

Francisco Manuel Inácio Ferreira Catarino

Segmentação da íris em imagens com ruído



Universidade da Beira Interior

Departamento de Informática

Agosto 2009

Francisco Manuel Inácio Ferreira Catarino

Segmentação da íris em imagens com ruído



*Tese submetida ao Departamento de Informática para avaliação
dos requisitos do grau de Mestre em Engenharia Informática*

*Orientado pelo Doutor Pedro de Almeida,
Professor Auxiliar no Departamento de Informática
da Universidade da Beira Interior, Covilhã, Portugal*

Universidade da Beira Interior
Departamento de Informática
Agosto 2009

Agradecimentos

Próximo do fim de mais uma etapa, não posso deixar de olhar para trás e reconhecer que o caminho que percorri não se deve só a mim mas a todos os que o fizeram comigo. Gostaria de agradecer a todos os que me apoiaram, ensinaram e aconselharam.

Agradeço aos meus pais e irmãos, avós e tios, todo o seu apoio, confiança e carinho que foram e ainda são essenciais na minha vida.

Agradeço também a todos os professores que nestes 18 anos de escolaridade contribuíram com o seu conhecimento para o meu enriquecimento intelectual.

Ao orientador de projecto, Prof. Pedro Almeida, pelo apoio e disponibilidade.

Agradeço o apoio financeiro dado pela “FCT - Fundação para a Ciência e Tecnologia” e “FEDER” no âmbito de pesquisa realizada no projecto “BIOREC: Non-Cooperative Biometric Recognition” - PTDC/EIA/69106/2006.

Aos meus amigos e colegas de laboratório pelo companheirismo e ajuda constantes.

À minha namorada pelo apoio, carinho demonstrados ao longo deste ano.

Abstract

A fast and effective iris segmentation in noisy images is one of the biggest difficulties in a non-cooperative iris recognition system. In this dissertation we propose an iris segmentation method with running times appropriate to real-time recognition systems, even if it sacrifices some precision.

Unlike other existent methods, we solve the iris segmentation problem as a pattern recognition problem. Because of the small percentage usually occupied by iris in the images, we use a pre-processing step in order to narrow down the iris location area. A feature evaluation method was used to select the features which add new information to the data set, avoiding waste of time in the extraction of unuseful features.

Several training data sets of different dimensions were created to find the set of features which improves the classifiers' learning and increases their precision. Each pixel is classified individually as being (or not) noise-free iris. The results obtained with our method are compared over the UBIRIS.v2 iris image data set, against several other classifiers using the error measures used in the iris segmentation contest NICE.1. The best classifier is then evaluated under the same conditions as the participants of the contest and its results are analysed and compared with the best scores obtained by the contest participants.

Resumo

A segmentação rápida e eficaz da íris em imagens com ruído é uma das maiores dificuldades num sistema de reconhecimento não-cooperativo. Por essa razão é proposto nesta dissertação um método de segmentação de íris, com tempo de execução apropriado em sistemas de reconhecimento em tempo real, sacrificando para isso alguma precisão.

Ao contrário da maioria dos métodos existentes, a segmentação da íris é interpretada como um problema de reconhecimento de padrões. Devido à pequena percentagem da imagem ocupada pela íris é utilizado um método com o propósito de delimitar rudemente a zona de localização da íris. Foi utilizado um método de selecção de características para que apenas sejam utilizadas as que adicionam nova informação ao conjunto de dados, evitando perdas de tempo na recolha de características inúteis. Foram criados grupos de treino de diversas dimensões para a encontrar o grupo de características que melhora a aprendizagem de classificadores e apresenta maior precisão. Os píxeis são classificados individualmente como sendo íris livre de ruído ou não. São comparados os resultados obtidos sobre a base de dados de imagens UBIRIS.v2, entre vários classificadores tendo por base as medidas de erro usadas no concurso de segmentação de íris NICE.1. O melhor classificador é avaliado sobre as mesmas condições do participantes do concurso e os resultados são analisados e comparados com as melhores pontuações do concurso NICE.1.

Acrónimos

DMCS Department of Microelectronics and Computer Science, Technical University Of Lodz

NICE.1 *Noise Iris Challenge Contest part 1*

RFID Identificação por Rádio Frequência

mRMR mínima-Redundância-Máxima-Relevância

FPR Taxa de Falsos Positivos

FNR Taxa de Falsos Negativos

ROC *Receiver-Operating Characteristic*

TPR Taxa de Verdadeiros Positivos

AUC *Area Under Curve*

FFNN *Feed-Forward Neural Network*

Conteúdo

Agradecimentos	iii
Abstract	v
Resumo	vii
Acrónimos	ix
Conteúdo	xi
Lista de Figuras	xv
Lista de Tabelas	xix
1 Introdução	1
1.1 Biometria	2
1.1.1 Íris	4
1.1.2 Reconhecimento da íris	5
1.1.2.1 Aquisição de imagem	6
1.1.2.2 Segmentação da íris	7
1.1.2.3 Normalização da íris	7
1.1.2.4 Extracção de características	8
1.1.2.5 Comparação de características	9
1.2 Descrição do Problema	10
1.2.1 Ruído	11

1.3	Estrutura do Documento	12
2	Segmentação da íris	15
2.1	Problema da segmentação da íris	15
2.2	Métodos de segmentação	15
2.2.1	Reconhecimento Cooperativo	16
2.2.1.1	Daugman	16
2.2.1.2	Wildes	17
2.2.1.3	Broussard <i>et al.</i>	20
2.2.1.4	Hugo Proença e Luís Alexandre	23
2.2.2	Reconhecimento Não-cooperativo	25
2.2.2.1	Tieniu Tan <i>et al.</i>	25
2.2.2.2	DMCS	30
2.2.2.3	Pedro de Almeida	34
3	Método Proposto	39
3.1	UBIRIS.v2	39
3.2	Desenvolvimento	42
3.2.1	Delimitação da íris	43
3.2.1.1	Detecção de reflexo	44
3.2.1.2	Detecção da pupila	45
3.2.2	Extracção de características	46
3.2.3	Seleção de Características	48
3.2.3.1	Método de selecção de características	49
3.2.4	Classificação dos dados	51
3.2.4.1	Rede Neuronal	51
3.2.4.2	Naive Bayes	53
3.3	Avaliação de desempenho	55
3.3.1	Medidas de erro de <i>Noise Iris Challenge Contest part 1</i> (NICE.1)	55
3.3.2	Curva de ROC	56
3.4	Discussão dos resultados	58

4 Conclusão	67
4.1 Trabalho Futuro	67
A Resultados mRMR	69
B Resultados da segmentação	75
Bibliografia	79

Lista de Figuras

1.1	Reconhecimento da íris Panasonic	2
1.2	Interior Mercedes SLR	3
1.3	Reconhecimento da íris IrisGuard	4
1.4	Ilustração do olho humano	4
1.5	Reconhecimento da íris	5
1.6	Imagens de várias bases de dados	6
1.7	Segmentação da íris	7
1.8	Normalização da íris	8
1.9	Imagem de íris segmentada e respectivo <i>iris code</i>	8
1.10	Histograma de comparações de <i>iris codes</i>	9
2.1	Segmentação da íris de Wildes	17
2.2	Mapas de arestas de Wildes.	18
2.3	Conversão do espaço xy para o espaço $r\theta$	19
2.4	Transformada de Hough	20
2.5	Processo de segmentação da íris de Broussard <i>et al.</i>	21
2.6	Várias etapas de segmentação da pupila de Kennell <i>et al.</i>	22
2.7	Configuração da rede neuronal de Broussard <i>et al.</i>	23
2.8	Segmentação da íris de Broussard <i>et al.</i>	23
2.9	Segmentação da íris de Proença e Alexandre	24
2.10	Imagens das várias etapas de segmentação de Proença e Alexandre	24
2.11	Processo de segmentação da íris de Tan <i>et al.</i>	25
2.12	Localização grosseira da íris apresentado por Tan <i>et al.</i> (adaptado)	26

2.13	Aceleração do operador integro-diferencial de Daugman por Tieniu Tan et al.	27
2.14	Ilustração do método de localização de pálpebras de Tieniu Tan et al.	28
2.15	Ilustração do método de detecção de sombras e pestanas de Tieniu Tan et al.	29
2.16	Segmentação da íris de DMCS	30
2.17	Filtro de amaciamento de arestas de DMCS	32
2.18	Ilustração da detecção da pálpebra superior por DMCS.	33
2.19	Íris segmentada pelo método de DMCS	34
2.20	Diagrama do método de segmentação de Almeida	35
2.21	Resultado do processo de aumento de contraste utilizado por Almeida	35
2.22	Íris segmentada por Almeida	37
3.1	Captura de imagens UBIRIS.v2	41
3.2	Imagens da base de dados UBIRIS.v2	42
3.3	Ilustração das etapas de desenvolvimento do método proposto. . . .	43
3.4	Delimitação da íris	45
3.5	Ilustração de um neurónio artificial	52
3.6	Ilustração da arquitectura da rede neuronal utilizada	53
3.7	Interpretação das curvas de ROC.	56
3.8	Curvas de ROC resultante de redes neuronais	57
3.9	AUC dos classificadores para os conjuntos de características iniciais .	58
3.10	Erros E^1 dos classificadores	59
3.11	Erros E^2 dos classificadores	60
3.12	Segmentação da íris pelo método proposto	64
3.13	Segmentação da íris pelo método proposto com maior E^1	64
3.14	Segmentação da íris pelo método proposto em que falha a delimitação da íris	65
B.1	Íris segmentada pelo método proposto com menor E^1	75
B.2	Íris segmentada pelo método proposto com menor E^2	76

B.3	Íris segmentada pelo método proposto com maior E^1	76
B.4	Íris segmentada pelo método proposto com maior E^2	76
B.5	Íris ocluída por cabelo segmentada pelo método proposto	77
B.6	Íris fora de ângulo segmentada pelo método proposto	77
B.7	Íris ocluída por óculos segmentada pelo método proposto	77
B.8	Íris ocluída por reflexos especular e difuso segmentada pelo método proposto	78
B.9	Íris segmentada pelo método proposto	78

Lista de Tabelas

3.1	Descrição da base de dados UBIRIS.v2	40
3.2	Resultados da detecção da pupila	46
3.3	Resultados da selecção de características de mRMR e Máxima Relevância	50
3.4	AUC dos classificadores para os conjuntos de características iniciais.	59
3.5	Erro E^1 com vários limiares para os vários conjuntos de características e classificadores.	60
3.6	Erro E^2 com vários limiares para os vários conjuntos de características e classificadores.	61
3.7	Medidas de performance das Redes Neurais	61
3.8	Resultados do concurso NICE.1.	62
3.9	Tempos de execução de algumas participações no NICE!	63
A.1	Resultados do método de selecção de características mRMR	74

Capítulo 1

Introdução

O controlo de acesso a determinadas instalações ou ficheiros é um importante factor de segurança nos dias de hoje. Nos últimos anos têm ganho bastante popularidade sistemas de identificação que recorrem à biometria a fim de policiar acessos a áreas restritas. Também a identificação de pessoas em postos de fronteira ou em aeroportos tem vindo a recorrer cada vez mais a sistemas biométricos nos últimos anos. Este súbito interesse deve-se ao aumento de insegurança sentido desde os últimos ataques terroristas, que levaram várias agências governamentais a investirem em sistemas de identificação adicionais e/ou alternativos [1].

O uso de sistemas de reconhecimento biométrico surge como alternativa aos sistemas comuns de identificação, cartões de banda magnética, Identificação por Rádio Frequência (RFID), palavra-chave e documentos de identificação pessoal.

Nos sistemas de reconhecimento de íris actuais é exigida uma cooperação total por parte dos utilizadores no processo de recolha de imagem da íris. Um exemplo desses sistemas comercial é o da Panasonic, na figura 1.1, que transmite instruções sonoras ao utilizador para que este se movimente de forma a que a íris fique alinhada com o dispositivo e melhorar a captura da imagem.

O reconhecimento de íris em grandes superfícies tais como a zona de *check-in* de um aeroporto tem sido aplicado com sucesso [41]. Devido ao enorme fluxo de pessoas nestes espaços, é exigido ao sistema um reconhecimento efectuado em tempo real.

Apesar de sistemas semelhantes ao Panasonic serem rápidos as reconhecer uma



Figura 1.1: Fotografia de um indivíduo sendo reconhecido pelo sistema BM-ET200 da Panasonic [36].

íris (0.3 segundos), o processo de captura é incómodo e moroso o que torna sua utilização na identificação de uma grande quantidade de pessoas impraticável. Desta necessidade surgem os sistemas de reconhecimento de íris não-cooperativos em que cada indivíduo é identificado praticamente sem cooperação.

1.1 Biometria

A Biometria está a emergir como o mais infalível método de identificação pessoal num mundo cada vez mais automatizado [34].

Ao contrário da banda magnética e do RFID, os sistemas de reconhecimento biométrico não necessitam de objectos identificadores específicos e exteriores ao utente para efectuar a identificação, uma vez que são identificados através das suas características físicas. Esta mais valia não significa só uma redução de custos, como um aumento do nível de segurança. A usurpação de identidade torna-se teoricamente impossível com elementos de identificação que não podem ser furtados ou replicados, tais como sinais biométricos.

Os sistemas biométricos têm como resultado por cada comparação, a distância entre duas assinaturas biométricas que pode ser interpretado como uma percentagem de certeza. O sistema considera correspondência positiva se a diferença entre as assinaturas for inferior a um limite máximo. A variação deste limite permite optar por uma preferência entre falsos positivos e falsos negativos. Por exemplo,

no acesso a ficheiros confidenciais é preferível um sistema com uma taxa de falsos positivos próxima de zero, mesmo que sujeitos classificados como falsos negativos tenham que tentar autenticar mais que uma vez. O contrário verifica-se em sistemas de identificação de terroristas em *check-in* de aeroportos, em que é ideal a inexistência de falsos negativos.

Num futuro próximo, as assinaturas biométricas serão parte integrante nos vários documentos de identificação, para além da impressão digital já utilizada no Bilhete de Identidade. Actualmente, o reconhecimento biométrico tem sido utilizado como substituto de passaportes no cruzamento de algumas fronteiras afim de evitar identidades fraudulentas[12], no controlo de acesso a áreas de aeroportos restritas, ficheiros de computador, etc [13].

A conceituada marca de automóveis Mercedes-Benz tem como opção em alguns modelos o uso da impressão digital em substituição da chave comum. A figura 1.2 mostra o interior de um modelo Mercedes-Benz SLR McLaren em que no punho da alavanca de velocidades se encontra o leitor de impressões digitais.



