 237–247, April 1978. ISSN 0018-9472.

SONG, C.; YANG, F.; LI, P. Rotation invariant texture measured by local binary pattern for remote sensing image classification. In: **Education Technology and Computer Science (ETCS), 2010 Second International Workshop on**. [S.l.: s.n.], 2010. v. 3, p. 3–6.

SOUZA, J. M. de. **Métodos para o reconhecimento de íris em ambiente não cooperativo**. Dissertação (Mestrado) — Universidade Federal de São Carlos, 2012.

SOUZA, J. M. de; VIEIRA, R. T.; GONZAGA, A. Analysis of texture under pupil contraction/dilation for biometric recognition. In: **XI Workshop de Visão Computacional - WVC 2014**. São Carlos, SP, Brazil: USP, 2015. p. 128 – 133. Disponível em: <<http://www.lbd.dcc.ufmg.br/colecoes/wvc/2015/021.pdf>>.

STANFIELD, C. L.; GERMANN, W. J. **Principles of Human Physiology**. USA: Pearson, 2006. ISBN 0805382860.

SUN, S.; ZHAO, L.; YANG, S. Gabor weber local descriptor for bovine iris recognition. In: **Mathematical Problems in Engineering**. [S.l.: s.n.], 2013. p. 7.

TAMURA, H.; MORI, S.; YAMAWAKI, T. Textural features corresponding to visual perception. **Systems, Man and Cybernetics, IEEE Transactions on**, 1978. v. 8, n. 6, p. 460–473, June 1978. ISSN 0018-9472.

TAPIA, J. E.; PEREZ, C. A.; BOWYER, K. W. Gender classification from iris images using fusion of uniform local binary patterns. In: **Computer Vision - ECCV 2014 Workshops - Zurich, Switzerland, September 6-7 and 12, 2014, Proceedings, Part II**. [s.n.], 2014. p. 751–763. Disponível em: <http://dx.doi.org/10.1007/978-3-319-16181-5_57>.

VIEIRA, R. T. **Análise de micropadrões em imagens digitais baseada em números fuzzy**. Dissertação (Mestrado) — Universidade de São Paulo, 2013.

- VIEIRA, R. T. et al. Local fuzzy pattern: A new way for micro-pattern analysis. In: _____. **Intelligent Data Engineering and Automated Learning - IDEAL 2012: 13th International Conference, Natal, Brazil, August 29-31, 2012. Proceedings**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 602–611. ISBN 978-3-642-32639-4. Disponível em: <http://dx.doi.org/10.1007/978-3-642-32639-4_73>.
- VIEIRA, T. F. **Identifying Kinship Cues from Facial Images**. Tese (Doutorado) — Universidade Federal do Pernambuco, 2013.
- VILLAR, J. D.; IVES, R.; MATEY, J. Design and implementation of a long range iris recognition system. In: **Signals, Systems and Computers (ASILOMAR), 2010 Conference Record of the Forty Fourth Asilomar Conference on**. [S.l.: s.n.], 2010. p. 1770–1773. ISSN 1058-6393.
- VIOLA, P.; JONES, M. J. Robust real-time face detection. **Int. J. Comput. Vision**, 2004. Kluwer Academic Publishers, Hingham, MA, USA, v. 57, n. 2, p. 137–154, maio 2004. ISSN 0920-5691. Disponível em: <<http://dx.doi.org/10.1023/B:VISI.0000013087-49260.fb>>.
- WANG, L.; HE, D.-C. Texture classification using texture spectrum. **Pattern Recognition**, 1990. Elsevier Science Inc., New York, NY, USA, v. 23, n. 8, p. 905–910, ago. 1990. ISSN 0031-3203. Disponível em: <[http://dx.doi.org/10.1016/0031-3203\(90\)90135-8](http://dx.doi.org/10.1016/0031-3203(90)90135-8)>.
- WANG, X. et al. Feature fusion of hog and wld for facial expression recognition. In: **System Integration (SII), 2013 IEEE/SICE International Symposium on**. [S.l.: s.n.], 2013. p. 227–232.
- WILDES, R. et al. A system for automated iris recognition. In: **Applications of Computer Vision, 1994., Proceedings of the Second IEEE Workshop on**. [S.l.: s.n.], 1994. p. 121–128.
- XIANCHUAN, X.; QI, Z. Medical image retrieval using local binary patterns with image euclidean distance. In: **Information Engineering and Computer Science, 2009. ICIECS 2009. International Conference on**. [S.l.: s.n.], 2009. p. 1–4.
- ZHANG, L. et al. Face detection based on multi-block lbp representation. In: _____. **Advances in Biometrics: International Conference, ICB 2007, Seoul, Korea, August 27-29, 2007. Proceedings**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 11–18. ISBN 978-3-540-74549-5. Disponível em: <http://dx.doi.org/10.1007/978-3-540-74549-5_2>.

Apêndices

Descrição da base de dados LAVI Iris Video DB2

A primeira coluna da Tabela 17 representa o número de classes da base de dados, já na segunda coluna é definida a identificação do usuário, composto pelas iniciais do nome seguido da sessão. A terceira e quarta colunas indicam a idade e o gênero do usuário. A base dados LAVI Iris Video DB2 é formada pelas sequências de vídeos destacadas em cor cinza na tabela, sendo que as não destacadas foram eliminadas da base por apresentarem erros de segmentação, baixo contraste e desfoque.

Tabela 17: Descrição completa da base de dados LAVI Iris Video DB2

Iris(video)	Sample(frame)	Age	Sexo
1	TTN_S1	25	F
	TTN_S2	25	F
	TTN_S3	25	F
	TTN_S4	25	F
2	RTV_S1	25	F
	RTV_S2	25	F
	RTV_S3	25	F
	RTV_S4	25	F
3	CTF_S1	34	F
	CTF_S2	34	F
	CTF_S3	34	F
	CTF_S4	34	F
4	MRC_S1	25	F
	MRC_S2	25	F
	MRC_S3	25	F
	MRC_S4	25	F
	MRC_S5	25	F

5	MAZ_S1	28	F
	MAZ_S2	28	F
	MAZ_S3	28	F
6	KDM_S1	25	F
	KDM_S2	25	F
	KDM_S3	25	F
7	MVG_S1	23	M
	MVG_S2	23	M
	MVG_S3	23	M
	MVG_S4	23	M
8	RVA_S1	26	M
	RVA_S2	26	M
	RVA_S3	26	M
	RVA_S4	26	M
	RVA_S5	26	M
9	ADG_S1	59	M
	ADG_S2	59	M
	ADG_S3	59	M
	ADG_S4	59	M
10	TRK_S1	31	F
	TRK_S2	31	F
	TRK_S3	31	F
	TRK_S4	31	F
11	JGS_S1	23	F
	JGS_S2	23	F
12	CAF_S1	26	F
	CAF_S2	26	F
	CAF_S3	26	F
	CAF_S4	26	F
13	AFN_S1	23	F
	AFN_S2	23	F
	AFN_S3	23	F
	AFN_S4	23	F
14	TCF_S1	27	F
	TCF_S2	27	F
	TCF_S3	27	F
	TCF_S4	27	F

15	ELG_S1	24	M
	ELG_S2	24	M
	ELG_S3	24	M
	ELG_S4	24	M
16	BEB_S1	25	M
	BEB_S2	25	M
	BEB_S3	25	M
	BEB_S4	25	M
17	TEP_S1	24	M
	TEP_S2	24	M
18	MPS_S1	28	M
	MPS_S2	28	M
	MPS_S3	28	M
	MPS_S4	28	M
19	RJL_S1	25	M
	RJL_S2	25	M
	RJL_S3	25	M
	RJL_S4	25	M
20	EJA_S1	23	M
	EJA_S2	23	M
	EJA_S3	23	M
	EJA_S4	23	M
21	JCZ_S1	24	M
	JCZ_S2	24	M
	JCZ_S3	24	M
	JCZ_S4	24	M
22	MAC_S1	41	M
23	ROR_S1	48	F
24	FMS_S1	19	M
	FMS_S2	19	M
25	CFS_S1	23	F
	CFS_S2	23	F
26	DRM_S1	35	M
	-	-	-
27	LTM_S1	24	M
	LTM_S2	24	M
28	RCF_S1	27	M
	RCF_S2	27	M

29	FRA_S1	24	M
	FRA_S2	24	M
	FRA_S3	24	M
	FRA_S4	24	M
30	ECP_S1	36	M
	ECP_S2	36	M
	ECP_S3	36	M
	ECP_S4	36	M
31	CFA_S1	23	F
	CFA_S2	23	F
32	MEK_S1	31	M
	MEK_S2	31	M
	MEK_S3	31	M
	MEK_S4	31	M
33	KRF_S1	36	M
	KRF_S2	36	M
34	EGP_S1	31	M
	EGP_S2	31	M
35	JPB_S1	27	M
36	VML_S1	38	M
	VML_S2	38	M
	VML_S3	38	M
	VML_S4	38	M
37	AAS_S1	53	F
	AAS_S3	53	F
38	JRZ_S1	40	F
	JRZ_S2	40	F
	JRZ_S3	40	F
	JRZ_S4	40	F
39	GTP_S1	25	M
	GTP_S2	25	M
40	HLV_S1	24	M
	HLV_S2	24	M
41	MGM_S1	32	M
	MGM_S2	32	M
	MGM_S3	32	M
	MGM_S4	32	M

42	TTC_S1	23	F
	TTC_S2	23	F
	TTC_S3	23	F
	TTC_S4	23	F
43	FAB_S1	24	M
	FAB_S2	24	M
	FAB_S3	24	M
	FAB_S4	24	M
44	TFL_S1	25	F
	TFL_S2	25	F
	TFL_S3	25	F
	TFL_S4	25	F
45	MRF_S1	50	F
	MRF_S2	50	F
46	AQC_S1	25	M
	AQC_S2	25	M
	AQC_S3	25	M
	AQC_S4	25	M
47	MVR_S1	22	M
	MVR_S2	22	M
	MVR_S3	22	M
	MVR_S4	22	M
48	GCR_S1	23	M
	GCR_S2	23	M
	GCR_S3	23	M
	GCR_S4	23	M
49	PPE_S1	29	F
	PPE_S2	29	F
50	LJS_S1	22	M
	LJS_S2	22	M
51	DRO_S1	27	M
	DRO_S2	27	M
	DRO_S3	27	M
	DRO_S4	27	M
52	HCR_S1	28	M
	HCR_S2	28	M
	HCR_S3	28	M
	HCR_S4	28	M

53	PFN_S1	28	F
	PFN_S2	28	F
	PFN_S3	28	F
	PFN_S4	28	F

Parâmetros do algoritmo Masek

Para se obter a segmentação do anel da íris e da pupila por meio do algoritmo de Masek, foi necessário definir alguns ajustes para cada base de dados. A Tabela 18 apresenta os parâmetros utilizados em cada base de dados para se obter uma melhor segmentação das amostras quando a pupila encontra-se dilatada e contraída.

Parâmetro	Pupila	
	Contraída	Dilatada
lpupilradius	20	40
upupilradius	65	85
lirisradius	75	95
uirisradius	128	150

(a) LAVI Iris Video DB2

Parâmetro	Pupila	
	Contraída	Dilatada
lpupilradius	30	50
upupilradius	70	90
lirisradius	80	105
uirisradius	190	215

(c) Notre Dame ND-Iris-Template-Aging-2008–2010

Parâmetro	Pupila	
	Contraída	Dilatada
lpupilradius	0	20
upupilradius	20	45
lirisradius	30	65
uirisradius	80	112

(e) UBIRIS V2

Parâmetro	Pupila	
	Contraída	Dilatada
lpupilradius	0	20
upupilradius	40	65
lirisradius	55	75
uirisradius	100	122

(b) UBIRIS V1

Parâmetro	Pupila	
	Contraída	Dilatada
lpupilradius	22	41
upupilradius	60	80
lirisradius	65	78
uirisradius	105	130

(d) CASIA V2

Parâmetro	Pupila	
	Contraída	Dilatada
lpupilradius	10	22
upupilradius	40	68
lirisradius	60	73
uirisradius	90	100

(f) CASIA-Iris-Distance

Tabela 18: Parâmetros do algoritmo de Masek para cada base de dados.

Resultados com a eliminação do ruído anatômico

Na Tabela 19 são apresentados os resultados obtidos com a aplicação do método proposto para eliminação do ruído nas amostras de íris da base de dados LAVI Iris Video DB2. Os resultados foram obtidos a partir do descritor LMP, e o mesmo conceito foi abordado para os demais descritores.

	20×240	30×360	40×480	50×600	60×720
Antes da metodologia	88,91%	92,94%	93,41%	93,08%	93,44%
Após aplicação do método	90,52%	94,44%	95,79%	95,88%	96,08%

(a) Amostras com pupila contraída e dilatada

	20×240	30×360	40×480	50×600	60×720
Antes da metodologia	87,35%	93,35%	95,64%	95,35%	95,23%
Após aplicação do método	93,94%	95,58%	97,29%	96,76%	96,82%

(b) Amostras com pupila contraída

	20×240	30×360	40×480	50×600	60×720
Antes da metodologia	88,29%	93,35%	95,64%	95,35%	95,17%
Após aplicação do método	92,82%	95,70%	96,79%	96,41%	96,76%

(c) Amostras com pupila dilatada

Tabela 19: Resultados obtidos antes/após aplicação da metodologia proposta para descarte do ruído anatômico.

Resultados com descritores circulares

Na Tabela 20 é apresentado os resultados obtidos com os descritores de textura LBP, LBP^{ri} , LBP^{riu2} , método de Daugman, sLMP e o LMP. A partir da metodologia proposta foram avaliados: o Subconjuntos-1 (Tabela 20c), o Subconjunto-2 (Tabela 20b) e o Subconjunto-3 (Tabela 20a). Nota-se que o método de Daugman apresenta melhores resultados com Subconjunto-2, e os descritores de textura circulares obtiveram melhores resultados com amostras com maiores resolução espacial. Além disso é possível observar que o descritor LBP básico supera os demais descritores avaliados com amostras do Subconjunto-1 e 3.

Método	PxR	20 × 240	30 × 360	40 × 480	50 × 600	60 × 720
Daugman	——	93,23%	93,41%	93,88%	94,00%	94,12%
LBP	——	95,32%	97,05%	97,14%	97,00%	96,94%
LMP	——	90,52%	94,44%	95,79%	95,88%	96,08%
LBP-ri	8 x 1	80,35%	89,44%	92,91%	95,02%	94,82%
LBP-ri	8 x 2	76,03%	85,67%	88,14%	90,11%	90,61%
LBP-riu2	8 x 1	70,64%	83,00%	88,38%	90,55%	91,85%
LBP-riu2	16 x 2	74,08%	85,05%	88,44%	89,70%	91,05%
sLMP	8 x 1	89,76%	94,58%	95,55%	95,94%	96,14%
sLMP	8 x 2	87,94%	94,08%	95,17%	95,85%	95,76%
sLMP	12 x 2	86,55%	93,26%	95,50%	95,82%	96,14%
sLMP	16 x 2	85,11%	91,67%	93,50%	94,11%	94,61%

(a) Amostras com pupila contraída e dilatada

Método	PxR	20 × 240	30 × 360	40 × 480	50 × 600	60 × 720
Daugman	——	99,07%	99,12%	99,20%	99,20%	99,23%
LBP	——	95,58%	97,58%	97,00%	97,29%	97,23%
LMP	——	93,94%	95,58%	97,29%	96,76%	96,82%
LBP-ri	8 x 1	42,73%	46,29%	47,20%	47,67%	47,47%
LBP-ri	8 x 2	41,67%	45,26%	46,00%	46,91%	46,26%
LBP-riu2	8 x 1	38,85%	43,91%	45,79%	45,79%	46,44%
LBP-riu2	16 x 2	39,85%	44,55%	45,52%	45,67%	46,05%
sLMP	8 x 1	91,70%	95,05%	95,88%	96,35%	96,23%
sLMP	8 x 2	91,76%	95,58%	95,47%	96,35%	96,58%
sLMP	12 x 2	90,35%	94,11%	96,47%	97,35%	97,58%
sLMP	16 x 2	88,70%	93,23%	94,29%	94,70%	94,94%

(b) Amostras com pupila contraída

Método	PxR	20 × 240	30 × 360	40 × 480	50 × 600	60 × 720
Daugman	——	95,97%	96,00%	96,12%	96,25%	96,43%
LBP	——	96,05%	97,35%	97,29%	97,35%	97,00%
LMP	——	92,82%	95,70%	96,79%	96,41%	96,76%
LBP-ri	8 x 1	41,05%	45,41%	46,88%	48,00%	47,79%
LBP-ri	8 x 2	40,79%	43,26%	44,58%	45,44%	46,26%
LBP-riu2	8 x 1	37,41%	43,17%	45,55%	46,47%	47,00%
LBP-riu2	16 x 2	39,35%	43,79%	44,94%	45,64%	46,17%
sLMP	8 x 1	90,94%	94,70%	96,17%	96,35%	96,70%
sLMP	8 x 2	88,52%	94,82%	95,47%	96,52%	96,52%
sLMP	12 x 2	87,64%	94,76%	96,41%	95,64%	96,52%
sLMP	16 x 2	85,64%	93,23%	94,88%	95,58%	96,29%

(c) Amostras com pupila dilatada

Tabela 20: Sensibilidade obtida pelos métodos avaliados.

Anexos

Especificação da base de dados

CASIA-Iris V2

A Tabela 21 apresenta as imagens selecionadas para os experimentos com a base de dados CASIA-Iris V2. No total foram selecionadas 600 imagens de íris do “dispositivo 2” da base de dados.

Tabela 21: Imagens selecionados a partir da base de dados CASIA-Iris V2

Arquivos de imagens				
0000_000.bmp	0000_002.bmp	0000_005.bmp	0000_007.bmp	0000_009.bmp
0000_011.bmp	0000_012.bmp	0000_015.bmp	0000_017.bmp	0000_019.bmp
0001_000.bmp	0001_002.bmp	0001_005.bmp	0001_007.bmp	0001_009.bmp
0001_011.bmp	0001_012.bmp	0001_015.bmp	0001_017.bmp	0001_019.bmp
0010_000.bmp	0010_002.bmp	0010_005.bmp	0010_007.bmp	0010_009.bmp
0010_011.bmp	0010_012.bmp	0010_015.bmp	0010_017.bmp	0010_019.bmp
0011_000.bmp	0011_002.bmp	0011_005.bmp	0011_007.bmp	0011_009.bmp
0011_011.bmp	0011_012.bmp	0011_015.bmp	0011_017.bmp	0011_019.bmp
0012_000.bmp	0012_002.bmp	0012_005.bmp	0012_007.bmp	0012_009.bmp
0012_011.bmp	0012_012.bmp	0012_015.bmp	0012_017.bmp	0012_019.bmp
0013_000.bmp	0013_002.bmp	0013_005.bmp	0013_007.bmp	0013_009.bmp
0013_011.bmp	0013_012.bmp	0013_015.bmp	0013_017.bmp	0013_019.bmp
0014_000.bmp	0014_002.bmp	0014_005.bmp	0014_007.bmp	0014_009.bmp
0014_011.bmp	0014_012.bmp	0014_015.bmp	0014_017.bmp	0014_019.bmp
0015_000.bmp	0015_002.bmp	0015_005.bmp	0015_007.bmp	0015_009.bmp
0015_011.bmp	0015_012.bmp	0015_015.bmp	0015_017.bmp	0015_019.bmp
0016_000.bmp	0016_002.bmp	0016_005.bmp	0016_007.bmp	0016_009.bmp
0016_011.bmp	0016_012.bmp	0016_015.bmp	0016_017.bmp	0016_019.bmp
0017_000.bmp	0017_002.bmp	0017_005.bmp	0017_007.bmp	0017_009.bmp
0017_011.bmp	0017_012.bmp	0017_015.bmp	0017_017.bmp	0017_019.bmp
0018_000.bmp	0018_002.bmp	0018_005.bmp	0018_007.bmp	0018_009.bmp
0018_011.bmp	0018_012.bmp	0018_015.bmp	0018_017.bmp	0018_019.bmp
0019_000.bmp	0019_002.bmp	0019_005.bmp	0019_007.bmp	0019_009.bmp
0019_011.bmp	0019_012.bmp	0019_015.bmp	0019_017.bmp	0019_019.bmp
0002_000.bmp	0002_002.bmp	0002_005.bmp	0002_007.bmp	0002_009.bmp
0002_011.bmp	0002_012.bmp	0002_015.bmp	0002_017.bmp	0002_019.bmp
0020_000.bmp	0020_002.bmp	0020_005.bmp	0020_007.bmp	0020_009.bmp
0020_011.bmp	0020_012.bmp	0020_015.bmp	0020_017.bmp	0020_019.bmp
0021_000.bmp	0021_002.bmp	0021_005.bmp	0021_007.bmp	0021_009.bmp
0021_011.bmp	0021_012.bmp	0021_015.bmp	0021_017.bmp	0021_019.bmp
0022_000.bmp	0022_002.bmp	0022_005.bmp	0022_007.bmp	0022_009.bmp
0022_011.bmp	0022_012.bmp	0022_015.bmp	0022_017.bmp	0022_019.bmp

[illegible]

0050_000.bmp	0050_002.bmp	0050_005.bmp	0050_007.bmp	0050_009.bmp
0050_011.bmp	0050_012.bmp	0050_015.bmp	0050_017.bmp	0050_019.bmp
0051_000.bmp	0051_002.bmp	0051_005.bmp	0051_007.bmp	0051_009.bmp
0051_011.bmp	0051_012.bmp	0051_015.bmp	0051_017.bmp	0051_019.bmp
0052_000.bmp	0052_002.bmp	0052_005.bmp	0052_007.bmp	0052_009.bmp
0052_011.bmp	0052_012.bmp	0052_015.bmp	0052_017.bmp	0052_019.bmp
0053_000.bmp	0053_002.bmp	0053_005.bmp	0053_007.bmp	0053_009.bmp
0053_011.bmp	0053_012.bmp	0053_015.bmp	0053_017.bmp	0053_019.bmp
0054_000.bmp	0054_002.bmp	0054_005.bmp	0054_007.bmp	0054_009.bmp
0054_011.bmp	0054_012.bmp	0054_015.bmp	0054_017.bmp	0054_019.bmp
0055_000.bmp	0055_002.bmp	0055_005.bmp	0055_007.bmp	0055_009.bmp
0055_011.bmp	0055_012.bmp	0055_015.bmp	0055_017.bmp	0055_019.bmp
0056_000.bmp	0056_002.bmp	0056_005.bmp	0056_007.bmp	0056_009.bmp
0056_011.bmp	0056_012.bmp	0056_015.bmp	0056_017.bmp	0056_019.bmp
0057_000.bmp	0057_002.bmp	0057_005.bmp	0057_007.bmp	0057_009.bmp
0057_011.bmp	0057_012.bmp	0057_015.bmp	0057_017.bmp	0057_019.bmp
0058_000.bmp	0058_002.bmp	0058_005.bmp	0058_007.bmp	0058_009.bmp
0058_011.bmp	0058_012.bmp	0058_015.bmp	0058_017.bmp	0058_019.bmp
0059_000.bmp	0059_002.bmp	0059_005.bmp	0059_007.bmp	0059_009.bmp
0059_011.bmp	0059_012.bmp	0059_015.bmp	0059_017.bmp	0059_019.bmp
0006_000.bmp	0006_002.bmp	0006_005.bmp	0006_007.bmp	0006_009.bmp
0006_011.bmp	0006_012.bmp	0006_015.bmp	0006_017.bmp	0006_019.bmp
0007_000.bmp	0007_002.bmp	0007_005.bmp	0007_007.bmp	0007_009.bmp
0007_011.bmp	0007_012.bmp	0007_015.bmp	0007_017.bmp	0007_019.bmp
0008_000.bmp	0008_002.bmp	0008_005.bmp	0008_007.bmp	0008_009.bmp
0008_011.bmp	0008_012.bmp	0008_015.bmp	0008_017.bmp	0008_019.bmp
0009_000.bmp	0009_002.bmp	0009_005.bmp	0009_007.bmp	0009_009.bmp
0009_011.bmp	0009_012.bmp	0009_015.bmp	0009_017.bmp	0009_019.bmp

Especificação da base de dados ND-Iris-Template-Aging-2008–2010

A Tabela 22 apresenta a relação completa das imagens selecionadas para os experimentos a partir da base de dados Notre Dame ND-Iris-Template-Aging-2008–2010. No geral, foram selecionadas 780 amostras de íris, distribuídas entre as sessões do ano de 2008 e 2009.