Figura 1.2: Utilização da impressão digital como substituta da chave do Mercedes-Benz SLR MacLaren [3].

O exemplo de maior sucesso e em grande escala de aplicação do reconhecimento de íris é do Ministério do Interior dos Emirados Árabes Unidos com o sistema IrisGuard [31] usado no reconhecimento de estrangeiros que entram no país em 35 portos terrestres, aéreos e marítimos, representado na imagem 1.3. Cada indivíduo é comparado com um milhão de íris de uma lista de *persona non grata*. O tempo

tomado pela pesquisa em toda a base de dados é de apenas um segundo. Em média 12 000 passageiros tentam entrar no país por dia. Em 7,5 milhões de passageiros, foram identificados 73 180 pertencentes à lista [13]. Este sistema tem por base o método de John Daugman apresentado em [14].



Figura 1.3: Reconhecimento da íris de um passageiro a entrar nos Emirados Árabes Unidos com o sistema IrisGuard [13].

1.1.1 Íris

Na imagem 1.4 é ilustrado o olho humano com identificação dos seus constituintes mais relevantes no reconhecimento da íris.




Figura 1.4: Ilustração do olho humano [4].

O uso da íris na identificação de indivíduos têm tido mais sucesso relativamente a

outras características fisiológicas do ser humano devido essencialmente à unicidade de cada íris. No ano de 1987, Flom and Safir afirmaram em [23] que a morfologia do olho humano mantém-se estável ao longo da vida e que a probabilidade de existirem duas íris semelhantes é de 1 em cada 10^{72} . Em [15] Daugman releva que em cerca de 9.1 milhões de comparações de íris realizadas em vários países, tais como Reino Unido, Japão e Coreia, o seu método obteve uma taxa de falsa correspondência que ronda a proporção de 1 para 10^{13} [15].

Outras características fisiológicas usadas na identificação como a face ou a impressão digital podem sofrer deformações resultantes de acidentes ou intervenções cirúrgicas. Com a íris a probabilidade de sofrer uma deformação por acidente é menor uma vez que se encontra numa zona da cara mais protegida e operações cirúrgicas a cataratas ou transplantes de córnea não alteram as características da íris. O padrão da íris é impossível de alterar sem correr o risco de cegar. Mesmo pessoas invisuais podem ser identificadas através da íris, desde que a possuam [47]. No reconhecimento à distância, com os sistemas actuais, a face e a íris são as únicas assinaturas utilizáveis. Com as várias expressões faciais possíveis, cortes de barba e cabelo e envelhecimento, a íris é a assinatura biométrica mais forte para o uso em sistemas de reconhecimento não-cooperativo. Todas estas as vantagens tornam uso a íris ideal no reconhecimento biométrico.

1.1.2 Reconhecimento da íris

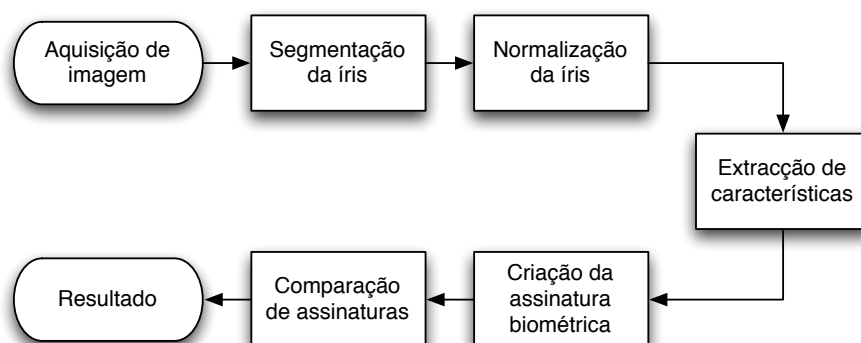


Figura 1.5: Ilustração de um típico sistema de reconhecimento de íris.

Com pequenas variantes em algumas das etapas, de um modo geral, todos os

sistemas de reconhecimento de íris seguem uma estrutura semelhante ao diagrama da figura 1.5. Este modelo foi inicialmente apresentado por Daugman [14] em 1993, mantendo-se até hoje uma grande referência no reconhecimento de íris.

1.1.2.1 Aquisição de imagem




Figura 1.6: Imagens de várias bases de dados: (a) BATH [30], (b) CASIA [8]. (c) UBIRIS.v1 [43] e (d) UBIRIS.v2 [44].

A primeira etapa, a aquisição de imagem, na grande maioria dos sistemas é feita com um câmara com iluminação *near-infrared*, ou em alternativa com câmaras convencionais. Em alguns sistemas a câmara é guiada por um funcionário, como no sistema da figura 1.3, em outros as câmaras são fixas e são dadas instruções ao indivíduo para se posicionar correctamente como acontece no sistema da figura 1.1.

Na figura encontram-se quatro imagens de quatro bases de dados, duas (1.6(a) 1.6(b)) capturadas com iluminação *near-infrared* e as duas últimas (1.6(c) 1.6(d)) capturadas no visível.

1.1.2.2 Segmentação da íris




Figura 1.7: Processo de segmentação de íris requerido aos participantes do concurso NICE.1.

A segmentação tem por objectivo identificar, na imagem capturada na etapa anterior, a localização da íris e os seus limites. Em situações não ideais, a segmentação da íris pode não se restringir à detecção das fronteiras pupilar e esclérica. Se parte da íris estiver obstruída por pálpebras ou outro factor de ruído, é necessário que também essas fronteiras sejam detectadas. A figura 1.10 representa o funcionamento exigido aos algoritmos participantes no concurso de segmentação de íris NICE.1. Na figura encontram-se duas imagens, a primeira uma fotografia de um olho com algum ruído sobre a íris e a segunda assinala a localização das zonas da íris livres de ruído.

1.1.2.3 Normalização da íris

Na aquisição de imagem não é possível garantir que todas as íris tenham a mesma dimensão, para além da distância entre o indivíduo e a câmara poder variar, e a dimensão da pupila estar relacionada com a iluminação, também as medidas do raio da pupila e da íris diferem de pessoa para pessoa. Com o objectivo de criar a assinatura biométrica invariante a dimensões da íris e pupila, Daugman propôs em [14] um método de normalização que consiste na conversão de todos os pixels localizados entre as fronteiras interior e exterior para um sistema de coordenadas polares, criando uma imagem rectangular de dimensões fixas. Mais tarde, o mesmo investigador propôs uma modificação da normalização [16], que permite corrigir imagens em que os centros da íris e da pupila estão muito afastados. Este processo é ilustrado pela imagem 1.8.

Devido à segmentação simples resultante de alguns métodos, em que apenas são detectadas as fronteiras da íris com a pupila, esclera e talvez pálpebras, algum ruído é ignorado e utilizado no processo de reconhecimento. Dando atenção a este problema alguns investigadores propuseram métodos de detecção de ruído em imagens de íris já normalizadas (ver em [20] e [26]).




Figura 1.8: Ilustração da normalização de íris de Daugman [40].

1.1.2.4 Extração de características




Figura 1.9: Imagem de íris segmentada e respectivo *iris code* (canto superior esquerdo) pelos métodos de Daugman (adaptado) [15].

Esta etapa tem por objectivo a geração de uma assinatura binária (*iris code*), a partir da íris normalizada que idealmente identifica unicamente cada indivíduo. O processo mais comum na extração de características foi proposto também por Daugman[14], e recorre ao uso de filtros para criar uma assinatura de 2048 *bits* .

A figura 1.9 tem presente uma imagem com íris segmentada, juntamente com o respectivo *iris code* no canto superior esquerdo.

1.1.2.5 Comparação de características

Com uma assinatura criada para a identificação segue-se a comparação com as assinaturas armazenadas. Apesar de a comparação entre características estar relacionada com o modo pela qual são extraídas, a maior parte dos sistemas recorre a métricas de distância, tais como a de Hamming ou a euclideana [42].

As métricas de distância apenas indicam distância entre duas assinaturas, que pode ser interpretada como a probabilidade de duas assinaturas pertencerem à mesma pessoa. Um limiar é definido para garantir uma distância mínima entre as assinaturas para que haja uma identificação correcta.




Figura 1.10: Histograma de distâncias de 2,3 milhões de comparações de *iris codes* de imagens tiradas a diferentes distâncias[15].

A imagem 1.10 mostra o resultado de várias comparações de íris. No gráfico, as comparações entre pessoas diferentes têm uma distância de Hamming próxima dos 0.45, enquanto que as comparações entre assinaturas da mesma íris têm uma distância muito menor. O limite utilizado para decidir se duas assinaturas pertencem a

uma só íris é um valor que separa as duas classes, neste caso, 0.35 aproximadamente.

É possível que em alguns casos a comparação de assinaturas da mesma íris tenha distância superior ao limite e que a distância entre íris diferentes seja inferior ao limite. Para evitar falsos positivos o limiar aplicado é reduzido, aceitando mais falsos negativos para evitar falsos positivos.

1.2 Descrição do Problema

Como dito anteriormente, em situações que envolvam o tráfego rápido de muitas pessoas, os sistemas de reconhecimento de íris não-cooperativos, para terem aplicabilidade, necessitam de ser rápidos não só no processo de reconhecimento mas também na captura da íris. Sendo o sistema não-cooperativo é natural que as imagens contenham mais ruído que num sistema cooperativo num ambiente controlado. Este ruído adicional causa um aumento de erro que se propaga ao longo de cada etapa do processo de reconhecimento, nomeadamente na etapa de segmentação.

Nesta dissertação é proposto um método rápido de segmentação da íris em imagens com ruído. Este método está inserido no projecto BioRec [5] que consiste no desenvolvimento de um sistema de reconhecimento biométrico multi-modal, capaz identificar e reconhecer pessoas à distância e sem a sua cooperação, através da íris e da face em luz visível e infravermelhos.

O laboratório SOCIALab [10] da Universidade da Beira Interior criou um concurso de segmentação da íris (NICE.1 [41]) em que os concorrentes foram avaliados sobre os resultados obtidos com a base de dados de imagens UBIRIS.v2 [44], constituída por imagens obtidas com o sistema de reconhecimento BioRec. O concurso criou assim uma base de comparação para avaliar o desempenho do método proposto. O presente desenvolvimento da etapa de segmentação teve como alvo de estudo apenas a base de dados UBIRIS.v2 e teve como objectivo conseguir uma melhor performance temporal do que as participações no concurso NICE.1.

Assim, o objectivo final deste estudo é criar um método de segmentação mais rápido que os dos primeiros classificados do concurso NICE.1. Este método tem como principal preocupação conseguir um tempo de execução próximo do de um sistema de reconhecimento em tempo real, sacrificando para isso alguma precisão.

O método proposto segue as normas de participação do concurso: recebe como entrada uma imagem a cores contendo (ou não) uma íris e devolve uma imagem binária em que os píxeis da íris livres de ruído devem ter intensidade igual a 0 (cor preta) e os restantes devem ter intensidade igual a 255 (cor branca). A imagem 1.10 ilustra os requisitos de funcionamento do concurso.

1.2.1 Ruído

Como foi referido anteriormente, os sistemas de reconhecimento não-cooperativos implicam um aumento de ruído na captura das imagens. O ruído nas imagens não só dificulta a localização da íris como pode obstruí-la e ser erradamente utilizado na extracção e comparação de características como se de íris se tratasse, influenciando negativamente os resultados.

No artigo [41] são descritos os tipos de ruído presentes nas imagens da base de dados UBIRIS.v2. Estes tipos de ruído são sumarizados a seguir:

- Imagens desfocadas. Devido a vários objectos ao alcance da câmara, esta pode focar outro elemento que não a íris. O desfoque também pode ser causado pelo movimento do indivíduo no momento da captura.
- Imagens com a íris fora de ângulo. Ocorrem quando o indivíduo não está a olhar na direcção da câmara no momento da captação da imagem.
- Imagens rodadas. Pode acontecer no momento da captura a cabeça do indivíduo não estar na posição vertical.
- Imagens com arrastamento (*Motion blur*). A imagem poderá ficar com um efeito de nevoeiro causado pelo movimento.
- Obstrução da íris por pestanas. É bastante comum a obstrução da íris por pestanas, principalmente as superiores, mesmo em sistemas de reconhecimento cooperativo.

- Obstrução da íris por pálpebras. As pálpebras são uma das maiores fontes de ruído nas imagens porque escondem grandes porções de íris nos extremos superiores e inferiores. Isto dificulta a segmentação, uma vez que a maior parte dos algoritmos baseiam a localização da íris em métodos de detecção de círculos.
- Obstrução por óculos. A presença de óculos na imagem é ruído não só por poderem obstruir a íris, mas também porque podem ser fonte de falsos positivos na localização da íris por detecção de segmentos circulares.
- Obstrução da íris por lentes de contacto. Lentes de contacto com elevada graduação podem obstruir e deformar partes de padrões da íris.
- Obstrução da íris por reflexo especular. Este tipo de ruído é geralmente fácil de detectar por serem os píxeis com maior intensidade na imagem.
- Íris com reflexos difusos. Com intensidade inferior ao especular e de valor igual ao objecto reflectido no olho, o reflexo difuso é muito mais difícil de detectar.
- Captura parcial da íris. Na maioria da imagens há partes da íris obstruídas por alguns dos factores de ruído mencionados anteriormente. Além disso, em alguns casos, a íris é cortada pelos limites da própria imagem.
- Imagens sem íris. Na captura da imagem o olho pode estar fechado ou a câmara focar uma zona onde não existe íris.

1.3 Estrutura do Documento

O remanescente desta dissertação encontra-se organizado em três capítulos. No capítulo dois é focada a etapa de segmentação da íris e são apresentados alguns dos métodos mais relevantes e com melhores resultados, tanto em sistemas de reconhecimento de íris cooperativos como não-cooperativos.

No capítulo três é exposto e explicado ao pormenor o método proposto sendo justificadas todas as decisões tomadas e analisados os resultados obtidos.

Por fim, no capítulo quatro são apresentadas conclusões sobre os resultados obtidos e referidos alguns aspectos que podem servir para trabalho futuro.

Capítulo 2

Segmentação da íris

Este capítulo é dedicado à etapa de segmentação da íris. Na primeira secção são expostas as várias dificuldades da segmentação, assim como a sua necessidade.

Na segunda secção são apresentados vários métodos de segmentação de vários autores.