Tabela 22: Imagens selecionados a partir da base de dados Notre Dame ND-Iris-Template-Aging-2008–2010

Arquivos de imagens				
04233d1712.tiff	04233d1714.tiff	04233d1716.tiff	04233d2131.tiff	04233d2133.tiff
04233d2135.tiff	04327d1296.tiff	04327d1298.tiff	04327d1300.tiff	04327d1659.tiff
04327d1661.tiff	04327d1663.tiff	04385d1434.tiff	04385d1436.tiff	04385d1438.tiff
04385d1805.tiff	04385d1807.tiff	04385d1809.tiff	04394d1542.tiff	04394d1544.tiff
04394d1546.tiff	04394d1959.tiff	04394d1961.tiff	04394d1963.tiff	04397d1460.tiff
04397d1462.tiff	04397d1464.tiff	04397d1850.tiff	04397d1852.tiff	04397d1854.tiff
04470d1530.tiff	04470d1532.tiff	04470d1534.tiff	04470d1991.tiff	04470d1993.tiff
04470d1995.tiff	04537d1374.tiff	04537d1376.tiff	04537d1378.tiff	04537d1573.tiff
04537d1575.tiff	04537d1577.tiff	05015d220.tiff	05015d222.tiff	05015d224.tiff
05015d646.tiff	05015d648.tiff	05015d650.tiff	05028d1017.tiff	05028d1019.tiff
05028d1021.tiff	05028d605.tiff	05028d607.tiff	05028d609.tiff	05033d1168.tiff
05033d1170.tiff	05033d1172.tiff	05033d701.tiff	05033d703.tiff	05033d705.tiff
05176d352.tiff	05176d354.tiff	05176d356.tiff	05176d740.tiff	05176d742.tiff
05176d744.tiff	05244d402.tiff	05244d404.tiff	05244d406.tiff	05244d797.tiff
05244d799.tiff	05244d801.tiff	05248d439.tiff	05248d441.tiff	05248d443.tiff
05248d792.tiff	05248d794.tiff	05248d796.tiff	05284d205.tiff	05284d207.tiff
05284d209.tiff	05284d644.tiff	05284d646.tiff	05284d648.tiff	05298d332.tiff
05298d334.tiff	05298d336.tiff	05298d46.tiff	05298d48.tiff	05298d50.tiff
05301d179.tiff	05301d181.tiff	05301d183.tiff	05301d533.tiff	05301d535.tiff
05301d537.tiff	05304d118.tiff	05304d120.tiff	05304d123.tiff	05304d440.tiff
05304d442.tiff	05304d444.tiff	05305d112.tiff	05305d114.tiff	05305d116.tiff
05305d386.tiff	05305d388.tiff	05305d390.tiff	05306d472.tiff	05306d474.tiff
05306d476.tiff	05306d88.tiff	05306d90.tiff	05306d92.tiff	05308d229.tiff
05308d230.tiff	05308d231.tiff	05308d75.tiff	05308d77.tiff	05308d79.tiff
05310d418.tiff	05310d420.tiff	05310d422.tiff	05310d91.tiff	05310d93.tiff
05310d95.tiff	05314d150.tiff	05314d152.tiff	05314d154.tiff	05314d562.tiff
05314d564.tiff	05314d566.tiff	05315d542.tiff	05315d544.tiff	05315d546.tiff
05315d76.tiff	05315d78.tiff	05315d80.tiff	05317d462.tiff	05317d464.tiff
05317d466.tiff	05317d93.tiff	05317d95.tiff	05317d97.tiff	05321d142.tiff

05321d144.tiff	05321d146.tiff	05321d536.tiff	05321d538.tiff	05321d540.tiff
05337d133.tiff	05337d135.tiff	05337d137.tiff	05337d434.tiff	05337d436.tiff
05337d438.tiff	05344d107.tiff	05344d109.tiff	05344d111.tiff	05344d408.tiff
05344d410.tiff	05344d412.tiff	05366d434.tiff	05366d436.tiff	05366d438.tiff
05366d77.tiff	05366d79.tiff	05366d81.tiff	05399d117.tiff	05399d119.tiff
05399d121.tiff	05399d456.tiff	05399d458.tiff	05399d460.tiff	05406d130.tiff
05406d132.tiff	05406d134.tiff	05406d464.tiff	05406d466.tiff	05406d468.tiff
05407d174.tiff	05407d176.tiff	05407d178.tiff	05407d486.tiff	05407d488.tiff
05407d490.tiff	05415d152.tiff	05415d154.tiff	05415d156.tiff	05415d548.tiff
05415d550.tiff	05415d552.tiff	05432d102.tiff	05432d104.tiff	05432d106.tiff
05432d424.tiff	05432d426.tiff	05432d428.tiff	05442d112.tiff	05442d114.tiff
05442d116.tiff	05442d387.tiff	05442d389.tiff	05442d391.tiff	05450d115.tiff
05450d117.tiff	05450d119.tiff	05450d535.tiff	05450d537.tiff	05450d539.tiff
05456d498.tiff	05456d500.tiff	05456d502.tiff	05456d59.tiff	05456d61.tiff
05456d63.tiff	05459d24.tiff	05459d26.tiff	05459d28.tiff	05459d368.tiff
05459d370.tiff	05459d372.tiff	05460d332.tiff	05460d334.tiff	05460d336.tiff
05460d93.tiff	05460d95.tiff	05460d97.tiff	05463d452.tiff	05463d454.tiff
05463d456.tiff	05463d89.tiff	05463d91.tiff	05463d93.tiff	05465d119.tiff
05465d121.tiff	05465d123.tiff	05465d525.tiff	05465d527.tiff	05465d529.tiff
05477d432.tiff	05477d434.tiff	05477d436.tiff	05477d64.tiff	05477d66.tiff
05477d68.tiff	05478d391.tiff	05478d393.tiff	05478d395.tiff	05478d57.tiff
05478d59.tiff	05478d61.tiff	05481d407.tiff	05481d409.tiff	05481d411.tiff
05481d49.tiff	05481d51.tiff	05481d53.tiff	05482d364.tiff	05482d366.tiff
05482d368.tiff	05482d39.tiff	05482d41.tiff	05482d43.tiff	05484d281.tiff
05484d283.tiff	05484d285.tiff	05484d83.tiff	05484d85.tiff	05484d87.tiff
05490d432.tiff	05490d434.tiff	05490d436.tiff	05490d52.tiff	05490d54.tiff
05490d56.tiff	05491d32.tiff	05491d34.tiff	05491d354.tiff	05491d356.tiff
05491d358.tiff	05491d36.tiff	05493d366.tiff	05493d368.tiff	05493d370.tiff
05493d64.tiff	05493d66.tiff	05493d68.tiff	05496d500.tiff	05496d502.tiff
05496d504.tiff	05496d75.tiff	05496d77.tiff	05496d79.tiff	05498d179.tiff
05498d181.tiff	05498d183.tiff	05498d262.tiff	05498d264.tiff	05498d266.tiff
05500d393.tiff	05500d395.tiff	05500d397.tiff	05500d52.tiff	05500d54.tiff
05500d56.tiff	05501d384.tiff	05501d386.tiff	05501d388.tiff	05501d65.tiff
05501d67.tiff	05501d69.tiff	05502d490.tiff	05502d492.tiff	05502d494.tiff
05502d64.tiff	05502d66.tiff	05502d68.tiff	05504d25.tiff	05504d27.tiff
05504d29.tiff	05504d360.tiff	05504d362.tiff	05504d364.tiff	05505d203.tiff
05505d205.tiff	05505d207.tiff	05505d25.tiff	05505d27.tiff	05505d29.tiff
05510d329.tiff	05510d331.tiff	05510d333.tiff	05510d35.tiff	05510d37.tiff
05510d39.tiff	05511d491.tiff	05511d493.tiff	05511d495.tiff	05511d62.tiff
05511d64.tiff	05511d66.tiff	05512d402.tiff	05512d404.tiff	05512d406.tiff
05512d50.tiff	05512d52.tiff	05512d54.tiff	05518d392.tiff	05518d394.tiff
05518d396.tiff	05518d460.tiff	05518d462.tiff	05518d464.tiff	05524d216.tiff
05524d218.tiff	05524d220.tiff	05524d279.tiff	05524d281.tiff	05524d283.tiff
05526d174.tiff	05526d176.tiff	05526d178.tiff	05526d239.tiff	05526d241.tiff
05526d242.tiff	05530d310.tiff	05530d312.tiff	05530d314.tiff	05530d374.tiff
05530d376.tiff	05530d378.tiff	05531d359.tiff	05531d361.tiff	05531d363.tiff
05531d429.tiff	05531d431.tiff	05531d433.tiff	05540d368.tiff	05540d370.tiff
05540d372.tiff	05540d432.tiff	05540d434.tiff	05540d436.tiff	05542d184.tiff
05542d186.tiff	05542d188.tiff	05542d376.tiff	05542d378.tiff	05542d380.tiff
05555d179.tiff	05555d181.tiff	05555d183.tiff	05555d362.tiff	05555d364.tiff
05555d366.tiff	05559d184.tiff	05559d186.tiff	05559d188.tiff	05559d358.tiff
05559d360.tiff	05559d362.tiff	05565d271.tiff	05565d273.tiff	05565d275.tiff
05565d335.tiff	05565d337.tiff	05565d339.tiff	05582d237.tiff	05582d239.tiff
05582d241.tiff	05582d293.tiff	05582d295.tiff	05582d297.tiff	05585d142.tiff
05585d144.tiff	05585d146.tiff	05585d33.tiff	05585d35.tiff	05585d37.tiff
05594d157.tiff	05594d159.tiff	05594d161.tiff	05594d348.tiff	05594d350.tiff
05594d352.tiff	05596d146.tiff	05596d148.tiff	05596d150.tiff	05596d322.tiff
05596d324.tiff	05596d326.tiff	05597d248.tiff	05597d250.tiff	05597d252.tiff
05597d85.tiff	05597d87.tiff	05597d89.tiff	05601d309.tiff	05601d311.tiff
05601d313.tiff	05601d375.tiff	05601d377.tiff	05601d379.tiff	05603d278.tiff

05603d280.tiff	05603d282.tiff	05603d344.tiff	05603d346.tiff	05603d348.tiff
05608d152.tiff	05608d154.tiff	05608d156.tiff	05608d354.tiff	05608d356.tiff
05608d358.tiff	05615d273.tiff	05615d275.tiff	05615d277.tiff	05615d337.tiff
05615d339.tiff	05615d341.tiff	05616d293.tiff	05616d295.tiff	05616d297.tiff
05616d358.tiff	05616d360.tiff	05616d362.tiff	05618d280.tiff	05618d282.tiff
05618d284.tiff	05618d346.tiff	05618d348.tiff	05618d350.tiff	05619d287.tiff
05619d289.tiff	05619d291.tiff	05619d352.tiff	05619d354.tiff	05619d356.tiff
05626d238.tiff	05626d240.tiff	05626d242.tiff	05626d302.tiff	05626d304.tiff
05626d306.tiff	05629d165.tiff	05629d167.tiff	05629d169.tiff	05629d350.tiff
05629d352.tiff	05629d354.tiff	05630d227.tiff	05630d229.tiff	05630d231.tiff
05630d291.tiff	05630d293.tiff	05630d295.tiff	05634d147.tiff	05634d149.tiff
05634d151.tiff	05634d213.tiff	05634d215.tiff	05634d217.tiff	05635d277.tiff
05635d279.tiff	05635d281.tiff	05635d345.tiff	05635d347.tiff	05635d349.tiff
05636d278.tiff	05636d280.tiff	05636d282.tiff	05636d343.tiff	05636d345.tiff
05636d347.tiff	05637d123.tiff	05637d125.tiff	05637d127.tiff	05637d273.tiff
05637d275.tiff	05637d277.tiff	05645d146.tiff	05645d148.tiff	05645d150.tiff
05645d342.tiff	05645d344.tiff	05645d346.tiff	05650d226.tiff	05650d228.tiff
05650d230.tiff	05650d290.tiff	05650d292.tiff	05650d294.tiff	05651d146.tiff
05651d148.tiff	05651d150.tiff	05651d210.tiff	05651d212.tiff	05651d463.tiff
05652d176.tiff	05652d178.tiff	05652d180.tiff	05652d61.tiff	05652d63.tiff
05652d65.tiff	05653d233.tiff	05653d235.tiff	05653d237.tiff	05653d316.tiff
05653d318.tiff	05653d320.tiff	05655d121.tiff	05655d123.tiff	05655d125.tiff
05655d292.tiff	05655d294.tiff	05655d296.tiff	05656d122.tiff	05656d124.tiff
05656d126.tiff	05656d291.tiff	05656d293.tiff	05656d295.tiff	05658d164.tiff
05658d166.tiff	05658d32.tiff	05658d34.tiff	05658d36.tiff	05658d677.tiff
05663d238.tiff	05663d240.tiff	05663d242.tiff	05663d300.tiff	05663d302.tiff
05663d304.tiff	05669d242.tiff	05669d244.tiff	05669d246.tiff	05669d306.tiff
05669d308.tiff	05669d310.tiff	05670d122.tiff	05670d124.tiff	05670d126.tiff
05670d301.tiff	05670d303.tiff	05670d305.tiff	05671d254.tiff	05671d256.tiff
05671d258.tiff	05671d91.tiff	05671d93.tiff	05671d95.tiff	05672d104.tiff
05672d106.tiff	05672d108.tiff	05672d260.tiff	05672d262.tiff	05672d264.tiff
05673d205.tiff	05673d207.tiff	05673d209.tiff	05673d84.tiff	05673d86.tiff
05673d88.tiff	05674d250.tiff	05674d252.tiff	05674d254.tiff	05674d83.tiff
05674d85.tiff	05674d87.tiff	05675d231.tiff	05675d233.tiff	05675d235.tiff
05675d301.tiff	05675d303.tiff	05675d305.tiff	05678d238.tiff	05678d240.tiff
05678d242.tiff	05678d301.tiff	05678d303.tiff	05678d305.tiff	05681d117.tiff
05681d119.tiff	05681d121.tiff	05681d184.tiff	05681d186.tiff	05681d188.tiff
05682d191.tiff	05682d193.tiff	05682d195.tiff	05682d267.tiff	05682d269.tiff
05682d271.tiff	05695d194.tiff	05695d196.tiff	05695d198.tiff	05695d259.tiff
05695d261.tiff	05695d263.tiff	05696d235.tiff	05696d237.tiff	05696d239.tiff
05696d307.tiff	05696d309.tiff	05696d311.tiff	05697d256.tiff	05697d258.tiff
05697d260.tiff	05697d92.tiff	05697d94.tiff	05697d96.tiff	05712d204.tiff
05712d206.tiff	05712d237.tiff	05712d56.tiff	05712d58.tiff	05712d60.tiff
05713d171.tiff	05713d173.tiff	05713d175.tiff	05713d61.tiff	05713d63.tiff
05713d65.tiff	05714d149.tiff	05714d151.tiff	05714d153.tiff	05714d214.tiff
05714d216.tiff	05714d218.tiff	05723d151.tiff	05723d153.tiff	05723d155.tiff
05723d90.tiff	05723d92.tiff	05723d94.tiff	05733d152.tiff	05733d154.tiff
05733d156.tiff	05733d32.tiff	05733d34.tiff	05733d36.tiff	05734d107.tiff
05734d109.tiff	05734d111.tiff	05734d172.tiff	05734d174.tiff	05734d176.tiff
05735d142.tiff	05735d144.tiff	05735d146.tiff	05735d82.tiff	05735d84.tiff
05735d86.tiff	05740d190.tiff	05740d192.tiff	05740d194.tiff	05740d32.tiff
05740d34.tiff	05740d36.tiff	05749d177.tiff	05749d179.tiff	05749d181.tiff
05749d32.tiff	05749d34.tiff	05749d36.tiff	05751d127.tiff	05751d129.tiff
05751d131.tiff	05751d61.tiff	05751d63.tiff	05751d65.tiff	05757d129.tiff
05757d131.tiff	05757d133.tiff	05757d63.tiff	05757d65.tiff	05757d67.tiff
05761d125.tiff	05761d127.tiff	05761d129.tiff	05761d2.tiff	05761d4.tiff
05761d6.tiff	05763d136.tiff	05763d138.tiff	05763d140.tiff	05763d2.tiff
05763d4.tiff	05763d6.tiff	05764d129.tiff	05764d131.tiff	05764d133.tiff
05764d2.tiff	05764d4.tiff	05764d6.tiff	05766d145.tiff	05766d147.tiff
05766d149.tiff	05766d2.tiff	05766d4.tiff	05766d6.tiff	05768d119.tiff

05768d121.tiff	05768d123.tiff	05768d2.tiff	05768d4.tiff	05768d6.tiff
05770d100.tiff	05770d102.tiff	05770d2.tiff	05770d4.tiff	05770d6.tiff
05770d98.tiff	05774d141.tiff	05774d143.tiff	05774d145.tiff	05774d2.tiff
05774d4.tiff	05774d6.tiff	05775d119.tiff	05775d121.tiff	05775d123.tiff
05775d2.tiff	05775d4.tiff	05775d6.tiff	05783d118.tiff	05783d120.tiff
05783d122.tiff	05783d2.tiff	05783d4.tiff	05783d6.tiff	05791d100.tiff
05791d102.tiff	05791d2.tiff	05791d4.tiff	05791d6.tiff	05791d98.tiff

Especificação da base UBIRIS V1

A Tabela 23 apresenta a identificação de cada imagem selecionada para a realização dos experimentos com a base de dados UBIRIS V1. No Total foram selecionadas 720 imagens de íris da base de dados, divididas em 144 classes.

Tabela 23: Imagens selecionados a partir da base de dados UBIRIS V1

Arquivos de imagens				
Img_1_1_1.jpg	Img_1_1_2.jpg	Img_1_1_3.jpg	Img_1_1_4.jpg	Img_1_1_5.jpg
Img_2_1_1.jpg	Img_2_1_2.jpg	Img_2_1_3.jpg	Img_2_1_4.jpg	Img_2_1_5.jpg
Img_3_1_1.jpg	Img_3_1_2.jpg	Img_3_1_3.jpg	Img_3_1_4.jpg	Img_3_1_5.jpg
Img_4_1_1.jpg	Img_4_1_2.jpg	Img_4_1_3.jpg	Img_4_1_4.jpg	Img_4_1_5.jpg
Img_5_1_1.jpg	Img_5_1_2.jpg	Img_5_1_3.jpg	Img_5_1_4.jpg	Img_5_1_5.jpg
Img_6_1_1.jpg	Img_6_1_2.jpg	Img_6_1_3.jpg	Img_6_1_4.jpg	Img_6_1_5.jpg
Img_7_1_1.jpg	Img_7_1_2.jpg	Img_7_1_3.jpg	Img_7_1_4.jpg	Img_7_1_5.jpg
Img_8_1_1.jpg	Img_8_1_2.jpg	Img_8_1_3.jpg	Img_8_1_4.jpg	Img_8_1_5.jpg
Img_9_1_1.jpg	Img_9_1_2.jpg	Img_9_1_3.jpg	Img_9_1_4.jpg	Img_9_1_5.jpg
Img_10_1_1.jpg	Img_10_1_2.jpg	Img_10_1_3.jpg	Img_10_1_4.jpg	Img_10_1_5.jpg
Img_11_1_1.jpg	Img_11_1_2.jpg	Img_11_1_3.jpg	Img_11_1_4.jpg	Img_11_1_5.jpg
Img_12_1_1.jpg	Img_12_1_2.jpg	Img_12_1_3.jpg	Img_12_1_4.jpg	Img_12_1_5.jpg
Img_13_1_1.jpg	Img_13_1_2.jpg	Img_13_1_3.jpg	Img_13_1_4.jpg	Img_13_1_5.jpg
Img_14_1_1.jpg	Img_14_1_2.jpg	Img_14_1_3.jpg	Img_14_1_4.jpg	Img_14_1_5.jpg
Img_15_1_1.jpg	Img_15_1_2.jpg	Img_15_1_3.jpg	Img_15_1_4.jpg	Img_15_1_5.jpg
Img_16_1_1.jpg	Img_16_1_2.jpg	Img_16_1_3.jpg	Img_16_1_4.jpg	Img_16_1_5.jpg
Img_17_1_1.jpg	Img_17_1_2.jpg	Img_17_1_3.jpg	Img_17_1_4.jpg	Img_17_1_5.jpg
Img_18_1_1.jpg	Img_18_1_2.jpg	Img_18_1_3.jpg	Img_18_1_4.jpg	Img_18_1_5.jpg
Img_19_1_1.jpg	Img_19_1_2.jpg	Img_19_1_3.jpg	Img_19_1_4.jpg	Img_19_1_5.jpg
Img_20_1_1.jpg	Img_20_1_2.jpg	Img_20_1_3.jpg	Img_20_1_4.jpg	Img_20_1_5.jpg
Img_21_1_1.jpg	Img_21_1_2.jpg	Img_21_1_3.jpg	Img_21_1_4.jpg	Img_21_1_5.jpg
Img_22_1_1.jpg	Img_22_1_2.jpg	Img_22_1_3.jpg	Img_22_1_4.jpg	Img_22_1_5.jpg
Img_23_1_1.jpg	Img_23_1_2.jpg	Img_23_1_3.jpg	Img_23_1_4.jpg	Img_23_1_5.jpg
Img_24_1_1.jpg	Img_24_1_2.jpg	Img_24_1_3.jpg	Img_24_1_4.jpg	Img_24_1_5.jpg
Img_25_1_1.jpg	Img_25_1_2.jpg	Img_25_1_3.jpg	Img_25_1_4.jpg	Img_25_1_5.jpg
Img_26_1_1.jpg	Img_26_1_2.jpg	Img_26_1_3.jpg	Img_26_1_4.jpg	Img_26_1_5.jpg
Img_27_1_1.jpg	Img_27_1_2.jpg	Img_27_1_3.jpg	Img_27_1_4.jpg	Img_27_1_5.jpg
Img_28_1_1.jpg	Img_28_1_2.jpg	Img_28_1_3.jpg	Img_28_1_4.jpg	Img_28_1_5.jpg
Img_29_1_1.jpg	Img_29_1_2.jpg	Img_29_1_3.jpg	Img_29_1_4.jpg	Img_29_1_5.jpg
Img_30_1_1.jpg	Img_30_1_2.jpg	Img_30_1_3.jpg	Img_30_1_4.jpg	Img_30_1_5.jpg
Img_31_1_1.jpg	Img_31_1_2.jpg	Img_31_1_3.jpg	Img_31_1_4.jpg	Img_31_1_5.jpg
Img_32_1_1.jpg	Img_32_1_2.jpg	Img_32_1_3.jpg	Img_32_1_4.jpg	Img_32_1_5.jpg
Img_33_1_1.jpg	Img_33_1_2.jpg	Img_33_1_3.jpg	Img_33_1_4.jpg	Img_33_1_5.jpg
Img_34_1_1.jpg	Img_34_1_2.jpg	Img_34_1_3.jpg	Img_34_1_4.jpg	Img_34_1_5.jpg
Img_35_1_1.jpg	Img_35_1_2.jpg	Img_35_1_3.jpg	Img_35_1_4.jpg	Img_35_1_5.jpg

[illegible]