2.1 Problema da segmentação da íris

A etapa de segmentação é comum em todos os sistemas de reconhecimento de íris. A segmentação é necessária para que seja apenas a íris a ser comparada no reconhecimento. A forma aproximadamente circular da íris sugere métodos de localização baseados na detecção de círculos para obter os limites esclérico e pupilar. Embora estas abordagens tenham excelentes resultados em imagens cooperativas, o mesmo não se verifica em imagens não-cooperativas, por exemplo se na imagem o olho estiver virado para o lado ou se houver bastante ruído.

2.2 Métodos de segmentação

Ao longo desta secção são dados a conhecer alguns dos métodos de segmentação da íris mais relevantes. Os algoritmos são apresentados segundo o tipo de sistemas para os quais foram desenhados, cooperativos ou não-cooperativos.

Os algoritmos de segmentação da íris dividem-se em duas categorias, os que

se baseiam na detecção de formas e os que se baseiam no reconhecimento de padrões. Na primeira categoria encontram-se inseridos os algoritmos que baseiam a segmentação da íris através de métodos de detecção de círculos. Na segunda categoria, a íris é localizada através de características recolhidas e cada pixel é classificado como sendo íris ou não.

2.2.1 Reconhecimento Cooperativo

Nesta secção são apresentados duas categorias de algoritmos de detecção da íris. Os dois primeiros baseiam-se em métodos de detecção de formas, o terceiro método utiliza métodos de reconhecimento de padrões e por último, o quarto método que utiliza as duas abordagens.

Por se tratarem de métodos de segmentação para sistemas de reconhecimento cooperativos, poucos dos vários tipos de ruído enunciados na secção 1.2.1 estão presentes nas imagens capturadas. São visíveis as diferenças de ruído entre as imagens 1.6(a) 1.6(b) 1.6(c) e a imagem 1.6(d), o que implica que estes algoritmos não teriam o mesmo desempenho em imagens como a 1.6(d).

2.2.1.1 Daugman

Proposto em 1993, todo o processo de reconhecimento apresentado por Daugman em [14] foi e continua a ser um algoritmo de referência e de grande sucesso.

Na etapa de segmentação, o autor assume que tanto a pupila como a íris tem forma circular e são concêntricas, porém em trabalho publicado posteriormente o autor apresenta um método de compensação da excentricidade entre a íris e a pupila.

Os círculos da íris e da pupila são detectados através do operador integro-diferencial apresentado por Daugman:

$$\max_{(r,x_0,y_0)} \left| G_\sigma(r) * \frac{\partial}{\partial r} \oint_{r,x_0,y_0} \frac{I(x,y)}{2\pi r} ds \right| \quad (2.1)$$

Na imagem $I(x, y)$ o operador 2.1 procura no domínio (x, y) pelo valor máximo na derivada parcial amaciada, aumentando o raio r , do contorno integral de $I(x, y)$ normalizado, com centro em (x_0, y_0) . Onde $*$ denota a operação de convolução e

$G_\sigma(r)$ representa a função de amaciamento através de um filtro Gaussiano de escala σ . De um modo simplificado, este operador procura na imagem amaciada por um filtro Gaussiano num espaço $\mathbb{N}^3((x_0, y_0, r))$, o centro (x_0, y_0) e raio r da circunferência com maior valor de contraste comparado com as circunferências vizinhas de raio maior e menor. O operador é utilizado na procura de ambas fronteiras circulares da íris, a interior e a exterior. Este método mostra ser mais eficaz, quanto maior for a separabilidade ou contraste da entre a íris e esclera, ou entre a íris e a pupila.

Depois de determinados os limites circulares da íris, é utilizada uma variante do operador 2.1 de modo a detectar arestas curvilíneas pertencentes às pálpebras superiores e inferiores.

2.2.1.2 Wildes




Figura 2.1: Processo de segmentação da íris proposto por Richard Wildes [51].

O método de segmentação da íris incluído no sistema de reconhecimento proposto por Richard Wildes em [51], pode ser dividido em dois passos. No primeiro passo, a partir da imagem adquirida, é criado um mapa de arestas binário através de um detector de arestas baseado no gradiente. É aplicado um limiar ao resultado da convulsão do gradiente da imagem com um filtro Gaussiano $G(x, y)$ definido pela equação 2.2.

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x-x_0)^2 + (y-y_0)^2}{2\pi\sigma^2}} \quad (2.2)$$

$G(x, y)$ é um filtro de duas dimensões com centro em (x_0, y_0) e desvio padrão σ , que amacia a imagem para seleccionar que arestas serão utilizadas no mapa binário.

O calculo das derivadas da imagem são pesadas de modo a serem compensadas com certas orientações a fim de eliminar arestas desnecessárias. O resultado da compensação de certas orientações das arestas é representado na imagem 2.2.



(a) Mapa de arestas favorecendo a orientação vertical (b) Mapa de arestas sem favorecimento de orientação

Figura 2.2: Mapas de arestas de Wildes. Imagens de Hugo Proença [42].

No segundo passo do algoritmo, é aplicada a Transformada Circular de Hough para detectar ambas as fronteiras esclérica e pupilar da íris. O método inicial desenhado para a detecção de linhas numa imagem foi patenteado em 1962 por Paul Hough [28] e generalizado por R. Duda e P. Hart em 1972 [18].

A transformada de Hough é uma técnica de votação utilizada em análise de imagem. O sistema de votação consiste numa conversão de uma imagem binária para um espaço de parâmetros acumulador de n -dimensões, com n igual ao número de parâmetros pelos quais o objecto é definido.

Na detecção de linhas, o espaço acumulador ideal a utilizar é mb , uma vez que cada recta é identificada de acordo com a equação 2.3:

$$y = mx + b \quad (2.3)$$

Se cada recta é representada por um par mb da equação 2.3, no espaço mb cada ponto representa uma recta no espaço xy . Na prática não é utilizado o espaço mb devido aos valores infinitos tomados pelas variáveis m e b nas equações de linhas verticais. É utilizada em alternativa, a equação 2.4 e o espaço $r\theta$.

$$r = x \times \cos\theta + y \times \sin\theta \quad (2.4)$$

O valor r representa o comprimento de um segmento de recta, perpendicular à recta em questão, desde a origem do plano xy até à recta. θ é o valor do ângulo entre o segmento de recta normal e o eixo X. Na figura 2.3 estão representados os

dois espaços, xy e $r\theta$, representando cada um a mesma linha.




Figura 2.3: Conversão do espaço xy para o espaço $r\theta$.


Cada ponto no espaço xy pode pertencer a um número infinito de rectas. Ao substituir na equação 2.4 as coordenadas de um ponto P_1 , obtém-se uma função no espaço $r\theta$ de todas as rectas que passam no P_1 . A imagem 2.4(b) representa o acumulador, visto como imagem, resultante da Transformada de Hough aplicada à imagem 2.4(a). Na imagem 2.4(b) cada pixel com cor diferente de 0 (preto) representa uma recta que intersecta um dos pontos da imagem binária. Quanto maior for a intensidade de um pixel (mais claro) da imagem acumuladora, mais pontos estão sobrepostos sobre a recta correspondente.

As rectas, ou linhas, podem ser escolhidas através de um limiar aplicado ao espaço acumulador quando é desconhecido o número de arestas a detectar ou através dos n pontos com maior valor no espaço acumulador, sendo n o número de arestas que se pretendem detectar. Os mesmos critérios se aplicam na detecção de quaisquer outros objectos.

As coordenadas no espaço $r\theta$ das rectas que definem as oito arestas do polígono presente na imagem 2.4(a), encontram-se assinaladas com um círculo vermelho na imagem 2.4(b).

Na detecção de círculos, estes podem ser representados matematicamente pela equação $(x - a)^2 + (y - b)^2 = r^2$, em que a circunferência de centro que (a, b) e raio r passa nos pontos (x, y) . Uma vez que a circunferência é representada a partir de três parâmetros, (a, b, r) , a Transformada de Hough será uma matriz de três dimensões.

O processo de “conversão” da imagem para o espaço abr na prática processa-se



(a) Imagem binária com oito arestas (linhas). (b) Acumulador resultante da transformada de Hough.

Figura 2.4: Transformada de Hough aplicada a uma imagem binária [22].

do seguinte modo:

- para os vários centros e raios possíveis (cada ponto no espaço *abr*), são armazenados o número total de pixels do mapa de arestas sobrepostos pelas arestas pertencentes ao círculo.
- os valores mais elevados na matriz representam os melhores círculos presentes na imagem binária.

Depois de detectadas as fronteiras interior e exterior da pupila, é utilizada mais uma vez a Transformada de Hough, alterada de modo a detectar ambas as pálpebras que possuem a forma geométrica de arcos.

2.2.1.3 Broussard *et al.*

Broussard *et al.* [6] apresentaram um método de segmentação de íris baseado em reconhecimento de padrões. A figura 2.5 contém um diagrama que ilustra o funcionamento do algoritmo proposto, desenvolvido sobre imagens da base de dados BATH [30].

Na primeira fase, são extraídas dez características. Como calculo auxiliar, a algumas características é aplicado o método de segmentação da pupila baseado em




Figura 2.5: Diagrama ilustrativo do método de segmentação proposto por Broussard *et al.* em [6].

morfologia binária e estatísticas locais proposto por Kennell *et al.* em [32], a fim de obter o centro e raio do círculo da fronteira entre a íris e a pupila.

A localização da pupila, na figura 2.6, é realizada sobre uma imagem binária gerada a partir da equalização do histograma seguido da aplicação de um limiar, em todos os píxeis acima desse valor tomam valor 0 e os restantes 255. De seguida são aplicados operadores morfológicos na seguinte ordem:

- Preenchimento, se existir reflexo no interior da íris, é removido.
- Erosão para eliminar pequenos píxeis de ruído.
- Dilatação, para recuperar a ligação entre regiões caso se tenham separado devido à aplicação da erosão.

É escolhida como região da pupila a que restar após subidas consecutivas do valor do limiar até que sobre apenas uma região. O raio escolhido é o do menor círculo que englobe a totalidade da região da pupila.

As dez características extraídas de cada pixel da imagem são as seguintes:

- Distância Euclidiana entre o pixel e o centro da pupila segmentada.
- Média numa vizinhança de 25×25 píxeis.
- Desvio padrão numa vizinhança perpendicular de 29 píxeis.
- Desvio padrão num raio de 11 menos o desvio padrão de uma vizinhança de 29×29 píxeis.
- Distância Euclidiana entre o pixel e a fronteira da pupila segmentada.




Figura 2.6: Imagens obtidas nas várias etapas de parte do método de segmentação proposto por Kennell *et al.* [32] adoptado por Broussard *et al.*. (a) Imagem original. (b) Imagem resultante da aplicação do limiar. (c) Imagem resultante da aplicação dos três métodos morfológicos, preenchimento, erosão e abertura. (d) Imagem com a pupila segmentada.

- Distância da coordenada y do pixel à coordenada y centro da pupila.
- Média numa vizinhança perpendicular de 29 píxeis.
- Valor absoluto do ângulo com o centro da pupila
- Desvio padrão numa vizinhança perpendicular de 21 píxeis.
- Obliquidade numa vizinhança perpendicular de 3 píxeis.

À etapa de classificação são passadas as dez características de cada um dos píxeis da imagem.

A figura 2.7 ilustra a configuração da rede utilizada. A rede contém dez neurónios na camada de entrada, correspondentes ao número de características, e apenas seis na camada escondida. Na camada de saída, a rede contém dois neurónios e saídas que transmitem o valor do pixel como sendo íris e não-íris. A saída com maior valor dita a classificação final de cada pixel.




Figura 2.7: Configuração da rede neuronal utilizada por Broussard *et al.* para a segmentação da íris [6].

Na etapa de pós-processamento são eliminados os píxeis isolados que não pertencem à maior região da imagem binária de saída. A imagem mostra uma imagem de entrada ao algoritmo 2.8(a) e o respectivo resultado de saída (imagem 2.8(b)).




Figura 2.8: Imagens de entrada e de saída do método de segmentação proposto por Broussard [6]. (a) Imagem original. (b) Máscara indicando a branco os píxeis que na imagem original são íris.

2.2.1.4 Hugo Proença e Luís Alexandre

No artigo [39] os autores propõem o método de segmentação representado em 2.9. É utilizado um algoritmo de *clustering*, fuzzy K-means, com o intuito de normalizar a imagem entre três valores (classes) a fim de eliminar ruído na criação do mapa de arestas. Os centros das três classes em que são classificados os píxeis, são calculados




Figura 2.9: Processo de segmentação da íris proposto por Hugo Proença e Luís Alexandre (adaptado). [39] [42].




Figura 2.10: Imagens obtidas nas várias etapas do método de segmentação proposto por Hugo Proença e Luís Alexandre [39]. (a) Imagem original. (b) Imagem resultante do *clustering*. (c) Imagem resultante da aplicação do detector de arestas *canny*. (d) Imagem final segmentada.

usando como características as coordenadas do pixel (x e y) e a sua intensidade. Após a classificação individual de cada pixel consoante a sua proximidade aos centros das classes, é obtida a imagem 2.10(b).

Na fase seguinte é aplicado o detector de arestas proposto por Canny em [7] resultando a imagem 2.10(c), que ao aplicar a Transformada Circular de Hough

para encontrar as melhores fronteiras interior e exterior como mostra 2.10(d).

2.2.2 Reconhecimento Não-cooperativo

Os algoritmos abordados nesta secção tiveram todos como base de treino imagens da base de dados UBIRIS.v2 [44]. Apenas 500 imagens da referida base de dados se encontram disponíveis, enquanto que outras 500 imagens são usadas na avaliação do concurso NICE.1. Os métodos são apresentados de acordo com a posição que obtiveram no concurso.

2.2.2.1 Tieniu Tan *et al.*

De acordo com o artigo submetido pelos autores ao concurso NICE.1, a abordagem proposta é representada pelas quatro fases no seguinte diagrama 2.11.

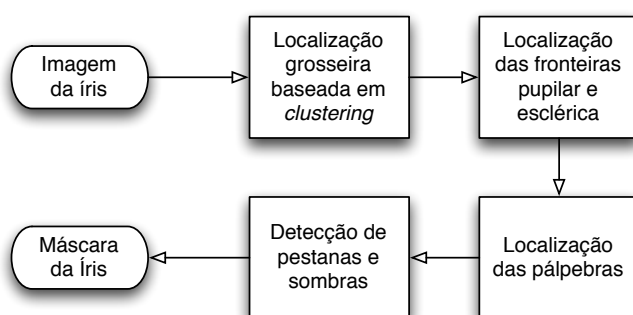


Figura 2.11: Processo de segmentação da íris proposto por Tan et al. (adaptado) [49].