Img_96_1_1.jpg	Img_96_1_2.jpg	Img_96_1_3.jpg	Img_96_1_4.jpg	Img_96_1_5.jpg
Img_97_1_1.jpg	Img_97_1_2.jpg	Img_97_1_3.jpg	Img_97_1_4.jpg	Img_97_1_5.jpg
Img_98_1_1.jpg	Img_98_1_2.jpg	Img_98_1_3.jpg	Img_98_1_4.jpg	Img_98_1_5.jpg
Img_99_1_1.jpg	Img_99_1_2.jpg	Img_99_1_3.jpg	Img_99_1_4.jpg	Img_99_1_5.jpg
Img_100_1_1.jpg	Img_100_1_2.jpg	Img_100_1_3.jpg	Img_100_1_4.jpg	Img_100_1_5.jpg
Img_101_1_1.jpg	Img_101_1_2.jpg	Img_101_1_3.jpg	Img_101_1_4.jpg	Img_101_1_5.jpg
Img_102_1_1.jpg	Img_102_1_2.jpg	Img_102_1_3.jpg	Img_102_1_4.jpg	Img_102_1_5.jpg
Img_103_1_1.jpg	Img_103_1_2.jpg	Img_103_1_3.jpg	Img_103_1_4.jpg	Img_103_1_5.jpg
Img_104_1_1.jpg	Img_104_1_2.jpg	Img_104_1_3.jpg	Img_104_1_4.jpg	Img_104_1_5.jpg
Img_105_1_1.jpg	Img_105_1_2.jpg	Img_105_1_3.jpg	Img_105_1_4.jpg	Img_105_1_5.jpg
Img_106_1_1.jpg	Img_106_1_2.jpg	Img_106_1_3.jpg	Img_106_1_4.jpg	Img_106_1_5.jpg
Img_107_1_1.jpg	Img_107_1_2.jpg	Img_107_1_3.jpg	Img_107_1_4.jpg	Img_107_1_5.jpg
Img_108_1_1.jpg	Img_108_1_2.jpg	Img_108_1_3.jpg	Img_108_1_4.jpg	Img_108_1_5.jpg
Img_109_1_1.jpg	Img_109_1_2.jpg	Img_109_1_3.jpg	Img_109_1_4.jpg	Img_109_1_5.jpg
Img_110_1_1.jpg	Img_110_1_2.jpg	Img_110_1_3.jpg	Img_110_1_4.jpg	Img_110_1_5.jpg
Img_111_1_1.jpg	Img_111_1_2.jpg	Img_111_1_3.jpg	Img_111_1_4.jpg	Img_111_1_5.jpg
Img_112_1_1.jpg	Img_112_1_2.jpg	Img_112_1_3.jpg	Img_112_1_4.jpg	Img_112_1_5.jpg
Img_113_1_1.jpg	Img_113_1_2.jpg	Img_113_1_3.jpg	Img_113_1_4.jpg	Img_113_1_5.jpg
Img_114_1_1.jpg	Img_114_1_2.jpg	Img_114_1_3.jpg	Img_114_1_4.jpg	Img_114_1_5.jpg
Img_115_1_2.jpg	Img_115_1_3.jpg	Img_115_1_4.jpg	Img_115_1_5.jpg	Img_115_1_6.jpg
Img_116_1_1.jpg	Img_116_1_2.jpg	Img_116_1_3.jpg	Img_116_1_4.jpg	Img_116_1_5.jpg
Img_117_1_1.jpg	Img_117_1_2.jpg	Img_117_1_3.jpg	Img_117_1_4.jpg	Img_117_1_5.jpg
Img_118_1_1.jpg	Img_118_1_2.jpg	Img_118_1_3.jpg	Img_118_1_4.jpg	Img_118_1_5.jpg
Img_119_1_2.jpg	Img_119_1_3.jpg	Img_119_1_4.jpg	Img_119_1_5.jpg	Img_119_1_6.jpg
Img_120_1_1.jpg	Img_120_1_2.jpg	Img_120_1_3.jpg	Img_120_1_4.jpg	Img_120_1_5.jpg
Img_121_1_1.jpg	Img_121_1_2.jpg	Img_121_1_3.jpg	Img_121_1_4.jpg	Img_121_1_5.jpg
Img_122_1_1.jpg	Img_122_1_2.jpg	Img_122_1_3.jpg	Img_122_1_4.jpg	Img_122_1_5.jpg
Img_123_1_1.jpg	Img_123_1_2.jpg	Img_123_1_3.jpg	Img_123_1_4.jpg	Img_123_1_5.jpg
Img_124_1_1.jpg	Img_124_1_2.jpg	Img_124_1_3.jpg	Img_124_1_4.jpg	Img_124_1_5.jpg
Img_125_1_1.jpg	Img_125_1_2.jpg	Img_125_1_3.jpg	Img_125_1_4.jpg	Img_125_1_5.jpg
Img_126_1_1.jpg	Img_126_1_2.jpg	Img_126_1_3.jpg	Img_126_1_4.jpg	Img_126_1_5.jpg
Img_127_1_1.jpg	Img_127_1_2.jpg	Img_127_1_3.jpg	Img_127_1_4.jpg	Img_127_1_5.jpg
Img_128_1_1.jpg	Img_128_1_2.jpg	Img_128_1_3.jpg	Img_128_1_4.jpg	Img_128_1_5.jpg
Img_129_1_1.jpg	Img_129_1_2.jpg	Img_129_1_3.jpg	Img_129_1_4.jpg	Img_129_1_5.jpg
Img_130_1_1.jpg	Img_130_1_2.jpg	Img_130_1_3.jpg	Img_130_1_4.jpg	Img_130_1_5.jpg
Img_131_1_1.jpg	Img_131_1_2.jpg	Img_131_1_3.jpg	Img_131_1_4.jpg	Img_131_1_5.jpg
Img_132_1_2.jpg	Img_132_1_3.jpg	Img_132_1_4.jpg	Img_132_1_5.jpg	Img_132_1_6.jpg
Img_133_1_1.jpg	Img_133_1_2.jpg	Img_133_1_3.jpg	Img_133_1_4.jpg	Img_133_1_5.jpg
Img_134_1_1.jpg	Img_134_1_2.jpg	Img_134_1_3.jpg	Img_134_1_4.jpg	Img_134_1_5.jpg
Img_135_1_1.jpg	Img_135_1_2.jpg	Img_135_1_3.jpg	Img_135_1_4.jpg	Img_135_1_5.jpg
Img_136_1_1.jpg	Img_136_1_2.jpg	Img_136_1_3.jpg	Img_136_1_4.jpg	Img_136_1_5.jpg
Img_137_1_1.jpg	Img_137_1_2.jpg	Img_137_1_3.jpg	Img_137_1_4.jpg	Img_137_1_5.jpg
Img_138_1_1.jpg	Img_138_1_2.jpg	Img_138_1_3.jpg	Img_138_1_4.jpg	Img_138_1_5.jpg
Img_139_1_1.jpg	Img_139_1_2.jpg	Img_139_1_3.jpg	Img_139_1_4.jpg	Img_139_1_5.jpg
Img_140_1_1.jpg	Img_140_1_2.jpg	Img_140_1_3.jpg	Img_140_1_4.jpg	Img_140_1_5.jpg
Img_141_1_1.jpg	Img_141_1_2.jpg	Img_141_1_3.jpg	Img_141_1_4.jpg	Img_141_1_5.jpg
Img_142_1_1.jpg	Img_142_1_2.jpg	Img_142_1_3.jpg	Img_142_1_4.jpg	Img_142_1_5.jpg
Img_143_1_1.jpg	Img_143_1_2.jpg	Img_143_1_3.jpg	Img_143_1_4.jpg	Img_143_1_5.jpg
Img_144_1_1.jpg	Img_144_1_2.jpg	Img_144_1_3.jpg	Img_144_1_4.jpg	Img_144_1_5.jpg

Especificação da base UBIRIS V2

A Tabela 24 apresenta a identificação de cada imagem selecionada para a realização dos experimentos com a base de dados UBIRIS V2.

Tabela 24: Imagens selecionados a partir da base de dados UBIRIS V2

Arquivos de imagens				
C100_S1_I3.tiff	C100_S1_I4.tiff	C100_S1_I5.tiff	C100_S1_I7.tiff	C100_S1_I8.tiff
C100_S1_I9.tiff	C100_S2_I1.tiff	C100_S2_I2.tiff	C100_S2_I4.tiff	C100_S2_I5.tiff
C100_S2_I6.tiff	C100_S2_I9.tiff	C101_S1_I1.tiff	C101_S1_I4.tiff	C101_S1_I5.tiff
C101_S1_I6.tiff	C101_S1_I7.tiff	C101_S1_I8.tiff	C101_S2_I1.tiff	C101_S2_I10.tiff
C101_S2_I5.tiff	C101_S2_I7.tiff	C101_S2_I8.tiff	C101_S2_I9.tiff	C102_S1_I10.tiff
C102_S1_I4.tiff	C102_S1_I5.tiff	C102_S1_I7.tiff	C102_S1_I8.tiff	C102_S1_I9.tiff
C102_S2_I2.tiff	C102_S2_I4.tiff	C102_S2_I5.tiff	C102_S2_I6.tiff	C102_S2_I8.tiff
C102_S2_I9.tiff	C103_S1_I2.tiff	C103_S1_I3.tiff	C103_S1_I4.tiff	C103_S1_I5.tiff
C103_S1_I6.tiff	C103_S1_I7.tiff	C103_S2_I2.tiff	C103_S2_I4.tiff	C103_S2_I5.tiff
C103_S2_I6.tiff	C103_S2_I7.tiff	C103_S2_I8.tiff	C104_S1_I11.tiff	C104_S1_I12.tiff
C104_S1_I3.tiff	C104_S1_I4.tiff	C104_S1_I5.tiff	C104_S1_I8.tiff	C104_S2_I1.tiff
C104_S2_I2.tiff	C104_S2_I3.tiff	C104_S2_I4.tiff	C104_S2_I5.tiff	C104_S2_I6.tiff
C10_S1_I1.tiff	C10_S1_I2.tiff	C10_S1_I4.tiff	C10_S1_I5.tiff	C10_S1_I6.tiff
C10_S1_I7.tiff	C10_S2_I3.tiff	C10_S2_I4.tiff	C10_S2_I5.tiff	C10_S2_I6.tiff
C10_S2_I7.tiff	C10_S2_I8.tiff	C11_S1_I1.tiff	C11_S1_I2.tiff	C11_S1_I4.tiff
C11_S1_I5.tiff	C11_S1_I7.tiff	C11_S1_I8.tiff	C12_S1_I1.tiff	C12_S1_I3.tiff
C12_S1_I4.tiff	C12_S1_I5.tiff	C12_S1_I6.tiff	C12_S1_I7.tiff	C13_S1_I2.tiff
C13_S1_I3.tiff	C13_S1_I4.tiff	C13_S1_I5.tiff	C13_S1_I6.tiff	C13_S1_I7.tiff
C14_S1_I2.tiff	C14_S1_I3.tiff	C14_S1_I4.tiff	C14_S1_I5.tiff	C14_S1_I7.tiff
C14_S1_I8.tiff	C15_S1_I1.tiff	C15_S1_I3.tiff	C15_S1_I4.tiff	C15_S1_I5.tiff
C15_S1_I6.tiff	C15_S1_I7.tiff	C16_S1_I1.tiff	C16_S1_I2.tiff	C16_S1_I4.tiff
C16_S1_I5.tiff	C16_S1_I6.tiff	C16_S1_I7.tiff	C17_S1_I1.tiff	C17_S1_I2.tiff
C17_S1_I3.tiff	C17_S1_I4.tiff	C17_S1_I5.tiff	C17_S1_I6.tiff	C17_S2_I1.tiff
C17_S2_I4.tiff	C17_S2_I5.tiff	C17_S2_I7.tiff	C17_S2_I8.tiff	C17_S2_I9.tiff
C18_S1_I1.tiff	C18_S1_I4.tiff	C18_S1_I5.tiff	C18_S1_I6.tiff	C18_S1_I7.tiff
C18_S1_I8.tiff	C18_S2_I3.tiff	C18_S2_I4.tiff	C18_S2_I5.tiff	C18_S2_I7.tiff
C18_S2_I8.tiff	C18_S2_I9.tiff	C19_S1_I1.tiff	C19_S1_I2.tiff	C19_S1_I3.tiff
C19_S1_I4.tiff	C19_S1_I5.tiff	C19_S1_I6.tiff	C19_S2_I1.tiff	C19_S2_I2.tiff
C19_S2_I3.tiff	C19_S2_I4.tiff	C19_S2_I5.tiff	C19_S2_I6.tiff	C1_S1_I1.tiff
C1_S1_I2.tiff	C1_S1_I5.tiff	C1_S1_I6.tiff	C1_S1_I7.tiff	C1_S1_I8.tiff
C1_S2_I10.tiff	C1_S2_I11.tiff	C1_S2_I4.tiff	C1_S2_I5.tiff	C1_S2_I8.tiff
C1_S2_I9.tiff	C20_S1_I2.tiff	C20_S1_I4.tiff	C20_S1_I5.tiff	C20_S1_I6.tiff
C20_S1_I7.tiff	C20_S1_I8.tiff	C20_S2_I1.tiff	C20_S2_I2.tiff	C20_S2_I4.tiff
C20_S2_I5.tiff	C20_S2_I6.tiff	C20_S2_I7.tiff	C21_S1_I1.tiff	C21_S1_I2.tiff
C21_S1_I3.tiff	C21_S1_I4.tiff	C21_S1_I5.tiff	C21_S1_I6.tiff	C22_S1_I1.tiff
C22_S1_I2.tiff	C22_S1_I4.tiff	C22_S1_I5.tiff	C22_S1_I7.tiff	C22_S1_I8.tiff