Em todo o algoritmo apenas o canal vermelho do espaço RGB é utilizado, uma vez que permite a sua aplicação em imagens em escala cinza. A primeira fase tem por objectivo a redução da área de busca da fronteira esclérica da íris. Para o efeito, um método de *clustering* é aplicado para que a imagem seja dividida em várias regiões de acordo com a sua estrutura. Porém, a aplicação directa de *clustering* em imagens originais tende a falhar devido a interrupções estruturais bruscas causadas por reflexos [49]. Para eliminar ou reduzir reflexos nas imagens é feito um pré-processamento. Um limiar adaptativo é utilizado para criar um mapa de reflexos $R_{(x,y)}$ da imagem $I_{(x,y)}$, em que cada pixel está classificado como sendo reflexo ou não reflexo com os valores 255 e 0 respectivamente. No artigo não está

explicito o método de cálculo do limiar, porém, baseado em trabalho prévio dos autores nomeadamente [50], podemos assumir que são considerados reflexo os 5% pixels mais claros da imagem. Cada pixel reflexo será substituída na imagem por um valor calculado através de um método de interpolação bi-linear (ver em [50]). Depois da remoção do reflexo segue a aplicação do método de *clustering*. Esta fase é inicializada criando as várias regiões base a partir de um limiar adaptativo em que, os 20% pixels mais escuros fazem parte de regiões candidatas a íris, e os 30% mais claros são considerados não-íris resultando na imagem 2.12(b).



Figura 2.12: Várias etapas do método de *clustering* para uma localização grosseira da íris apresentado por Tan et al. (adaptado) [49].

A verde encontram-se as regiões candidatas a íris e a azul as regiões não-íris. Os pixels não incluídos na aplicação dos limiares, serão agregados a uma dada região se obedecerem a dois critérios:

- pertencer à vizinhança (janela de 3x3) de um pixel da região;
- distância entre o pixel e a região ser inferior a um dado limiar. A distância é dada pela equação 2.5:

$$dist(P, R) = \frac{|g_P - g_R|}{var_R} \quad (2.5)$$

em que g_P é o valor do pixel a classificar, g_R o valor médio da intensidade de todos os pixels pertencentes à região e var_R a variância da região.

De entre todas as candidatas a íris é seleccionada a correcta através de uma relação largura-altura da região, usando a altura de cada coluna da região.

A segunda fase, detecção das fronteiras esclérica e pupilar, baseia-se na aplicação do operador integro-diferencial apresentado por Daugman em [14], com uma

pequena alteração no método de escolha dos vários centros das circunferências. Esta modificação deve-se essencialmente ao elevado custo computacional do operador. A solução para acelerar o integro-diferencial passa por iterativamente achar o caminho mais curto para maximizar a equação 2.6.

$$\max_{(r,x_0,y_0)} \left| G_\sigma(r) * \frac{\partial}{\partial r} \oint_{r,x_0,y_0} \frac{I(x,y)}{2\pi r} ds \right| \quad (2.6)$$

Contudo, não é possível obter directamente a transição de direcção óptima derivando a equação 2.6, uma vez que não tem uma expressão analítica. Como solução, os autores criaram um “anel integro-diferencial” 2.13(a) para calcular a direcção a seguir.

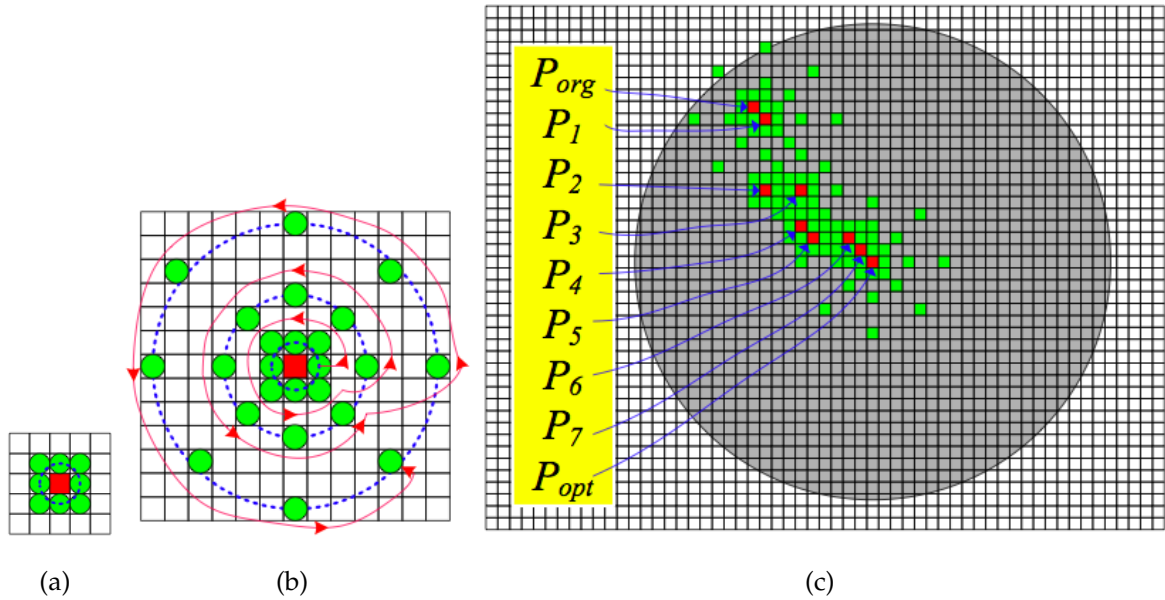


Figura 2.13: Aceleração do operador integro-diferencial de Daugman por Tieniu Tan et al. [49]: (a) Ilustração do “anel integro-diferencial”. Em (b) a representação da “constelação integro-diferencial”; (c) Caminho tomado até ao melhor centro da íris. [49]

Em contrapartida e de acordo com os autores, este método de pesquisa nos oito vizinhos prende-se em mínimos locais. Para evitar locais mínimos, foram adicionados vários “anéis” com raios variáveis para criar uma “constelação integro-diferencial” como mostra a figura 2.13(b). Podemos ver o inteiro processo de localização da íris na imagem 2.13(c), em que a verde e vermelho estão sinalizados os pontos utilizados pelo novo método, sendo os vermelhos o melhor caminho

de transição. A cinzento encontram-se todos os outros pixels que, para além dos vermelhos e verdes, seriam utilizados aplicando simplesmente o operador de Daugman.

A detecção de pálpebras, representada na figura 2.14, é realizada usando um método apresentado em artigos dos mesmos autores anteriormente publicados [50] [26]. Um filtro horizontal de posição de uma dimensão (1-D) é aplicado que enfraquece ou remove pestanas dependendo da sua largura, resultando a imagem 2.14(b). A aplicação deste método torna a fronteira entre íris e pálpebra mais clara, facilitando a detecção da aresta recorrendo a um operador *canny* [7] com direcção vertical. O mapa de arestas é constituído apenas por um ponto por coluna de modo a eliminar grande parte do ruído, como mostra a imagem 2.14(c).

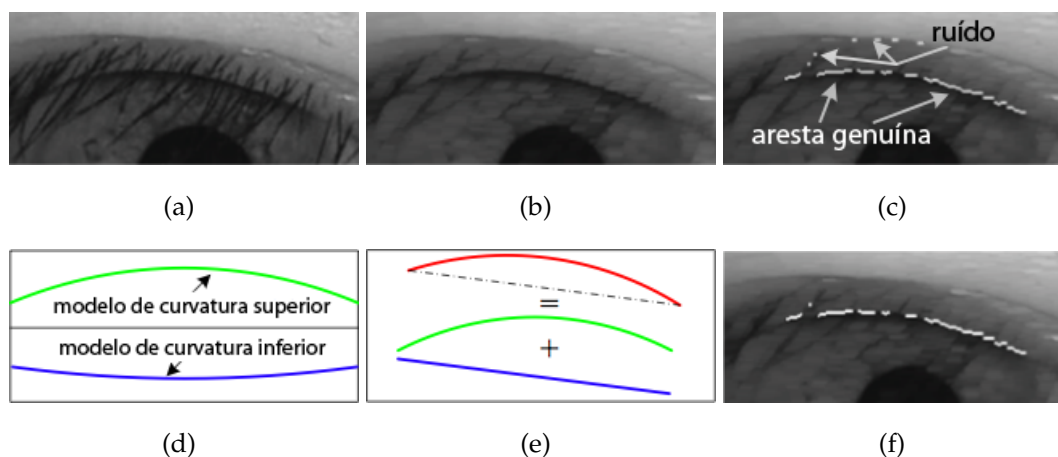


Figura 2.14: Ilustração do método de localização de pálpebras de Tieniu Tan et al. [49]: (a) Imagem original. (b) Remoção de pestanas usando o filtro horizontal de posição de uma dimensão (1-D). (c) Sinalização da fronteira da íris com a pálpebra e ruído. (d) Modelos de curvatura das pálpebras superior e inferior. (e) Decomposição da pálpebra. (f) Aresta genuína da pálpebra superior após eliminação de ruído através do modelo de curvatura [49].

No entanto após a aplicação do filtro, em certa ocasiões, a imagem contém ainda muito ruído pelo que os autores estabeleceram um modelo de curvatura cada pálpebra, superior e inferior. Considerando que, apesar da forma das pálpebras variar consideravelmente de imagem para imagem, todas possuem uma estrutura em forma de arco, os modelos foram concebidos manualmente tendo como base uma

média das formas das pálpebras existentes na base de dados. Na imagem 2.14(c) vemos que o limite da pálpebra pode ser decomposto num arco e num segmento de recta como mostra 2.14(e). Pode-se então subtrair o modelo de curvatura ao arco de 2.14(c), que resulta em algo semelhante a uma recta facilmente detectável com a transformada de Hough [49]. A recta escolhida pela transformada de Hough será a que melhor se ajusta à pálpebra o que exclui os restantes pontos que idealmente serão ruído. Com o ruído eliminado da imagem 2.14(c) resulta a imagem 2.14(f) que é então utilizada para delimitar a pálpebra recorrendo a um ajustamento de uma curva parabólica. O mesmo processo é realizado para a pesquisa da fronteira da pálpebra inferior com o modelo de curvatura adequado exibido na figura 2.14(d).

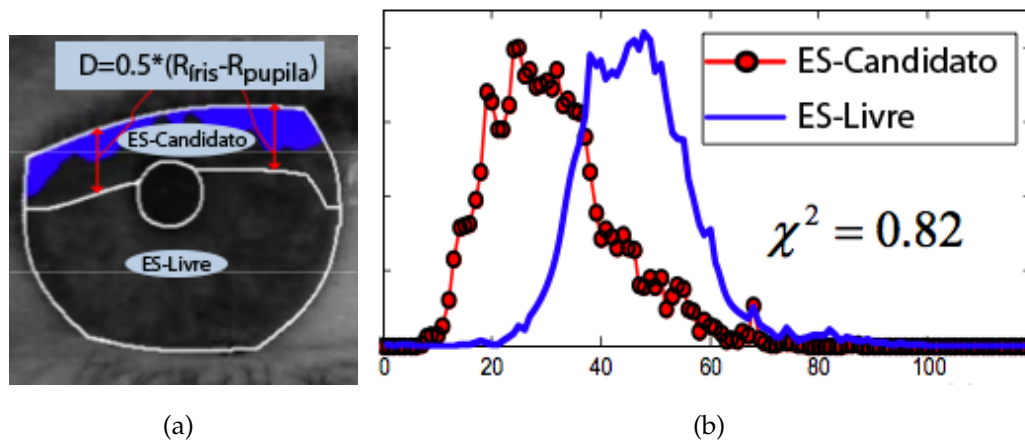


Figura 2.15: Ilustração do método de detecção de sombras e pestanas de Tieniu Tan et al [49]. (a) Divisão da íris em na região livre de sombra e pestanas (ES-Livre) e na região susceptível a oclusão de íris por parte de pestanas e/ou sombras (ES-Candidata). (b) Histogramas de ambas as regiões.

A terceira etapa do algoritmo, a detecção de pestanas e sombras consiste essencialmente na aplicação de um limiar, uma vez que as pestanas e a sombra são geralmente mais escuras que a íris e a pálpebra [49]. O problema da variação da intensidade, de imagem para imagem, torna difícil a selecção do limiar. De acordo com Daugman (ver em [16]), a distribuição de intensidade varia em diferentes regiões da íris, o que pode ser usado na escolha de um limiar que diferencie íris da sombra ou pálpebras [49]. A região da íris segmentada é então dividida em

duas regiões de acordo com a imagem 2.15(a), com uma nova aresta resultante da deslocação da aresta superior da íris na vertical com o valor dado pela fórmula também representada em 2.15(a). A região inferior, considerada livre de pálpebras e sombra, é denominada de ES-Livre. A região superior, ES-Candidata, poderá ter ruído ou não. A detecção de sombras e pálpebras é feita avaliando o desfaseamento entre os histogramas das regiões como mostra 2.15(b), assim como a determinação do limiar de intensidade que destinge os pixels ruído dos pixels íris. Este método foi originalmente desenvolvido para bases de dados de imagens cooperativas como CASIA [26].

2.2.2.2 DMCS

Este método [35] foi submetido ao concurso NICE.1 pelo Department of Micro-electronics and Computer Science, Technical University Of Lodz (DMCS), uma vez que nem artigo nem nos registos do concurso são identificados os autores, este serão referenciados como DMCS. O algoritmo pode ser dividido, de acordo com os autores, em cinco fases como ilustra a figura 2.16.

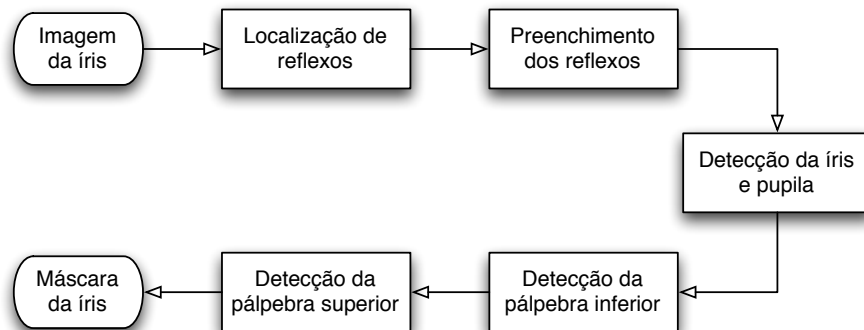


Figura 2.16: Processo de segmentação da íris proposto por DMCS.