C23_S1_I1.tiff	C23_S1_I2.tiff	C23_S1_I6.tiff	C23_S1_I7.tiff	C23_S1_I8.tiff
C23_S1_I9.tiff	C24_S1_I1.tiff	C24_S1_I2.tiff	C24_S1_I6.tiff	C24_S1_I7.tiff
C24_S1_I8.tiff	C24_S1_I9.tiff	C25_S1_I1.tiff	C25_S1_I3.tiff	C25_S1_I4.tiff
C25_S1_I5.tiff	C25_S1_I6.tiff	C25_S1_I8.tiff	C25_S2_I2.tiff	C25_S2_I3.tiff
C25_S2_I4.tiff	C25_S2_I5.tiff	C25_S2_I6.tiff	C25_S2_I7.tiff	C26_S1_I1.tiff
C26_S1_I2.tiff	C26_S1_I3.tiff	C26_S1_I4.tiff	C26_S1_I5.tiff	C26_S1_I6.tiff
C26_S2_I2.tiff	C26_S2_I3.tiff	C26_S2_I4.tiff	C26_S2_I5.tiff	C26_S2_I7.tiff
C26_S2_I8.tiff	C27_S1_I2.tiff	C27_S1_I3.tiff	C27_S1_I4.tiff	C27_S1_I5.tiff
C27_S1_I6.tiff	C27_S1_I7.tiff	C28_S1_I2.tiff	C28_S1_I4.tiff	C28_S1_I5.tiff
C28_S1_I6.tiff	C28_S1_I7.tiff	C28_S1_I8.tiff	C29_S1_I2.tiff	C29_S1_I4.tiff
C29_S1_I5.tiff	C29_S1_I7.tiff	C29_S1_I8.tiff	C29_S1_I9.tiff	C2_S1_I2.tiff
C2_S1_I4.tiff	C2_S1_I5.tiff	C2_S1_I6.tiff	C2_S1_I7.tiff	C2_S1_I8.tiff
C2_S2_I10.tiff	C2_S2_I11.tiff	C2_S2_I6.tiff	C2_S2_I7.tiff	C2_S2_I8.tiff
C2_S2_I9.tiff	C30_S1_I10.tiff	C30_S1_I11.tiff	C30_S1_I3.tiff	C30_S1_I5.tiff
C30_S1_I7.tiff	C30_S1_I8.tiff	C31_S1_I10.tiff	C31_S1_I5.tiff	C31_S1_I6.tiff
C31_S1_I7.tiff	C31_S1_I8.tiff	C31_S1_I9.tiff	C32_S1_I10.tiff	C32_S1_I4.tiff
C32_S1_I6.tiff	C32_S1_I7.tiff	C32_S1_I8.tiff	C32_S1_I9.tiff	C33_S1_I10.tiff
C33_S1_I11.tiff	C33_S1_I12.tiff	C33_S1_I15.tiff	C33_S1_I4.tiff	C33_S1_I8.tiff
C33_S2_I10.tiff	C33_S2_I11.tiff	C33_S2_I12.tiff	C33_S2_I7.tiff	C33_S2_I8.tiff
C33_S2_I9.tiff	C34_S1_I1.tiff	C34_S1_I4.tiff	C34_S1_I5.tiff	C34_S1_I6.tiff
C34_S1_I7.tiff	C34_S1_I8.tiff	C34_S2_I10.tiff	C34_S2_I11.tiff	C34_S2_I12.tiff
C34_S2_I14.tiff	C34_S2_I7.tiff	C34_S2_I9.tiff	C35_S1_I10.tiff	C35_S1_I5.tiff
C35_S1_I6.tiff	C35_S1_I7.tiff	C35_S1_I8.tiff	C35_S1_I9.tiff	C35_S2_I4.tiff
C35_S2_I5.tiff	C35_S2_I6.tiff	C35_S2_I7.tiff	C35_S2_I8.tiff	C35_S2_I9.tiff
C36_S1_I10.tiff	C36_S1_I11.tiff	C36_S1_I4.tiff	C36_S1_I5.tiff	C36_S1_I6.tiff
C36_S1_I9.tiff	C36_S2_I10.tiff	C36_S2_I11.tiff	C36_S2_I4.tiff	C36_S2_I5.tiff
C36_S2_I7.tiff	C36_S2_I9.tiff	C37_S1_I2.tiff	C37_S1_I4.tiff	C37_S1_I5.tiff
C37_S1_I7.tiff	C37_S1_I8.tiff	C37_S1_I9.tiff	C38_S1_I1.tiff	C38_S1_I3.tiff
C38_S1_I4.tiff	C38_S1_I5.tiff	C38_S1_I6.tiff	C38_S1_I7.tiff	C39_S1_I1.tiff
C39_S1_I2.tiff	C39_S1_I4.tiff	C39_S1_I5.tiff	C39_S1_I6.tiff	C39_S1_I7.tiff
C39_S2_I1.tiff	C39_S2_I4.tiff	C39_S2_I5.tiff	C39_S2_I7.tiff	C39_S2_I8.tiff
C39_S2_I9.tiff	C3_S1_I1.tiff	C3_S1_I2.tiff	C3_S1_I3.tiff	C3_S1_I4.tiff
C3_S1_I5.tiff	C3_S1_I6.tiff	C40_S1_I1.tiff	C40_S1_I2.tiff	C40_S1_I3.tiff
C40_S1_I4.tiff	C40_S1_I5.tiff	C40_S1_I6.tiff	C40_S2_I2.tiff	C40_S2_I4.tiff
C40_S2_I5.tiff	C40_S2_I7.tiff	C40_S2_I8.tiff	C40_S2_I9.tiff	C41_S1_I4.tiff
C41_S1_I5.tiff	C41_S1_I6.tiff	C41_S1_I7.tiff	C41_S1_I8.tiff	C41_S1_I9.tiff
C42_S1_I1.tiff	C42_S1_I3.tiff	C42_S1_I4.tiff	C42_S1_I5.tiff	C42_S1_I6.tiff
C42_S1_I7.tiff	C43_S1_I1.tiff	C43_S1_I2.tiff	C43_S1_I3.tiff	C43_S1_I4.tiff
C43_S1_I5.tiff	C43_S1_I6.tiff	C43_S2_I4.tiff	C43_S2_I5.tiff	C43_S2_I6.tiff
C43_S2_I7.tiff	C43_S2_I8.tiff	C43_S2_I9.tiff	C44_S1_I10.tiff	C44_S1_I11.tiff
C44_S1_I2.tiff	C44_S1_I5.tiff	C44_S1_I7.tiff	C44_S1_I9.tiff	C44_S2_I10.tiff
C44_S2_I11.tiff	C44_S2_I12.tiff	C44_S2_I7.tiff	C44_S2_I8.tiff	C44_S2_I9.tiff
C45_S1_I2.tiff	C45_S1_I4.tiff	C45_S1_I5.tiff	C45_S1_I7.tiff	C45_S1_I8.tiff
C45_S1_I9.tiff	C45_S2_I1.tiff	C45_S2_I2.tiff	C45_S2_I3.tiff	C45_S2_I4.tiff
C45_S2_I5.tiff	C45_S2_I8.tiff	C46_S1_I1.tiff	C46_S1_I2.tiff	C46_S1_I4.tiff
C46_S1_I5.tiff	C46_S1_I6.tiff	C46_S1_I7.tiff	C46_S2_I1.tiff	C46_S2_I2.tiff
C46_S2_I3.tiff	C46_S2_I4.tiff	C46_S2_I5.tiff	C46_S2_I6.tiff	C47_S1_I11.tiff
C47_S1_I12.tiff	C47_S1_I4.tiff	C47_S1_I7.tiff	C47_S1_I8.tiff	C47_S1_I9.tiff
C48_S1_I11.tiff	C48_S1_I4.tiff	C48_S1_I5.tiff	C48_S1_I7.tiff	C48_S1_I8.tiff
C48_S1_I9.tiff	C48_S2_I3.tiff	C48_S2_I4.tiff	C48_S2_I5.tiff	C48_S2_I6.tiff
C48_S2_I7.tiff	C48_S2_I8.tiff	C49_S1_I1.tiff	C49_S1_I3.tiff	C49_S1_I5.tiff
C49_S1_I6.tiff	C49_S1_I7.tiff	C49_S1_I9.tiff	C49_S2_I10.tiff	C49_S2_I11.tiff
C49_S2_I12.tiff	C49_S2_I7.tiff	C49_S2_I8.tiff	C49_S2_I9.tiff	C4_S1_I1.tiff
C4_S1_I2.tiff	C4_S1_I3.tiff	C4_S1_I4.tiff	C4_S1_I5.tiff	C4_S1_I6.tiff
C50_S1_I10.tiff	C50_S1_I11.tiff	C50_S1_I12.tiff	C50_S1_I7.tiff	C50_S1_I8.tiff
C50_S1_I9.tiff	C50_S2_I10.tiff	C50_S2_I11.tiff	C50_S2_I5.tiff	C50_S2_I7.tiff
C50_S2_I8.tiff	C50_S2_I9.tiff	C51_S1_I1.tiff	C51_S1_I11.tiff	C51_S1_I12.tiff
C51_S1_I5.tiff	C51_S1_I6.tiff	C51_S1_I8.tiff	C52_S1_I10.tiff	C52_S1_I11.tiff
C52_S1_I12.tiff	C52_S1_I2.tiff	C52_S1_I3.tiff	C52_S1_I8.tiff	C57_S1_I1.tiff
C57_S1_I4.tiff	C57_S1_I5.tiff	C57_S1_I7.tiff	C57_S1_I8.tiff	C57_S1_I9.tiff

C58_S1_I1.tiff	C58_S1_I4.tiff	C58_S1_I5.tiff	C58_S1_I7.tiff	C58_S1_I8.tiff
C58_S1_I9.tiff	C59_S1_I1.tiff	C59_S1_I2.tiff	C59_S1_I3.tiff	C59_S1_I4.tiff
C59_S1_I5.tiff	C59_S1_I6.tiff	C5_S1_I1.tiff	C5_S1_I2.tiff	C5_S1_I3.tiff
C5_S1_I4.tiff	C5_S1_I5.tiff	C5_S1_I6.tiff	C5_S2_I2.tiff	C5_S2_I4.tiff
C5_S2_I5.tiff	C5_S2_I7.tiff	C5_S2_I8.tiff	C5_S2_I9.tiff	C60_S1_I2.tiff
C60_S1_I3.tiff	C60_S1_I4.tiff	C60_S1_I5.tiff	C60_S1_I7.tiff	C60_S1_I8.tiff
C61_S1_I1.tiff	C61_S1_I4.tiff	C61_S1_I5.tiff	C61_S1_I6.tiff	C61_S1_I7.tiff
C61_S1_I8.tiff	C61_S2_I1.tiff	C61_S2_I3.tiff	C61_S2_I4.tiff	C61_S2_I5.tiff
C61_S2_I7.tiff	C61_S2_I8.tiff	C62_S1_I1.tiff	C62_S1_I4.tiff	C62_S1_I5.tiff
C62_S1_I6.tiff	C62_S1_I7.tiff	C62_S1_I8.tiff	C62_S2_I1.tiff	C62_S2_I4.tiff
C62_S2_I5.tiff	C62_S2_I6.tiff	C62_S2_I7.tiff	C62_S2_I8.tiff	C63_S1_I1.tiff
C63_S1_I2.tiff	C63_S1_I4.tiff	C63_S1_I5.tiff	C63_S1_I7.tiff	C63_S1_I8.tiff
C64_S1_I1.tiff	C64_S1_I2.tiff	C64_S1_I4.tiff	C64_S1_I5.tiff	C64_S1_I7.tiff
C64_S1_I8.tiff	C65_S1_I1.tiff	C65_S1_I2.tiff	C65_S1_I3.tiff	C65_S1_I4.tiff
C65_S1_I5.tiff	C65_S1_I6.tiff	C66_S1_I1.tiff	C66_S1_I2.tiff	C66_S1_I3.tiff
C66_S1_I4.tiff	C66_S1_I5.tiff	C66_S1_I6.tiff	C67_S1_I1.tiff	C67_S1_I3.tiff
C67_S1_I5.tiff	C67_S1_I6.tiff	C67_S1_I7.tiff	C67_S1_I8.tiff	C68_S1_I1.tiff
C68_S1_I10.tiff	C68_S1_I2.tiff	C68_S1_I7.tiff	C68_S1_I8.tiff	C68_S1_I9.tiff
C69_S1_I1.tiff	C69_S1_I2.tiff	C69_S1_I3.tiff	C69_S1_I5.tiff	C69_S1_I6.tiff
C69_S1_I7.tiff	C6_S1_I1.tiff	C6_S1_I2.tiff	C6_S1_I3.tiff	C6_S1_I4.tiff
C6_S1_I5.tiff	C6_S1_I7.tiff	C6_S2_I1.tiff	C6_S2_I10.tiff	C6_S2_I3.tiff
C6_S2_I6.tiff	C6_S2_I7.tiff	C6_S2_I8.tiff	C70_S1_I10.tiff	C70_S1_I2.tiff
C70_S1_I5.tiff	C70_S1_I7.tiff	C70_S1_I8.tiff	C70_S1_I9.tiff	C71_S1_I1.tiff
C71_S1_I10.tiff	C71_S1_I11.tiff	C71_S1_I12.tiff	C71_S1_I15.tiff	C71_S1_I7.tiff
C72_S1_I10.tiff	C72_S1_I11.tiff	C72_S1_I12.tiff	C72_S1_I14.tiff	C72_S1_I2.tiff
C72_S1_I5.tiff	C73_S1_I10.tiff	C73_S1_I11.tiff	C73_S1_I12.tiff	C73_S1_I4.tiff
C73_S1_I7.tiff	C73_S1_I9.tiff	C73_S2_I10.tiff	C73_S2_I2.tiff	C73_S2_I6.tiff
C73_S2_I7.tiff	C73_S2_I8.tiff	C73_S2_I9.tiff	C74_S1_I10.tiff	C74_S1_I11.tiff
C74_S1_I6.tiff	C74_S1_I7.tiff	C74_S1_I8.tiff	C74_S1_I9.tiff	C74_S2_I10.tiff
C74_S2_I11.tiff	C74_S2_I2.tiff	C74_S2_I7.tiff	C74_S2_I8.tiff	C74_S2_I9.tiff
C75_S1_I1.tiff	C75_S1_I3.tiff	C75_S1_I4.tiff	C75_S1_I5.tiff	C75_S1_I6.tiff
C75_S1_I7.tiff	C76_S1_I10.tiff	C76_S1_I4.tiff	C76_S1_I5.tiff	C76_S1_I7.tiff
C76_S1_I8.tiff	C76_S1_I9.tiff	C77_S1_I1.tiff	C77_S1_I2.tiff	C77_S1_I5.tiff
C77_S1_I6.tiff	C77_S1_I7.tiff	C77_S1_I8.tiff	C78_S1_I3.tiff	C78_S1_I4.tiff
C78_S1_I5.tiff	C78_S1_I6.tiff	C78_S1_I7.tiff	C78_S1_I8.tiff	C79_S1_I1.tiff
C79_S1_I2.tiff	C79_S1_I4.tiff	C79_S1_I5.tiff	C79_S1_I6.tiff	C79_S1_I7.tiff
C79_S2_I3.tiff	C79_S2_I4.tiff	C79_S2_I5.tiff	C79_S2_I7.tiff	C79_S2_I8.tiff
C79_S2_I9.tiff	C7_S1_I1.tiff	C7_S1_I2.tiff	C7_S1_I3.tiff	C7_S1_I4.tiff
C7_S1_I5.tiff	C7_S1_I6.tiff	C7_S2_I1.tiff	C7_S2_I5.tiff	C7_S2_I6.tiff
C7_S2_I7.tiff	C7_S2_I8.tiff	C7_S2_I9.tiff	C80_S1_I1.tiff	C80_S1_I3.tiff
C80_S1_I4.tiff	C80_S1_I5.tiff	C80_S1_I6.tiff	C80_S1_I7.tiff	C80_S2_I10.tiff
C80_S2_I2.tiff	C80_S2_I4.tiff	C80_S2_I7.tiff	C80_S2_I8.tiff	C80_S2_I9.tiff
C81_S1_I1.tiff	C81_S1_I2.tiff	C81_S1_I4.tiff	C81_S1_I5.tiff	C81_S1_I6.tiff
C81_S1_I7.tiff	C82_S1_I1.tiff	C82_S1_I4.tiff	C82_S1_I5.tiff	C82_S1_I7.tiff
C82_S1_I8.tiff	C82_S1_I9.tiff	C83_S1_I10.tiff	C83_S1_I11.tiff	C83_S1_I12.tiff
C83_S1_I4.tiff	C83_S1_I7.tiff	C83_S1_I9.tiff	C84_S1_I10.tiff	C84_S1_I11.tiff
C84_S1_I12.tiff	C84_S1_I2.tiff	C84_S1_I7.tiff	C84_S1_I8.tiff	C85_S1_I10.tiff
C85_S1_I2.tiff	C85_S1_I4.tiff	C85_S1_I5.tiff	C85_S1_I8.tiff	C85_S1_I9.tiff
C85_S2_I1.tiff	C85_S2_I2.tiff	C85_S2_I3.tiff	C85_S2_I4.tiff	C85_S2_I5.tiff
C85_S2_I6.tiff	C86_S1_I10.tiff	C86_S1_I11.tiff	C86_S1_I12.tiff	C86_S1_I4.tiff
C86_S1_I8.tiff	C86_S1_I9.tiff	C86_S2_I1.tiff	C86_S2_I3.tiff	C86_S2_I4.tiff
C86_S2_I5.tiff	C86_S2_I6.tiff	C86_S2_I7.tiff	C87_S1_I10.tiff	C87_S1_I11.tiff
C87_S1_I12.tiff	C87_S1_I14.tiff	C87_S1_I8.tiff	C87_S1_I9.tiff	C88_S1_I10.tiff
C88_S1_I11.tiff	C88_S1_I12.tiff	C88_S1_I4.tiff	C88_S1_I7.tiff	C88_S1_I8.tiff
C89_S1_I10.tiff	C89_S1_I11.tiff	C89_S1_I12.tiff	C89_S1_I14.tiff	C89_S1_I8.tiff
C89_S1_I9.tiff	C89_S2_I10.tiff	C89_S2_I11.tiff	C89_S2_I12.tiff	C89_S2_I7.tiff
C89_S2_I8.tiff	C89_S2_I9.tiff	C8_S1_I2.tiff	C8_S1_I4.tiff	C8_S1_I5.tiff
C8_S1_I6.tiff	C8_S1_I7.tiff	C8_S1_I8.tiff	C8_S2_I2.tiff	C8_S2_I4.tiff
C8_S2_I5.tiff	C8_S2_I6.tiff	C8_S2_I7.tiff	C8_S2_I8.tiff	C90_S1_I10.tiff
C90_S1_I11.tiff	C90_S1_I12.tiff	C90_S1_I7.tiff	C90_S1_I8.tiff	C90_S1_I9.tiff

C90_S2_I10.tiff	C90_S2_I11.tiff	C90_S2_I12.tiff	C90_S2_I13.tiff	C90_S2_I18.tiff
C90_S2_I9.tiff	C91_S1_I10.tiff	C91_S1_I11.tiff	C91_S1_I12.tiff	C91_S1_I7.tiff
C91_S1_I8.tiff	C91_S1_I9.tiff	C91_S2_I10.tiff	C91_S2_I11.tiff	C91_S2_I12.tiff
C91_S2_I5.tiff	C91_S2_I6.tiff	C91_S2_I8.tiff	C92_S1_I10.tiff	C92_S1_I11.tiff
C92_S1_I12.tiff	C92_S1_I7.tiff	C92_S1_I8.tiff	C92_S1_I9.tiff	C92_S2_I10.tiff
C92_S2_I11.tiff	C92_S2_I12.tiff	C92_S2_I6.tiff	C92_S2_I8.tiff	C92_S2_I9.tiff
C93_S1_I10.tiff	C93_S1_I11.tiff	C93_S1_I12.tiff	C93_S1_I13.tiff	C93_S1_I14.tiff
C93_S1_I15.tiff	C93_S2_I10.tiff	C93_S2_I11.tiff	C93_S2_I13.tiff	C93_S2_I14.tiff
C93_S2_I15.tiff	C93_S2_I9.tiff	C94_S1_I10.tiff	C94_S1_I11.tiff	C94_S1_I12.tiff
C94_S1_I13.tiff	C94_S1_I14.tiff	C94_S1_I9.tiff	C94_S2_I10.tiff	C94_S2_I11.tiff
C94_S2_I12.tiff	C94_S2_I13.tiff	C94_S2_I14.tiff	C94_S2_I15.tiff	C95_S2_I10.tiff
C95_S2_I11.tiff	C95_S2_I12.tiff	C95_S2_I13.tiff	C95_S2_I8.tiff	C95_S2_I9.tiff
C96_S2_I10.tiff	C96_S2_I11.tiff	C96_S2_I12.tiff	C96_S2_I14.tiff	C96_S2_I8.tiff
C96_S2_I9.tiff	C97_S1_I10.tiff	C97_S1_I11.tiff	C97_S1_I12.tiff	C97_S1_I14.tiff
C97_S1_I15.tiff	C97_S1_I9.tiff	C98_S1_I10.tiff	C98_S1_I11.tiff	C98_S1_I12.tiff
C98_S1_I7.tiff	C98_S1_I8.tiff	C98_S1_I9.tiff	C99_S1_I10.tiff	C99_S1_I11.tiff
C99_S1_I12.tiff	C99_S1_I14.tiff	C99_S1_I5.tiff	C99_S1_I7.tiff	C99_S2_I11.tiff
C99_S2_I12.tiff	C99_S2_I14.tiff	C99_S2_I5.tiff	C99_S2_I8.tiff	C99_S2_I9.tiff
C9_S1_I1.tiff	C9_S1_I3.tiff	C9_S1_I4.tiff	C9_S1_I6.tiff	C9_S1_I7.tiff
C9_S1_I9.tiff	C9_S2_I1.tiff	C9_S2_I2.tiff	C9_S2_I4.tiff	C9_S2_I5.tiff
C9_S2_I6.tiff	C9_S2_I7.tiff			

Especificação da base de dados CASIA-Iris-Distance

Todos os arquivos listados na Tabela 25 correspondem às imagens selecionadas para a realização dos experimentos com a base de dados CASIA-Iris-Distance.

Tabela 25: Imagens selecionados a partir da base de dados CASIA-Iris-Distance

Arquivos de imagens				
S4000D05.jpg	S4000D06.jpg	S4000D07.jpg	S4000D08.jpg	S4000D09.jpg
S4001D05.jpg	S4001D06.jpg	S4001D07.jpg	S4001D08.jpg	S4001D09.jpg
S4002D00.jpg	S4002D01.jpg	S4002D02.jpg	S4002D03.jpg	S4002D04.jpg
S4003D00.jpg	S4003D01.jpg	S4003D02.jpg	S4003D03.jpg	S4003D04.jpg
S4004D00.jpg	S4004D01.jpg	S4004D02.jpg	S4004D03.jpg	S4004D04.jpg
S4005D05.jpg	S4005D06.jpg	S4005D07.jpg	S4005D08.jpg	S4005D09.jpg
S4006D00.jpg	S4006D01.jpg	S4006D02.jpg	S4006D03.jpg	S4006D04.jpg
S4007D00.jpg	S4007D01.jpg	S4007D02.jpg	S4007D03.jpg	S4007D04.jpg
S4008D05.jpg	S4008D06.jpg	S4008D07.jpg	S4008D08.jpg	S4008D09.jpg
S4009D05.jpg	S4009D06.jpg	S4009D07.jpg	S4009D08.jpg	S4009D09.jpg
S4010D05.jpg	S4010D06.jpg	S4010D07.jpg	S4010D08.jpg	S4010D09.jpg
S4011D05.jpg	S4011D06.jpg	S4011D07.jpg	S4011D08.jpg	S4011D09.jpg
S4012D05.jpg	S4012D06.jpg	S4012D07.jpg	S4012D08.jpg	S4012D09.jpg
S4013D05.jpg	S4013D06.jpg	S4013D07.jpg	S4013D08.jpg	S4013D09.jpg
S4014D05.jpg	S4014D06.jpg	S4014D07.jpg	S4014D08.jpg	S4014D09.jpg
S4015D05.jpg	S4015D06.jpg	S4015D07.jpg	S4015D08.jpg	S4015D09.jpg
S4016D05.jpg	S4016D06.jpg	S4016D07.jpg	S4016D08.jpg	S4016D09.jpg
S4017D05.jpg	S4017D06.jpg	S4017D07.jpg	S4017D08.jpg	S4017D09.jpg
S4018D05.jpg	S4018D06.jpg	S4018D07.jpg	S4018D08.jpg	S4018D09.jpg
S4019D05.jpg	S4019D06.jpg	S4019D07.jpg	S4019D08.jpg	S4019D09.jpg
S4020D05.jpg	S4020D06.jpg	S4020D07.jpg	S4020D08.jpg	S4020D09.jpg
S4021D05.jpg	S4021D06.jpg	S4021D07.jpg	S4021D08.jpg	S4021D09.jpg
S4022D05.jpg	S4022D06.jpg	S4022D07.jpg	S4022D08.jpg	S4022D09.jpg
S4023D00.jpg	S4023D06.jpg	S4023D07.jpg	S4023D18.jpg	S4023D09.jpg
S4024D05.jpg	S4024D06.jpg	S4024D07.jpg	S4024D08.jpg	S4024D09.jpg
S4025D05.jpg	S4025D06.jpg	S4025D07.jpg	S4025D08.jpg	S4025D09.jpg
S4026D05.jpg	S4026D06.jpg	S4026D07.jpg	S4026D08.jpg	S4026D09.jpg
S4027D05.jpg	S4027D06.jpg	S4027D07.jpg	S4027D08.jpg	S4027D09.jpg
S4028D05.jpg	S4028D06.jpg	S4028D07.jpg	S4028D08.jpg	S4028D09.jpg
S4029D05.jpg	S4029D06.jpg	S4029D07.jpg	S4029D08.jpg	S4029D09.jpg
S4030D05.jpg	S4030D06.jpg	S4030D07.jpg	S4030D08.jpg	S4030D09.jpg
S4031D05.jpg	S4031D06.jpg	S4031D07.jpg	S4031D08.jpg	S4031D09.jpg
S4032D05.jpg	S4032D06.jpg	S4032D07.jpg	S4032D08.jpg	S4032D09.jpg