A fase inicial tem como propósito a detecção de reflexos na imagem. Para o efeito, a imagem é convertida para o espaço de cor YIQ e depois convertida para uma escala cinza. O reflexo é identificado nesta nova imagem cinza através da aplicação de um limiar, T_{ref} , calculado de forma automática para cada imagem, com a equação 2.7. I_{med} e I_{max} são os valores médio e máximo da intensidade da imagem em escala cinza e P é uma variável de regulação de proporção que toma valores entre 0 e 1.

$$T_{ref} = I_{med} + P \times (I_{max} - I_{med}) \quad (2.7)$$

É criada uma máscara com o pixels que são classificados como reflexos a que é aplicada o operador morfológico de dilatação para incluir pixels de reflexo que não tenham sido detectados.

O preenchimento dos pixels reflexo, é feita através de uma interpolação baseada nos quatro pixels vizinhos não-reflexo mais próximos, nas direcções vertical e horizontal, e aplicada a cada canal do espaço de cor RGB. O método de substituição de reflexo é semelhante ao apresentado por Tieniu Tan *et al.* [49], apenas diferem na equação. O novo valor do reflexo para cada canal é dado pelas equações 2.8 e 2.11.

$$C = \frac{\sum_{i=1}^4 w_i C_i}{\sum_{i=1}^4 w_i}, \quad (2.8)$$

$$w_i = \frac{1}{i}, \quad i = 1, 2, 3, 4 \quad (2.9)$$

O novo valor C atribuído ao pixel tem em consideração os valores dos pixels vizinhos num raio igual a quatro. A influência dos pixels vizinhos no cálculo do novo valor é maior quanto mais próximos estes se encontram do pixel em questão, dando maior peso (w_i) ao pixel C_i localizado à distância i .

Na terceira etapa é utilizado o operador integro-diferencial de Daugman à imagem de escala cinza com os pontos reflexo já corrigidos, para localizar a fronteira esclérica da íris e só depois o operador é utilizado novamente para a fronteira pupilar. O funcionamento do operador é descrito anteriormente em 2.2.1.1.

A localização da pálpebra inferior é feita em quatro passos:

- como pré-processamento desta etapa, é aplicado um filtro de média de amaciamento, de dimensões 3x3 pixels, à mesma imagem utilizada na detecção da íris com o propósito de eliminar pixels de ruído, seguida da aplicação do filtro Gaussiano.
- após a aplicação do filtro só as arestas mais salientes são detectáveis, de seguida é aplicado o detector de arestas horizontal de Sobel.

- para diminuir o número de arestas são removidas as que se encontram próximas da pupila. Como a forma da pálpebra é mais complexa que a de um simples arco, nem todos os pontos da verdadeira aresta coincidem com a forma do arco coincidente, mas decerto estarão na vizinhança. Tendo este factor em conta é aplicado um filtro de amaciamento ao mapa de arestas, $E(x, y)$, com orientação vertical ilustrado na figura seguinte 2.17:

0.25
0.50
0.25

Figura 2.17: Filtro de amaciamento de arestas de DMCS.

- Por fim a pesquisa da pálpebra consiste numa busca exaustiva de vários arcos em que cada candidato é avaliado com a equação 2.10. Na equação 2.11 $I(n)$ representa o número de pontos de aresta que pertencem ao arco n , e $(x_a(n, i), y_a(n, i))$ a coordenada do i -ésimo pixel do arco n . Quanto maior $g_i(n)$, melhor o arco. Singularmente esta equação não tem o desempenho desejado, por esse motivo surgem as seguintes 2.10 e 2.12. Muita informação importante ainda se encontra na imagem original, como por exemplo, as extremidades do arco ideal são fronteira entre a pálpebra e a esclera. Tendo a esclera um valor médio de intensidade bastante alto, pode ser usada como segundo critério na selecção do melhor arco traduzindo-se na fórmula 2.12. As coordenadas do pixel j localizado num extremo do arco n são dadas por $(x_{end}(n, j), y_{end}(n, j))$, e $I(n)$ o número de pixeis pertencentes à extremidade do mesmo arco. Os valores da intensidade da esclera são da imagem em escala cinza inicial, P . O valor y_{offset} corresponde à distância entre os pixeis da extremidade do arco e os pixeis da região da esclera utilizada. Na imagem 2.19, a linha a vermelho representa os pixeis usados como amostra da esclera obtida a partir do deslocamento vertical do arco a verde.

$$g_l(n) = g_{l1} \times g_{l2} \quad (2.10)$$

$$g_{I1}(n) = \frac{1}{I(n)} \sum_{i=0}^{I(n)-1} E(x_a(n, i), y_a(n, i)) \quad (2.11)$$

$$g_{I2}(n) = \frac{1}{J(n)} \sum_{j=0}^{J(n)-1} P(x_{end}(n, j), y_{end}(n, j) - y_{offset}) \quad (2.12)$$

Combinando os dois critérios de selecção de melhor fronteira de pálpebra, a melhor aresta e melhor fronteira com a esclera, é escolhido o arco n que tenha o maior valor com a fórmula 2.10.

A última etapa, a detecção da pálpebra superior, difere significativamente da inferior. Está representado na imagem 2.18(a) o processo de procura. No espaço de cor RGB, é bastante saliente a diferença de cor entre as várias regiões delimitadas pelos rectângulos brancos e vermelhos. Como na detecção da pálpebra inferior, são utilizados três critério de selecção da melhor fronteira possível para a pálpebra superior. Simplificando, são comparados pares das regiões delimitadas a vermelho e branco com o objectivo de escolher o melhor par em que o rectângulo branco esteja sobre a pálpebra e pestanas e o seu par vermelho esteja sobre a esclera, como exemplificado na figura 2.18(b). Cada par de regiões é avaliado segundo a conjugação de três critérios, sendo estes representados pelas fórmulas 2.14, 2.15 e 2.16.




Figura 2.18: Ilustração da detecção da pálpebra superior por DMCS [35]. (a) Várias regiões do processo de localização. Em (b) as regiões seleccionadas para a localização da pálpebra superior".

$$g_u = g_{u1} \times g_{u2} \times g_{u3} \quad (2.13)$$

$$g_{u1} = 1 + \frac{R_{med\ esclera} + G_{med\ esclera} + B_{med\ esclera}}{3} \quad (2.14)$$

$$g_{u2} = \frac{1}{1 + \frac{G_{med\ esclera} + B_{med\ esclera}}{2}} \quad (2.15)$$

$$g_{u3} = \begin{cases} 1 + \Delta_{GB} & \text{se } x \geq 0 \\ 1 & \text{caso contrário} \end{cases} \quad (2.16)$$

$$\Delta_{GB} = \frac{G_{med\ esclera} - G_{med\ palpebra} + B_{med\ esclera} - B_{med\ palpebra}}{2} \quad (2.17)$$

$R_{med\ esclera}$, $G_{med\ esclera}$ e $B_{med\ esclera}$ representam o valor médio da intensidade dos canais R, G e B respectivamente, numa região esclera. Analogamente, $R_{med\ palpebra}$, $G_{med\ palpebra}$ e $B_{med\ palpebra}$ representam os mesmos valores mas de regiões potencialmente pertencentes à pálpebra superior.

Este processo é realizado separadamente em ambos os lados da pupila. Após seleccionados, são calculados os pontos médios entre cada um dos dois pares de regiões. Os dois pontos médios são ligados através de um segmento de recta que será a melhor aproximação à fronteira da pálpebra superior evidenciada a verde escuro na imagem 2.19.




Figura 2.19: Íris segmentada pelo método de DMCS [35].

2.2.2.3 Pedro de Almeida

O diagrama presente na figura 2.20 ilustra o processo de segmentação submetido por Pedro de Almeida ao concurso NICE.1 (ver [2]).

A fase de pré-processamento tem por objectivo preparar a imagem de entrada para as fases seguintes. São considerados reflexo todos os pixels de intensidade,






Figura 2.20: Diagrama do método de segmentação da íris proposto por Almeida [2].

em escala cinza, superior a 250 e todos pertencentes a pequenas áreas com grandes valores de intensidade. Cada pixel reflexo é substituído pela média da metade da vizinhança mais escura para que as etapas seguintes não sejam condicionadas pelo ruído que ele representa. Depois do tratamento dos reflexos, é criada uma imagem de contraste aumentado baseada na diferença de intensidades entre os canais do espaço de cor RGB, com o intuito de facilitar o processo de localização da pupila. As imagens 2.21(a) e 2.21(b) mostram os resultados do tratamento de reflexos e do aumento de contraste.



(a)



(b)

Figura 2.21: Resultado do processo de aumento de contraste utilizado por Almeida [2]. (a) Imagem de entrada. (b) O resultado do processo de aumento de contraste que serve de base à detecção da pupila.

No processo de localização da pupila são tidos em conta vários possíveis centros de pupila através de três métodos de localização sobre a imagem de contraste aumentado. No primeiro, é procurado o quadrado mais escuro, no retângulo mais

escuro da imagem. No segundo método são considerados potenciais pupilas os quadrados mais escuros de várias dimensões em toda a imagem em escala cinza. O terceiro método consiste em utilizar 15 pontos fixos na imagem como sementes para a busca dos potenciais centros de pupila. A partir de cada uma destas potenciais localizações para a pupila, é realizada uma busca “greedy” que procura melhorar a localização do centro e procura o círculo com o melhor raio.

Cada círculo é avaliado por uma função heurística que relaciona a intensidade dos píxeis contidos no interior do círculo com as intensidades de círculos adjacentes. Os melhores círculos são armazenados juntamente com o respectivo valor heurístico para processamento futuro.

A procura de círculos de íris parte do centro do melhor círculo que delimita a pupila, e de outros nove pontos obtidos de modo análogo ao método utilizado na busca da pupila. O método de avaliação de cada círculo candidato é semelhante ao utilizado na procura da pupila. No processo de localização da íris são escolhidos os dez melhores círculos no canal R da imagem reduzida para um quarto das dimensões originais. Os melhores círculos são posteriormente ajustados, em raio e centro, no canal R com as dimensões reais. Os melhores círculos são armazenados para refinamento das fronteiras da íris na etapa seguinte.

A etapa “Combinação entre pupila e íris” procura entre os vários círculos de íris e pupila armazenados, o melhor par avaliado de acordo com a diferença entre os centros e raios da íris e da pupila.

Na etapa de localização de pálpebras o autor assume que estas possuem a forma de um arco e utiliza uma variação do procedimento de pesquisa usado na localização dos círculos da pupila e da íris [2]. A pesquisa é realizada numa imagem em escala cinza obtida a partir da média entre os canais de cor G e B onde o contraste entre a esclera e a pálpebra é mais visível que no canal R [2].

As pálpebras superior e inferior são procuradas a partir de apenas um centro “semente” potencial (cada uma), situados acima e abaixo do centro da íris, respectivamente. O processo de pesquisa é idêntico ao utilizado na íris e pupila: da semente inicial é escolhido o melhor círculo, refinando o centro e o raio. Os vários arcos são avaliados em relação aos seus vizinhos. Fora dos limites circulares da íris procura-se uma transição de claro (esclera) para mais escuro (pele), dentro da íris uma transição de escuro para claro uma vez que a íris apresenta tons mais escuros

que a pele na maioria dos casos.

Na última etapa, tratamento de reflexos, são detectados os reflexos de intensidade mais baixa que não foram identificados na fase de pré-processamento. Apenas o reflexo contido no interior dos limites da íris é detectado. Para cada círculo dentro da íris é calculada a média da intensidade dos pixels e depois cada pixel é comparado com a média do círculo a que pertence e se a diferença for superior a um dado limiar é considerado reflexo. Este processo é feito sobre a imagem cinza criada com a média dos três canais de cor RGB.

A imagem 2.22 é o resultado do método proposto por Almeida à imagem 2.21(a).




Figura 2.22: Imagem segmentada por Almeida com linhas guia indicando os limites da pupila, da íris, e das pálpebras [2] .

Capítulo 3

Método Proposto

Este capítulo é dedicado à descrição do método desenvolvido e proposto neste trabalho. Na secção 3.1 é descrita a base de dados UBIRIS.v2 para a qual o método proposto foi criado.

Na secção 3.2 são enumeradas as experiências realizadas em cada uma das etapas do algoritmo de segmentação proposto.

Na secção 3.3 são enunciadas as medidas de performance utilizadas na avaliação do método proposto, em que parte foram utilizadas na avaliação das participações no concurso NICE.1.

Por fim, na secção 3.4, são apresentados e discutidos os resultados obtidos.

3.1 UBIRIS.v2

Como referido anteriormente, o método desenvolvido neste trabalho foi direccionado para bases de dados de imagens de íris capturadas por sistemas de reconhecimento não-cooperativo, mais especificamente a base de dados UBIRIS.v2. De acordo com os autores Proença *et al.* em [44], a base de dados UBIRIS.v2 foi criada com três preocupações principais: capturar as imagens em movimento, fazer variar a distância entre o sujeito e a câmara, e incorporar factores de ruído que resultam de ambientes não controlados e com variação de iluminação.

A base de dados UBIRIS.v2 é constituída por 11 102 imagens com as dimensões de 800×600 píxeis com 24 bits de profundidade de cor. Foram capturadas imagens de 261 indivíduos voluntários resultando num total de 522 íris diferentes. 90 % dos

UBIRIS v2.0					
Detalhes das imagens cortadas manualmente					
Número total de imagens	11 102				
Dimensões	Largura			Altura	
	800			600	
Formato	.tiff				
Profundidade de cor	24 bit				
Voluntários					
Indivíduos	261				
Número de íris	522				
Etnia	Caucasiana	Asiática		Africana	
	90 %	2 %		8 %	
Pigmentação da íris	Leve	Média		Pesada	
	18.3 %	42.6 %		39.1 %	
Género	Masculino			Feminino	
	54.4 %			45.6 %	
Idade	Intervalos				
	[0,20]	[21,25]	[26,30]	[31,35]	[36,99]
	6.6 %	32.9 %	23.8 %	21.0 %	15.7 %

Tabela 3.1: Tabela com descrição detalhada da base de dados de imagens UBIRIS.v2.

participantes são caucasianos, 2 % asiáticos e 8% de origem africana. A cor da íris é dada pela quantidade do pigmento melanina presente (quanto maior mais escura é a íris). 18.3 % das íris são levemente pigmentadas (íris claras), 42.6 % possuem uma pigmentação média e 39.1 % pesada (olhos escuros). 54 % dos voluntários são do sexo masculino e 45.6 % do sexo feminino. 6.6 % voluntários tem idade inferior 21 anos, 32.9 % entre 21 e 30, 23.8 % entre 26 e 30, 21 % entre 31 e 35 e 15.7 % com idade superior a 35 anos. A tabela 3.1 contém uma descrição resumida dos detalhes da base de dados enunciados anteriormente.