S4033D05.jpg	S4033D06.jpg	S4033D07.jpg	S4033D08.jpg	S4033D09.jpg
S4034D05.jpg	S4034D06.jpg	S4034D07.jpg	S4034D08.jpg	S4034D09.jpg
S4035D05.jpg	S4035D06.jpg	S4035D07.jpg	S4035D08.jpg	S4035D09.jpg
S4036D05.jpg	S4036D06.jpg	S4036D07.jpg	S4036D08.jpg	S4036D09.jpg
S4037D05.jpg	S4037D06.jpg	S4037D07.jpg	S4037D08.jpg	S4037D09.jpg
S4038D05.jpg	S4038D06.jpg	S4038D07.jpg	S4038D08.jpg	S4038D09.jpg
S4039D05.jpg	S4039D06.jpg	S4039D07.jpg	S4039D08.jpg	S4039D09.jpg
S4040D05.jpg	S4040D06.jpg	S4040D07.jpg	S4040D08.jpg	S4040D09.jpg
S4041D05.jpg	S4041D06.jpg	S4041D07.jpg	S4041D08.jpg	S4041D09.jpg
S4042D05.jpg	S4042D06.jpg	S4042D07.jpg	S4042D08.jpg	S4042D09.jpg
S4043D05.jpg	S4043D06.jpg	S4043D07.jpg	S4043D08.jpg	S4043D09.jpg
S4044D05.jpg	S4044D06.jpg	S4044D07.jpg	S4044D08.jpg	S4044D09.jpg
S4045D05.jpg	S4045D06.jpg	S4045D07.jpg	S4045D08.jpg	S4045D09.jpg
S4046D05.jpg	S4046D06.jpg	S4046D07.jpg	S4046D08.jpg	S4046D09.jpg
S4047D05.jpg	S4047D06.jpg	S4047D07.jpg	S4047D08.jpg	S4047D09.jpg
S4048D05.jpg	S4048D06.jpg	S4048D07.jpg	S4048D08.jpg	S4048D09.jpg
S4049D05.jpg	S4049D06.jpg	S4049D07.jpg	S4049D08.jpg	S4049D09.jpg
S4050D05.jpg	S4050D06.jpg	S4050D07.jpg	S4050D08.jpg	S4050D09.jpg
S4051D05.jpg	S4051D06.jpg	S4051D07.jpg	S4051D08.jpg	S4051D09.jpg
S4052D05.jpg	S4052D06.jpg	S4052D07.jpg	S4052D08.jpg	S4052D09.jpg
S4053D05.jpg	S4053D06.jpg	S4053D07.jpg	S4053D08.jpg	S4053D09.jpg
S4054D05.jpg	S4054D06.jpg	S4054D07.jpg	S4054D08.jpg	S4054D09.jpg
S4055D05.jpg	S4055D06.jpg	S4055D07.jpg	S4055D08.jpg	S4055D09.jpg
S4056D05.jpg	S4056D06.jpg	S4056D07.jpg	S4056D08.jpg	S4056D09.jpg
S4057D05.jpg	S4057D06.jpg	S4057D07.jpg	S4057D08.jpg	S4057D09.jpg
S4058D05.jpg	S4058D06.jpg	S4058D07.jpg	S4058D08.jpg	S4058D09.jpg
S4059D05.jpg	S4059D06.jpg	S4059D07.jpg	S4059D08.jpg	S4059D09.jpg
S4060D05.jpg	S4060D06.jpg	S4060D07.jpg	S4060D08.jpg	S4060D09.jpg
S4061D05.jpg	S4061D06.jpg	S4061D07.jpg	S4061D08.jpg	S4061D09.jpg
S4062D05.jpg	S4062D06.jpg	S4062D07.jpg	S4062D08.jpg	S4062D09.jpg
S4063D05.jpg	S4063D06.jpg	S4063D07.jpg	S4063D08.jpg	S4063D09.jpg
S4064D05.jpg	S4064D06.jpg	S4064D07.jpg	S4064D08.jpg	S4064D09.jpg
S4065D05.jpg	S4065D06.jpg	S4065D07.jpg	S4065D08.jpg	S4065D09.jpg
S4066D05.jpg	S4066D06.jpg	S4066D07.jpg	S4066D08.jpg	S4066D09.jpg
S4067D05.jpg	S4067D06.jpg	S4067D07.jpg	S4067D08.jpg	S4067D09.jpg
S4068D05.jpg	S4068D06.jpg	S4068D07.jpg	S4068D08.jpg	S4068D09.jpg
S4069D05.jpg	S4069D06.jpg	S4069D07.jpg	S4069D08.jpg	S4069D09.jpg
S4070D05.jpg	S4070D06.jpg	S4070D07.jpg	S4070D08.jpg	S4070D09.jpg
S4071D05.jpg	S4071D06.jpg	S4071D07.jpg	S4071D08.jpg	S4071D09.jpg
S4072D05.jpg	S4072D06.jpg	S4072D07.jpg	S4072D08.jpg	S4072D09.jpg
S4073D05.jpg	S4073D06.jpg	S4073D07.jpg	S4073D08.jpg	S4073D09.jpg
S4074D05.jpg	S4074D06.jpg	S4074D07.jpg	S4074D08.jpg	S4074D09.jpg
S4075D05.jpg	S4075D06.jpg	S4075D07.jpg	S4075D08.jpg	S4075D09.jpg
S4076D05.jpg	S4076D06.jpg	S4076D07.jpg	S4076D08.jpg	S4076D09.jpg
S4077D05.jpg	S4077D06.jpg	S4077D07.jpg	S4077D08.jpg	S4077D09.jpg
S4078D05.jpg	S4078D06.jpg	S4078D07.jpg	S4078D08.jpg	S4078D09.jpg
S4079D05.jpg	S4079D06.jpg	S4079D07.jpg	S4079D08.jpg	S4079D09.jpg
S4080D05.jpg	S4080D06.jpg	S4080D07.jpg	S4080D08.jpg	S4080D09.jpg
S4081D05.jpg	S4081D06.jpg	S4081D07.jpg	S4081D08.jpg	S4081D09.jpg
S4082D05.jpg	S4082D06.jpg	S4082D07.jpg	S4082D08.jpg	S4082D09.jpg
S4083D05.jpg	S4083D06.jpg	S4083D07.jpg	S4083D08.jpg	S4083D09.jpg
S4084D05.jpg	S4084D06.jpg	S4084D07.jpg	S4084D08.jpg	S4084D09.jpg
S4085D05.jpg	S4085D06.jpg	S4085D07.jpg	S4085D08.jpg	S4085D09.jpg
S4086D05.jpg	S4086D06.jpg	S4086D07.jpg	S4086D08.jpg	S4086D09.jpg
S4087D05.jpg	S4087D06.jpg	S4087D07.jpg	S4087D08.jpg	S4087D09.jpg
S4088D05.jpg	S4088D06.jpg	S4088D07.jpg	S4088D08.jpg	S4088D09.jpg
S4089D05.jpg	S4089D06.jpg	S4089D07.jpg	S4089D08.jpg	S4089D09.jpg
S4090D05.jpg	S4090D06.jpg	S4090D07.jpg	S4090D08.jpg	S4090D09.jpg
S4091D05.jpg	S4091D06.jpg	S4091D07.jpg	S4091D08.jpg	S4091D09.jpg
S4092D05.jpg	S4092D06.jpg	S4092D07.jpg	S4092D08.jpg	S4092D09.jpg

S4093D05.jpg	S4093D06.jpg	S4093D07.jpg	S4093D08.jpg	S4093D09.jpg
S4094D05.jpg	S4094D06.jpg	S4094D07.jpg	S4094D08.jpg	S4094D09.jpg
S4095D05.jpg	S4095D06.jpg	S4095D07.jpg	S4095D08.jpg	S4095D09.jpg
S4096D05.jpg	S4096D06.jpg	S4096D07.jpg	S4096D08.jpg	S4096D09.jpg
S4097D05.jpg	S4097D06.jpg	S4097D07.jpg	S4097D08.jpg	S4097D09.jpg
S4098D05.jpg	S4098D06.jpg	S4098D07.jpg	S4098D08.jpg	S4098D09.jpg
S4099D05.jpg	S4099D06.jpg	S4099D07.jpg	S4099D08.jpg	S4099D09.jpg
S4100D05.jpg	S4100D06.jpg	S4100D07.jpg	S4100D08.jpg	S4100D09.jpg
S4101D05.jpg	S4101D06.jpg	S4101D07.jpg	S4101D08.jpg	S4101D09.jpg
S4102D05.jpg	S4102D06.jpg	S4102D07.jpg	S4102D08.jpg	S4102D09.jpg
S4103D05.jpg	S4103D06.jpg	S4103D07.jpg	S4103D08.jpg	S4103D09.jpg
S4104D05.jpg	S4104D06.jpg	S4104D07.jpg	S4104D08.jpg	S4104D09.jpg
S4105D05.jpg	S4105D06.jpg	S4105D07.jpg	S4105D08.jpg	S4105D09.jpg
S4106D05.jpg	S4106D06.jpg	S4106D07.jpg	S4106D08.jpg	S4106D09.jpg
S4107D05.jpg	S4107D06.jpg	S4107D07.jpg	S4107D08.jpg	S4107D09.jpg
S4108D05.jpg	S4108D06.jpg	S4108D07.jpg	S4108D08.jpg	S4108D09.jpg
S4109D05.jpg	S4109D06.jpg	S4109D07.jpg	S4109D08.jpg	S4109D09.jpg
S4110D05.jpg	S4110D06.jpg	S4110D07.jpg	S4110D08.jpg	S4110D09.jpg
S4111D05.jpg	S4111D06.jpg	S4111D07.jpg	S4111D08.jpg	S4111D09.jpg
S4112D05.jpg	S4112D06.jpg	S4112D07.jpg	S4112D08.jpg	S4112D09.jpg
S4113D05.jpg	S4113D06.jpg	S4113D07.jpg	S4113D08.jpg	S4113D09.jpg
S4114D05.jpg	S4114D06.jpg	S4114D07.jpg	S4114D08.jpg	S4114D09.jpg
S4115D05.jpg	S4115D06.jpg	S4115D07.jpg	S4115D08.jpg	S4115D09.jpg
S4116D05.jpg	S4116D06.jpg	S4116D07.jpg	S4116D08.jpg	S4116D09.jpg
S4117D05.jpg	S4117D06.jpg	S4117D07.jpg	S4117D08.jpg	S4117D09.jpg
S4118D05.jpg	S4118D06.jpg	S4118D07.jpg	S4118D08.jpg	S4118D09.jpg
S4119D05.jpg	S4119D06.jpg	S4119D07.jpg	S4119D08.jpg	S4119D09.jpg
S4120D05.jpg	S4120D06.jpg	S4120D07.jpg	S4120D08.jpg	S4120D09.jpg
S4121D05.jpg	S4121D06.jpg	S4121D07.jpg	S4121D08.jpg	S4121D09.jpg
S4122D05.jpg	S4122D06.jpg	S4122D07.jpg	S4122D08.jpg	S4122D09.jpg
S4123D05.jpg	S4123D06.jpg	S4123D07.jpg	S4123D08.jpg	S4123D09.jpg
S4124D05.jpg	S4124D06.jpg	S4124D07.jpg	S4124D08.jpg	S4124D09.jpg
S4125D05.jpg	S4125D06.jpg	S4125D07.jpg	S4125D08.jpg	S4125D09.jpg
S4126D05.jpg	S4126D06.jpg	S4126D07.jpg	S4126D08.jpg	S4126D09.jpg
S4127D05.jpg	S4127D06.jpg	S4127D07.jpg	S4127D08.jpg	S4127D09.jpg
S4128D05.jpg	S4128D06.jpg	S4128D07.jpg	S4128D08.jpg	S4128D09.jpg
S4129D05.jpg	S4129D06.jpg	S4129D07.jpg	S4129D08.jpg	S4129D09.jpg
S4130D05.jpg	S4130D06.jpg	S4130D07.jpg	S4130D08.jpg	S4130D09.jpg
S4131D05.jpg	S4131D06.jpg	S4131D07.jpg	S4131D08.jpg	S4131D09.jpg
S4132D05.jpg	S4132D06.jpg	S4132D07.jpg	S4132D08.jpg	S4132D09.jpg
S4133D05.jpg	S4133D06.jpg	S4133D07.jpg	S4133D08.jpg	S4133D09.jpg
S4134D05.jpg	S4134D06.jpg	S4134D07.jpg	S4134D08.jpg	S4134D09.jpg
S4135D05.jpg	S4135D06.jpg	S4135D07.jpg	S4135D08.jpg	S4135D09.jpg
S4136D05.jpg	S4136D06.jpg	S4136D07.jpg	S4136D08.jpg	S4136D09.jpg
S4137D05.jpg	S4137D06.jpg	S4137D07.jpg	S4137D08.jpg	S4137D09.jpg
S4138D05.jpg	S4138D06.jpg	S4138D07.jpg	S4138D08.jpg	S4138D09.jpg
S4139D05.jpg	S4139D06.jpg	S4139D07.jpg	S4139D08.jpg	S4139D09.jpg
S4140D05.jpg	S4140D06.jpg	S4140D07.jpg	S4140D08.jpg	S4140D09.jpg
S4141D05.jpg	S4141D06.jpg	S4141D07.jpg	S4141D08.jpg	S4141D09.jpg