Como ilustra a figura 3.1, a estrutura utilizada na captura das imagens da base de dados foi instalada numa sala com fontes de luz natural e artificial. No chão foram colocados alguns marcos a várias distâncias compreendidas entre os três e dez metros do dispositivo de captura, e foram pedidos voluntários para a aquisição de imagens. Foram realizadas duas sessões distintas de recolha de imagens, cada

uma com duas semanas de duração e separadas por uma semana de intervalo. Entre as duas sessões diferem a orientação e localização do dispositivo de captura e as fontes de luz artificial. A alteração das condições de aquisição de imagem tem por objectivo transportar para a base de dados factores existentes num sistema de reconhecimento com captura de imagem não cooperativa.




Figura 3.1: Ilustração da estrutura de aquisição de imagens da base de dados UBIRIS.v2, apresentada no artigo [44], com dispositivos de captura de imagem (A,B), fontes de luz artificial e natural (C,D) e localização do voluntário (E).

Aos voluntários foi pedido que se deslocassem com velocidade inferior da normal ao longo dos marcos posicionados no chão, e que olhassem para alguns marcos laterais o que obrigou a uma rotação da cabeça e dos olhos resultando em três imagens por metro, entre os quatro e oito metros. No total foram capturadas quinze imagens por olho e por sessão. A cooperação exigida aos voluntários teve o único objectivo obter um número fixo de imagens utilizáveis por sujeito e por sessão.

Na figura 3.2 é possível constatar alguns dos factores de ruído presentes em imagens da base de dados UBIRIS.v2. A imagem 3.2(a) é uma boa imagem de íris quando comparada com as restantes da base de dados apesar de apresentar algum ruído na forma de reflexo na pupila e oclusão mínima por parte de pálpebras e pestanas.

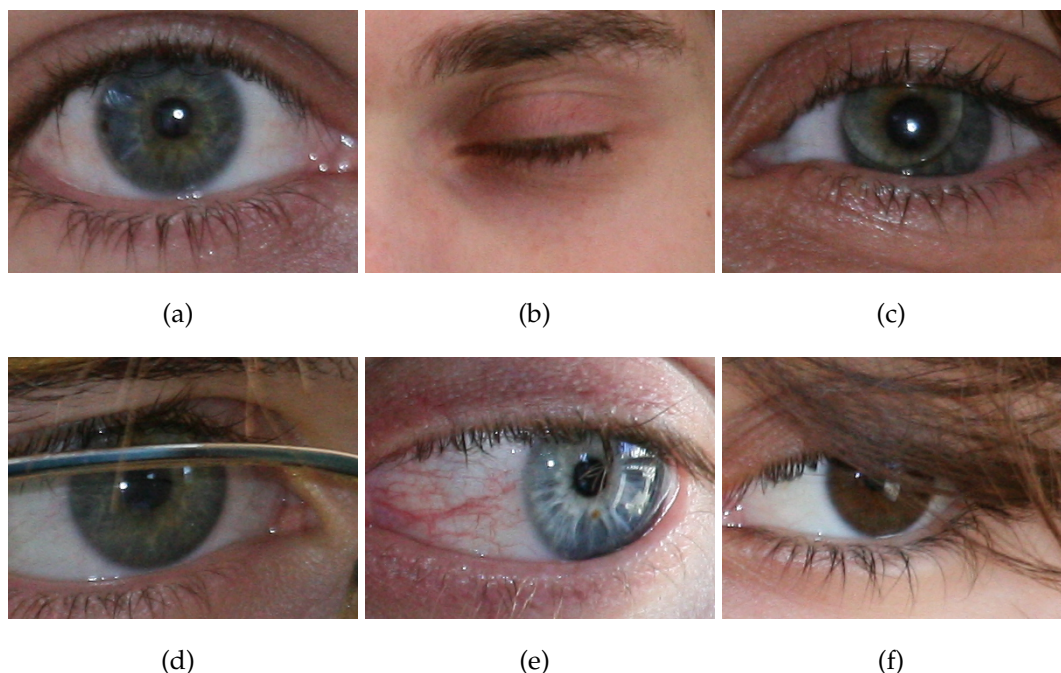


Figura 3.2: Imagens da base de dados UBIRIS.v2. 3.2(a) Imagem de íris com boa qualidade. 3.2(b) Imagem de olho fechado, 3.2(c) Imagem de íris sobreposta por lente de contacto. 3.2(d) Imagem de íris obstruída por armação de óculos. 3.2(e) Imagem de íris enviesada e obstruída por reflexo e pestanas. 3.2(f) Imagem de íris ocluída por cabelo.

Para o concurso NICE.1 foi apenas disponibilizada uma pequena parte da base de dados UBIRIS.v2. O conjunto de imagens cedido para os participantes contém 500 exemplares, em que as dimensões foram reduzidas para metade (400X300), e respectivos mapas binários com localização de píxeis de íris sem ruído. Todas as conclusões atingidas e testes realizados durante este trabalho, tiveram por base apenas o mesmo conjunto de 500 imagens cedidas aos participantes. Neste trabalho, o conjunto foi dividido em dois subconjuntos, de treino e de teste, com o primeiro constituído por 10 % do conjunto inicial e o segundo pelos 90 % restantes.

3.2 Desenvolvimento

O presente trabalho teve como objectivo desenvolver um método de segmentação de íris rápido e eficiente. De forma a evitar métodos de detecção de círculos que tendem a ser algo morosos, foi empregue uma abordagem que interpreta a

segmentação da íris como um problema de reconhecimento de padrões.

Um conjunto de características é extraído de cada amostra e passado a um método de aprendizagem automática que classifica cada pixel como íris ou não-íris com base nas características extraídas.

Na figura 3.3 são ilustradas as várias etapas do desenvolvimento do método proposto, cada uma descrita nas subsecções seguintes.

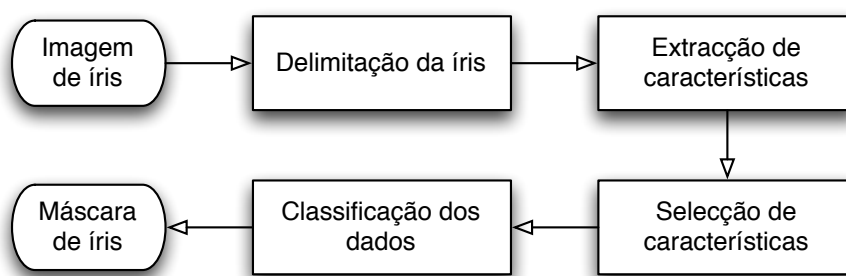


Figura 3.3: Ilustração das etapas de desenvolvimento do método proposto.

3.2.1 Delimitação da íris

A delimitação inicial da íris tem por objectivo diminuir o número de pixels que têm efectivamente de ser classificados. Em média apenas 7 % dos píxeis das imagens da UBIRIS.v2 são íris, o que resulta num enorme desperdício de tempo se todos os píxeis da imagem forem classificados pelo método de aprendizagem automática. Se a localização da íris puder ser restringida a uma pequena área da imagem, será possível poupar muito tempo de processamento.

A ideia de delimitar a zona de localização da íris surgiu com o estudo do algoritmo proposto por Tieniu Tan *et al.* [49], descrito anteriormente na secção 2.2.2.1. Embora o método utilizado pelos autores tenha muito bons resultados, o processo de *clustering* tem um tempo de execução bastante considerável que não pode ser ignorado.

Em alternativa, Almeida [2] (ver 2.2.2.3) apresenta um método de localização da pupila baseado na procura do quadrado mais escuro numa imagem de contraste aumentado. O tempo de execução apresentado pelo método é compatível com os objectivos definidos para o método proposto.

A zona que limita a localização da íris é definida pelo quadrado de lado 201 píxeis, centrado no quadrado mais escuro. De acordo com Yu Chen em [9], o diâmetro das íris na base de dados varia entre os 75 e os 190 píxeis. Confirmando este facto no conjunto de treino, a dimensão da zona foi definida pelo maior diâmetro adicionado a uma margem de segurança de 11 píxeis para diminuir a possibilidade de a íris não estar inteiramente incluída. A margem de segurança inclui um pixel extra para que a zona delimitada tenha o quadrado mais escuro centrado num pixel específico (o que exige que o lado do quadrado tenha um número ímpar de píxeis).

3.2.1.1 Detecção de reflexo

A detecção e tratamento do reflexo na imagem é necessária para melhorar a performance do método de detecção da pupila descrito em 3.2.1.2. Nas imagens da UBIRIS.v2 a maioria do reflexo encontra-se na íris ou na pupila. A detecção da pupila baseia-se na sua cor escura e poderá falhar se a pupila estiver ocluída por reflexo.

Na maior parte dos métodos de segmentação estudados, a detecção de reflexo passa apenas por a aplicação de um limiar fixo ou adaptativo (ver [49], [50] e [2]). No artigo [49] os autores consideram ruído os 5 % píxeis mais claros da imagem. Em muitas imagens resulta num classificação incorrecta de zonas de pele ou esclera como reflexo porque se parte do princípio que em todas imagens existe reflexo mesmo quando não há. Porém a substituição dos reflexos por valores obtidos com a interpolação bi-linear (ver 2.2.2.1), permite corrigir estes erros.

Com maiores taxas de acerto no conjunto de treino de 50 imagens empregue neste trabalho, consideramos reflexo os 10 % píxeis mais intensos do canal R presentes na imagem. As intensidades dos píxeis tomados por ruído localizados sobre a pupila são substituídas pelo valor 23 obtido a partir da média dos píxeis da pupila livres de ruído das imagens do conjunto de treino. Os píxeis classificados como reflexo sobre a íris podem influenciar negativamente a detecção da pupila. Ainda assim a localização da íris pode não ser afectada e estar incluída na área delimitada. Os restantes píxeis reflexo localizados em regiões da pele, na imagem de contraste aumentado têm como vizinhança valores muito elevados o que os exclui como pertencentes à pupila, logo o seu valor na imagem de contraste não é actualizado. O uso da interpolação bi-linear para atribuição de valores aos píxeis reflexo de

acordo com os valores das suas vizinhanças foi posto de parte porque o seu custo computacional não se justifica nesta tarefa.

3.2.1.2 Detecção da pupila

Numa primeira fase, é aplicado o método de aumento de contraste baseado na diferença entre os canais de cor do espaço RGB proposto em [2]. A figura 3.4(b) resulta da aplicação do método de aumento de contraste à imagem 3.4(a).




Figura 3.4: Delimitação da localização da íris. 3.4(a) Imagem original. 3.4(b) Imagem de contraste aumentado com reflexos compensados. 3.4(c) Imagem com a localização da pupila (quadrado azul) e a zona delimitada da íris (quadrado vermelho).

A pesquisa da pupila começa na procura do rectângulo vertical mais escuro na imagem de contraste aumentado, com altura igual à da imagem e largura de 75 píxeis. Depois de localizado o rectângulo mais escuro, é procurado no seu interior o quadrado mais escuro de lado igual à largura do rectângulo.

O valor da largura do rectângulo e do quadrado foi escolhido a partir do valor com menor erro na tabela 3.2. Os valores da tabela foram obtidos sobre as imagens do conjunto de treino. A classificação de erros na detecção da pupila foi feita manualmente, sendo que uma detecção errada corresponde a uma maioria da área da pupila encontrar-se fora do quadrado mais escuro (quadrado azul na figura 3.4(c)). A detecção incorrecta da localização da pupila deve-se sempre à presença de cabelo, sobrancelhas ou óculos nas imagens.

Detecção do quadrado mais escuro							
Largura de quadrado (píxeis)	25	51	75	101	125	151	201
Erro (%)	20	14	2	6	4	6	6

Tabela 3.2: Resultados do método de detecção da pupila para várias larguras do quadrado mais escuro.

3.2.2 Extracção de características

A delimitação da íris diminui para aproximadamente um terço o número de píxeis dos quais é necessário extrair características e classificar. No total foram recolhidas 189 características com base na observação e estudo das imagens do conjunto de treino e de alguns métodos de segmentação.

As características extraídas das imagens são descritas a seguir:

- Posição do pixel na imagem. Cada pixel na imagem pode ser representado pelas suas coordenadas, linha e coluna que constituem duas das características utilizadas.
- Intensidade do pixel. Na maioria das bases de dados existentes, a intensidade de um pixel resume-se apenas a um valor uma vez que as imagens se apresentam em escala cinza. Na base de dados UBIRIS.v2, cada imagem é representada no espaço de cor RGB dividindo a intensidade do pixel em três valores. Para além do espaço RGB, foram utilizados como características outro espaços de representação de cor, apesar de certo modo todos os conterem a mesma informação. Em alguns artigos sobre segmentação, os métodos apresentados têm por base a aplicação de um limiar à intensidade em outros espaços de cor como HSV ou YCbCr (ver [48] [46] [9]). Por este motivo foram adicionados à lista de características cada um dos canais dos quatro espaços de cor RGB, HSV, YCbCr e YIQ resultando num total de doze características.
- Eliminação de pele. São utilizadas duas características que consistem em duas imagens binárias resultantes de dois métodos de detecção de pele. Os píxeis identificados pelos métodos como sendo pele tomam valor 1 enquanto os restantes têm valor 0. O primeiro método consiste na aplicação de um limiar à imagem, em que todos os valores que transcendam o limiar são considerados pele. Esclera e reflexos também são incluídos na mesma categoria. O

segundo método é baseado num método de segmentação de faces proposto por Sawangsri *et al.* [46] em que são considerados pele os píxeis que, no espaço YCbCr, estejam num determinado intervalo dos canais Cb e Cr.

- Alinhamento com a maior área de Y. Este método consiste na identificação das linhas em que se encontra a íris através da detecção da esclera. O método de localização da esclera consiste na procura da maior área no canal Y do espaço YCbCr acima de um determinado limiar. A localização no eixo vertical da íris coincide sempre com a da esclera, desde que a cabeça esteja numa posição vertical. Cada pixel assume o valor 1 se pertencer a uma das linhas seleccionadas, caso contrário tem valor 0.
- Imagem média RGB. Esta característica consiste no valor do pixel na imagem representada numa escala cinza resultante da média de cada pixel de cada canal de cor do espaço RGB.
- Distância ao ponto mais claro. Na grande maioria dos casos, o reflexo mais acentuado na imagem situa-se na íris, pupila ou na esclera. Por esta razão, os píxeis mais próximos do reflexo mais intenso na imagem, têm uma maior probabilidade de serem íris.
- Filtro de íris. O valor de cada pixel consiste no produto entre o pixel correspondente numa máscara de probabilidade de localização de íris obtida com as 50 imagens usadas no conjunto de treino, e o pixel correspondente num canal de cor. Existe uma característica para cada canal de cor dos quatro espaços de cor utilizados.
- Contraste aumentado. É usado como característica o valor do pixel na imagem resultante do aumento de contraste para a detecção da pupila pois salienta a localização da pupila que não deve ser confundida com íris e tem o mesmo efeito de um método de eliminação de pele uma vez que os tons mais claros da imagem original passam a ter valor máximo de intensidade.
- Média linha-coluna. Esta característica representa em cada pixel, a média do valor de todos os píxeis na linha e na coluna do pixel em questão. Este cálculo estatístico é aplicado aos doze canais de cor referidos anteriormente dando origem a doze características.

- Média. Cada pixel tem como característica, para cada canal dos quatro espaços de cor, a média de intensidade de todos os píxeis.
- Média na vizinhança. São também usadas como características a média da vizinhança de cada pixel para cada um dos canais de cor. As dimensões das janelas tomam três valores diferentes: 3x3, 5x5 e 7x7.
- Desvio Padrão. Também o desvio padrão é calculado para a imagem total nos vários espaços de cor, como em pequenas vizinhanças de 3x3, 5x5 e 7x7.
- Entropia. De modo análogo às medidas estatísticas Média e Desvio Padrão, a Entropia é calcula para a imagem total e para cada uma das janelas de lado 3, 5 e 7.

Grande parte das características reunidas baseia-se em valores estatísticos que obtiveram bons resultados no trabalho de Broussard *et al.* [6]. O número de características recolhidas nesta etapa não intervém no tempo de execução do método proposto, porque elas serão avaliadas e seleccionadas, e apenas as melhores serão utilizadas no algoritmo final.

3.2.3 Selecção de Características

O processo de selecção de características consiste na escolha dum subconjunto das características produzidas a partir do sinal original, sem perder, na medida do possível, a capacidade discriminante. A selecção de características ajuda a compreender melhor o conjunto de dados na medida em que salienta as melhores características.

O aumento do número de características, para o mesmo número de medições, pode melhorar o desempenho de um classificador ao introduzir mais informação, ou piorar o desempenho se introduzir mais ruído, além de aumentar a dimensionalidade do problema. O aumento da dimensionalidade diminui a densidade das amostras no espaço do problema tornando a representação do problema mais difusa, e dificultando a aprendizagem do sistema de reconhecimento de padrões, podendo degradar o seu desempenho. Este problema é conhecido por “Maldição da Dimensionalidade” (da expressão inglesa “*Curse of Dimensionality*”). Outro problema resultante do uso de muitas características é o aumento da probabilidade

de algumas serem redundantes e introduzirem a mesma informação ao sistema, o que não só é inútil como pode prejudicar o desempenho do sistema.

Além disso, a redução do número de características permite reduzir o custo computacional tanto no processo de aprendizagem como no de classificação. Esta vantagem é vital em sistemas em que um tempo de execução mínimo é um factor essencial, como é o caso do método proposto.

Com 50 imagens constituídas por 120 000 píxeis cada, o conjunto de treino perfaz um total de 6 milhões de amostras. Devido à desigualdade entre o número de píxeis íris e não-íris, e para que a selecção de características seja mais equilibrada, são seleccionados do conjunto de treino todos os píxeis íris e igual número de píxeis não-íris resultando em 1 091 432 amostras. Ainda assim, o conjunto de dados é demasiado elevado para ser usado no treino de alguns classificadores. Por esse motivo, novo conjunto de treino usado na selecção de características e no treino de classificadores foi reduzido para o mesmo número de píxeis íris e não-íris de apenas 30 imagens do conjunto de treino inicial (456 735 amostras). Os píxeis não-íris são seleccionados aleatoriamente de dentro da janela de localização da íris.

3.2.3.1 Método de selecção de características

O uso de um método de selecção de características permitiu a recolha de características com uma maior liberdade uma vez que após a avaliação apenas seriam utilizadas as melhores. As características podem ser seleccionadas de várias modos, entre eles a Máxima-Relevância [38] e [17], que selecciona as características que mais se correlacionam com a variável de classe. Matematicamente, a Máxima-Relevância traduz-se na procura de características do conjunto total S que satisfaçam a equação 3.1, onde $I(x_i; c)$ representa a Informação Mútua entre a característica x_i e a classe c definida nos termos das suas funções de densidade probabilística $p(x_i)$, $p(c)$ e $p(x_i, c)$ na equação 3.2.

$$\max D(S, c), D = \frac{1}{|S|} \sum_{x_i \in S} I(x_i; c) \quad (3.1)$$

$$I(x_i, c) = \int \int p(x_i, c) \log \frac{p(x_i, c)}{p(x_i)p(c)} dx_i dc \quad (3.2)$$

Por outro lado, as características podem ser seleccionadas por serem distantes entre si e ainda assim terem uma grande correlação com a variável de classe. O

algoritmo “mínima-Redundância-Máxima-Relevância” mRMR proposto por Peng *et al.* em [38] e [17] utiliza este critério na ordenação das características. A Mínima Redundância entre duas características, x_i e x_j , é dada pela equação 3.3.

$$\min R(S), R = \frac{1}{|S|^2} \sum_{x_i, x_j \in S} I(x_i, x_j) \quad (3.3)$$

O algoritmo mRMR combina as medidas de Máxima-Relevância e Mínima-Redundância segundo a equação 3.4.

$$\max \Phi(D, R), \Phi = D - R \quad (3.4)$$

Métodos de Selecção de Características				
mRMR			Máxima Relevância	
Ordem	Índice	Característica	Índice	Característica
1	33	Contraste Aumentado	33	Contraste Aumentado
2	27	Filtro íris Y - YIQ	87	Média 7x7 Q - YIQ
3	159	Entropia 3x3 Q - YIQ	75	Média 5x5 Q - YIQ
4	31	Filtro íris Cb - YCbCr	76	Média 5x5 R - RGB
5	6	Eliminação de pele 1	64	Média 3x3 R - RGB
6	7	Eliminação de pele 2	88	Média 7x7 R - RGB
7	163	Entropia 3x3 Y - YCbCr	3	R - RGB
8	87	Média 7x7 Q - YIQ	63	Média 3x3 Q - YIQ
9	17	Em linha Y - YCbCr	13	Q - YIQ
10	3	R - RGB	60	Média 3x3 V - HSV

Tabela 3.3: Resultados da selecção de características de mRMR e Máxima Relevância

A tabela 3.3 mostra as dez melhores características seleccionadas pelos métodos mRMR e Máxima Relevância. No artigo [38] encontram-se resultados de comparações exaustivas entre os dois métodos, em que o mRMR mostra ser mais eficiente. Os resultados foram obtidos sobre igual número de píxeis de íris e não íris de 30 imagens do conjunto de treino, o mesmo conjunto usado na aprendizagem dos métodos de classificação. No anexo A encontra-se os resultados completos devolvidos pelo método mRMR.

3.2.4 Classificação dos dados

Nesta etapa, os algoritmos usam as características recolhidas e seleccionadas na sua aprendizagem com o propósito de extraírem conhecimento do conjunto de treino e classificarem com sucesso novas imagens de íris.

Devido à importância do factor tempo na execução do algoritmo, todos os algoritmos classificados como métodos de aprendizagem “lazy” (como é o caso do k-vizinhos mais próximos) foram postos de parte, uma vez que a aprendizagem tem lugar durante o processo de classificação.

Outros métodos de aprendizagem automática não puderam ser utilizados devido às dimensões do problema, por tornarem o processo de aprendizagem impossível ou exigirem um elevado tempo de execução na etapa de classificação. São exemplos das situações anteriores as máquinas de vectores de suporte, em que os recursos computacionais disponíveis só conseguiram concluir a aprendizagem com apenas 30 000 exemplos (que não chegam a constituir o conjunto de dados recolhido de três imagens). Outro dos métodos de aprendizagem automática que mostrou não ser compatível com as exigências da proposta foi a árvore de decisão. As árvores de decisão criadas atingiram profundidades elevadas, o que na classificação de todos os píxeis numa janela de 201×201 resulta num tempo de execução superior a 5 segundos com poucas características.

Dos métodos de aprendizagem restantes foram usados dois dos mais robustos e comuns, as Redes Neurais e o Naive Bayes.

3.2.4.1 Rede Neuronal

As Redes Neurais são um método de Aprendizagem Automática inspirado na estrutura e funcionamento das redes neuronais biológicas. A Rede Neuronal consiste num grupo de neurónios artificiais (que simulam o funcionamento de um neurónio biológico) ligados entre si.

A figura 3.5 ilustra a estrutura de um neurónio artificial, em que ao conjunto de variáveis de entrada (x_1, x_2, \dots, x_n) no neurónio é aplicado um somatório com os pesos (w_1, w_2, \dots, w_n) correspondentes (equação 3.5).

$$S = \sum_{i=1}^n x_i w_i \quad (3.5)$$

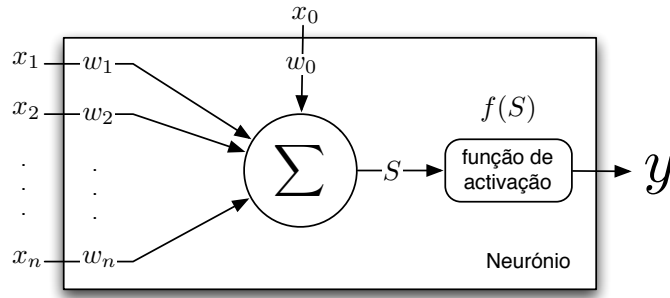


Figura 3.5: Ilustração de um neurónio artificial.

O resultado é passado por uma função de activação $y = f(S)$ que devolve a saída do neurónio. A entrada x_0 denominada de viés permite deslocar a função de activação, se for negativo a soma pesada das características tem que superar o seu valor para que o y tenha valor positivo.

O método mais comum de treino das Redes Neurais é a “descida do gradiente” que consiste na procura dos melhores pesos (os que minimizam a função de erro). Os pesos são avaliados por uma função de erro ou custo que permite saber o quão próximo da verdadeira classe se encontra a saída do neurónio. A função mais comum é o erro quadrático médio (equação 3.6), dado pelo somatório do quadrado das diferenças entre cada previsão do neurónio y_i e a classe real d_i , de cada ponto i do conjunto de treino P .

$$e = \sum_{i=1}^P (d_i - y_i)^2 \quad (3.6)$$

Os neurónios individuais apenas conseguem distinguir pontos do espaço de entrada que sejam linearmente separáveis. Para a resolução de problemas não-lineares são usadas as Redes Neurais.

As Redes Neurais são compostas por neurónios agrupados por camadas como mostra a figura 3.6, em que as saídas dos neurónios duma camada são as entradas dos neurónios da camada seguinte. Cada círculo na figura 3.6 representa um neurónio artificial completo como o ilustrado na figura 3.5.

As Redes Neurais utilizadas neste trabalho apresentam a arquitectura da figura 3.6, uma camada de entrada, uma camada escondida e outra de saída. As saídas dos neurónios de uma camada são as entradas dos neurónios da camada seguinte. O que implica que a informação circule apenas num sentido na rede (*Feed-Forward Neural*

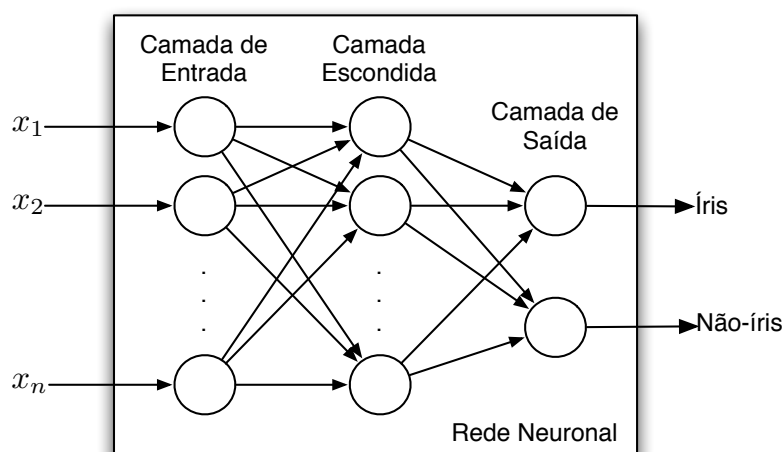


Figura 3.6: Ilustração da arquitectura da rede neuronal utilizada.

Network (FFNN)). As Redes Neurais FFNN treinadas com retropropagação do erro [45] estão entre as mais versáteis e populares [37]. Foi mostrado por diversos investigadores que Redes Neurais FFNN com apenas uma camada escondida com funções de activação não-lineares são classificadores universais [24], [11], [25] e [27]. No nosso caso, o número de neurónios usados nas camadas de entrada e escondida é igual ao número de características do vector de entrada. Cada característica de uma amostra está ligada a um dos neurónios da camada de entrada. A camada de saída tem dois neurónios dando à rede dois valores de saída por cada vector aplicado à entrada. As saídas dos dois neurónios são dois valores compreendidos entre 0 e 1 que podem ser interpretados como a probabilidade do vector de entrada ser um pixel íris para o primeiro neurónio, e para o segundo a probabilidade de ser não íris.

O treino das redes neuronais é uma etapa e com algum custo temporal, proporcional à dimensão do conjunto de treino e ao número de características. Por outro lado, a classificação de novos dados é bastante rápida pois consiste apenas em operações de somas pesadas por cada neurónio da rede.

3.2.4.2 Naive Bayes

A teoria Bayesiana é uma abordagem estatística fundamental no problema de classificação de padrões [19]. O teorema de Bayes mostra como a probabilidade

do acontecimento A , depois de observado B , está relacionada com as probabilidades dos acontecimentos A , B e de B dado A anteriores ao acontecimento A , pela equação 3.7. Esta afirmação implica que um acontecimento tem uma maior confirmação caso tenha sido mais improvável antes de ser observado [29].

$$p(A) = \frac{p(A|B) \times p(B)}{p(B|A)} \quad (3.7)$$

O classificador Naive Bayes encara o processo de classificação em termos probabilísticos com base no teorema de Bayes, assumindo que todas as características são independentes. Tendo por base a equação 3.7, a probabilidade da amostra A com n características (x_1, x_2, \dots, x_n) pertencer à classe c é dada pela equação 3.8.

$$p(c|A) = p(c|x_1, x_2, \dots, x_n) = \frac{p(x_1, x_2, \dots, x_n|c) \times p(c)}{p(x_1, x_2, \dots, x_n)} \quad (3.8)$$

Assumindo que as características (x_1, x_2, \dots, x_n) são independentes entre si, $p(x_1, x_2, \dots, x_n|c)$ é dado pela equação 3.9.

$$p(x_1, x_2, \dots, x_n|c) = p(x_1|c) \times p(x_2|c) \times \dots \times p(x_n|c) = \prod_{i=1}^n p(x_i|c) \quad (3.9)$$

O classificador Naive Bayes atribui a A com a classe com maior probabilidade dado A , a classe 1 no caso da equação 3.10 se verificar.

$$p(c|A) = \frac{p(C = 1|A)}{p(C = 0|A)} \geq 1 \quad (3.10)$$

Numa única equação, a classificação de uma amostra A pelo Naive Bayes é dada por 3.11

$$nb = \frac{p(C = 1)}{p(C = 0)} \prod_{i=1}^n \frac{p(x_i|C = 1)}{p(x_i|C = 0)} \quad (3.11)$$

O classificador Naive Bayes tem um rápido processo de aprendizagem porque consiste apenas no cálculo de probabilidades do conjunto de treino. O processo de classificação é igualmente rápido uma vez que as probabilidades dos acontecimentos anteriores (conjunto de treino) encontram-se armazenados, e a execução da equação 3.11 é quase imediata.

3.3 Avaliação de desempenho

A avaliação de desempenho do método desenvolvido neste trabalho foi efectuada através das duas medidas de erro propostas pelo concurso NICE.1 e pela área debaixo da curva ROC em inglês, *Area Under Curve* (AUC) (ver a sub-secção 3.3.2). São usadas as medidas do concurso para que os resultados do método possam ser comparados com os dos participantes. Apesar de serem calculadas as três medidas, o desenvolvimento do método foi direccionado para a minimização da primeira medida de erro do concurso, pois foi pela qual os participantes foram avaliados. As medidas de desempenho estão descritas nas subsecções seguintes.

3.3.1 Medidas de erro de NICE.1

A primeira medida de erro (E_i^1) consiste na razão entre o número de píxeis classificados incorrectamente e o número total de píxeis da imagem i , através da equação 3.12. Nesta equação, r e c são o número de linhas e colunas da imagem e $O(c', r')$ $C(c', r')$ representam píxeis das imagens da saída do algoritmo e da máscara binária. O operador ou-exclusivo (\otimes) devolve 1 se os píxeis forem diferentes e devolve 0 se forem iguais.

$$E_i^1 = \frac{1}{c \times r} \sum_{c'} \sum_{r'} O(c', r') \otimes C(c', r') \quad (3.12)$$

A segunda medida de erro (E_i^2), calculada pela equação 3.13, tem por objectivo compensar a desproporção entre o número de píxeis íris e não-íris nas imagens, recorrendo a uma média entre a Taxa de Falsos Positivos (FPR) e Taxa de Falsos Negativos (FNR).

$$E_i^2 = 0.5 \times \text{FPR} + 0.5 \times \text{FNR} \quad (3.13)$$

Os valores de FPR e FNR para cada imagem são calculados com as equações 3.14 e 3.15.

$$\text{FPR} = \frac{\text{número de falsos positivos}}{\text{número de instâncias negativas}} \quad (3.14)$$

$$\text{FNR} = \frac{\text{número de falsos negativos}}{\text{número de instâncias positivas}} \quad (3.15)$$

Os valores dos erros E^1 e E^2 de cada método de segmentação em todo o conjunto de teste são obtidos pela média dos erros em cada imagem. No concurso NICE.1 os concorrentes foram classificados apenas pela medida de erro E^1 , que varia no intervalo $[0,1]$ com “1” a representar o pior valor e “0” o melhor.

3.3.2 Curva de ROC

Depois do treino de um classificador é utilizado um conjunto de teste para avaliar a precisão do classificador. O problema de avaliar a precisão reside na interpretação dos resultados dos classificadores. No caso concreto dos classificadores utilizados neste trabalho as Redes Neurais tem duas saídas, uma que avalia o pixel como sendo íris e o outro como não-íris, e o Naive Bayes devolve as probabilidade do pixel ser íris e ser não-íris. O método mais usual consiste na escolha da classe com maior probabilidade (Naive Bayes) ou na classe correspondente ao neurónio com maior valor de saída, no caso das Redes Neurais.




Figura 3.7: Interpretação das curvas de ROC.

No entanto, em alternativa pode ser aplicado um limiar às saídas dos classifi-

cadadores que minimize o erro no conjunto de teste, e provavelmente na aplicação prática. A curva de *Receiver-Operating Characteristic* (ROC) mostra a influência da variação desse limiar na Taxa de Verdadeiros Positivos (TPR) e na FPR.

A figura 3.7 ajuda na interpretação das curvas de ROC, em que a vermelho está sinalizada a curva (ou linha) que simboliza a classificação aleatória de um conjunto de teste.

O gráfico da figura 3.8 representa duas curvas ROC resultantes de Redes Neurais treinadas com as 5 e 50 melhores características.




Figura 3.8: Curvas ROC resultantes das Rede Neurais de 5 e 50 características.

Quanto mais próxima dos lados esquerdo e superior do gráfico a curva estiver, melhor é o desempenho do classificador. A medida utilizada para expressar o valor de aproximação da curva à curva ideal é a AUC. Esta medida representa melhor a qualidade do classificador que as medidas de erro mais comuns que avaliam com base num limiar ótimo para o conjunto de teste.

Segundo Tom Fawcet, a AUC é igual à probabilidade de um classificador classificar uma instância escolhida ao acaso com maior certeza do que uma instância negativa igualmente escolhida aleatoriamente [21]. Ling *et al.* [33] provam que a AUC é mais consistente e discriminante que as medidas de precisão simples.

3.4 Discussão dos resultados

Inicialmente foram utilizados seis conjuntos de dados de treino para cada um dos classificadores, constituídos pelas 5, 10, 15, 20, 35 e 50 melhores características para conseguir visualizar, globalmente, o comportamento dos classificadores. Depois, o desempenho dos classificadores Rede Neuronal e Naive Bayes treinados sobre esses dados, foi avaliado sobre o conjunto de teste recorrendo à AUC, que é melhor que a precisão na avaliação de algoritmos de aprendizagem [33]. O gráfico da figura 3.9 mostra a variação da AUC para os vários conjuntos de características utilizados.




Figura 3.9: AUC dos classificadores para os conjuntos de características iniciais.

Na tabela 3.4 encontram-se os dados numéricos do gráfico da figura 3.9.

Só foram utilizados conjuntos até 50 características porque são irrelevantes os desempenhos dos classificadores para conjunto maiores pois a execução deixa de cumprir o critério de velocidade.

No gráfico da figura 3.9 é possível observar que, não só as Redes Neuronais apresentam melhores desempenhos que o Naive Bayes para menores números de características, como que os melhores resultados rondam os conjuntos com 10 características. A descida da AUC para um maior número de características nas Redes Neuronais pode dever-se ao facto de o aumento das características introduzir

Número de Características	AUC	
	Redes Neurais	Naive Bayes
5	0.9669	0.9501
10	0.9699	0.9570
15	0.9631	0.9566
20	0.9629	0.9557
35	0.9634	0.9552
50	0.9386	0.9581

Tabela 3.4: AUC dos classificadores para os conjuntos de características iniciais.

ruído no conjunto de treino, como referido anteriormente.

Nas figuras 3.10 e 3.11 encontram-se os gráficos com os erros de cada classificador para cada conjunto de características, de acordo com as medidas do concurso NICE.1, obtidos com o conjunto de teste. Os erros presentes nos gráficos das figuras 3.10 e 3.11 e nas tabelas 3.5 e 3.6 foram obtidos com vários limiares maximizando E^1 e E^2 . Os erros do classificador Naive Bayes com aplicação do melhor limiar coincidem com o critério da classe com maior valor de saída, resultando nas linhas sobrepostas no gráfico da figura 3.10.




Figura 3.10: Gráfico com a variação do erro E^1 com o número de características utilizadas pelas Redes Neurais e Naive Bayes.




Figura 3.11: Gráfico com a variação do erro E^2 com o número de características utilizadas pelas Redes Neurais e Naive Bayes.

Apesar do concurso NICE.1 usar E^1 como medida de classificação dos concorrentes, são apresentados os resultados nas tabelas 3.5 e 3.6 para mostrar a influência da maximização de uma medida no valor da outra e vice-versa.

Na tabela 3.5 estão dispostos os valores de E^1 para limiares que minimizam E^1 e limiares que minimizam E^2 , obtidos pelos classificadores. Os valores de E^2 na tabela 3.6 foram obtidos nas mesmas condições com os mesmos limiares.

Nº Características	E^1			
	Redes Neurais		Naive Bayes	
	Min E^1	Min E^2	Min E^1	Min E^2
5	0.0474	0.0779	0.0569	0.0833
10	0.0381	0.0731	0.0574	0.0969
15	0.0375	0.0717	0.0576	0.0945
20	0.0393	0.0670	0.0577	0.0901
35	0.0386	0.0723	0.0567	0.0900
50	0.0416	0.0708	0.0529	0.0793

Tabela 3.5: Erro E^1 com vários limiares para os vários conjuntos de características e classificadores.

Nº Características	E^2			
	Redes Neurais		Naive Bayes	
	Min E^1	Min E^2	Min E^1	Min E^2
5	0.1737	0.0660	0.1756	0.0679
10	0.1533	0.0623	0.2957	0.0731
15	0.1606	0.0614	0.2980	0.0755
20	0.1545	0.0657	0.3023	0.0800
35	0.1646	0.0635	0.2974	0.0758
50	0.1674	0.0762	0.2785	0.0749

Tabela 3.6: Erro E^2 com vários limiares para os vários conjuntos de características e classificadores.

Devido ao pico da AUC para o conjunto com as melhores 10 características, são analisados os conjuntos com o número de características entre 5 e 15 para encontrar o melhor conjunto. Apesar de E^1 mostrar menor erro no conjunto de 15 características e ser a medida utilizada na avaliação do concurso NICE.1, a procura pelo melhor conjunto é orientada pela AUC pelas razões mencionadas anteriormente.

Rede Neuronal	Medidas de Performance			
Nº Características	Min E^1	Min E^2	AUC	T (s)
5	0.0474	0.0660	0.9669	0.53
6	0.0452	0.0649	0.9671	0.54
7	0.0417	0.0646	0.9673	0.58
8	0.0386	0.0608	0.9815	0.62
9	0.0385	0.0714	0.9721	0.63
10	0.0381	0.0623	0.9699	0.64
11	0.0362	0.0613	0.9711	0.66
12	0.0380	0.0729	0.9673	0.68
13	0.0367	0.0639	0.9763	0.70
14	0.0383	0.0632	0.9634	0.74
15	0.0375	0.0614	0.9692	0.77

Tabela 3.7: Medidas de performance das Redes Neurais, pelos erros minimizados E^1 e E^2 , pela AUC e pelo tempo de execução T em segundos.

Para os conjuntos com 5 a 15 características temos os valores da tabela 3.7 apenas

para as Redes Neurais. Podemos concluir que o Naive Bayes não obtém melhores resultados que as Redes Neurais, pelo menos no intervalo de características em questão, por isso apenas são apresentados os valores para as Redes Neurais.

A tabela 3.7 apresenta ambas as medidas de erro propostas pelo concurso NICE.1, a AUC e o tempo de classificação de cada imagem, para cada uma das redes neurais. O tempo de execução diz respeito a todo o processo de segmentação. Os tempos de execução foram medidos num computador com processador 2.0 GHz e 2 GB de RAM.

Analisando a tabela 3.7, podemos ver que o conjunto com as 11 melhores características obtém o menor E^1 e o segundo melhor E^2 . Apesar dos bons resultados no conjunto de teste, é de esperar que o conjunto das 8 melhores características tenha maior probabilidade, em relação às 11 melhores, em obter melhores resultados em conjuntos de treino diferentes uma vez que tem a maior AUC e o menor E^2 .

E^1			E^2		
Posição	Utilizador	Erro	Posição	Utilizador	Erro
1	ZhaofengHe	0.013	1	ZhaofengHe	0.055
2	DMCS	0.016	2	DMCS	0.060
3	Palmeida	0.018	3	Gmelfe	0.066
4	PeihuaLi	0.022	4	PeihuaLi	0.068
5	Dal-hoCho	0.028	5	Ricardo_psantos	0.071
6	CATE	0.029	6	Fengsynt	0.075
7	Dtibiola	0.030	7	Palmeida	0.089
8	Font	0.031	8	Touche	0.111
9	Touche	0.032	9	Dtibiola	0.116
10	Forse	0.034	10	BAML	0.117
11	BAML	0.034	11	Mitras.at.ubi	0.127
12	Mkazanov	0.041	12	Font	0.136
13	Ricardo_psantos	0.042	13	ISPG	0.138
14	Sunchina	0.048	14	Dal-hoCho	0.144
15	Gmelfe	0.049	15	CATE	0.163

Tabela 3.8: Resultados do concurso NICE.1.

A tabela 3.8 contém parte dos resultados do concurso NICE.1. É de salientar que os resultados não podem ser comparados com os da tabela 3.7 uma vez que foram

obtidos de conjuntos de imagens diferentes.

Submetido o método com a Rede Neuronal de 8 características com o limiar de minimização de E^1 ao concurso NICE.1, obtivemos $E^1 = 0.036$ e $E^2 = 0.138$, com FPR = 0.023 e FNR = 0.252. O que coloca o método proposto na 12^a posição segundo E^1 , e na 13^a segundo E^2 .

Um valor baixo de FPR é ideal para que apenas píxeis íris sejam usados no reconhecimento.

Os tempos de execução dos métodos submetidos pelos participantes não foram facultados pela organização do concurso. Porém alguns autores revelam os tempos dos seus algoritmos nos seus artigos. Na tabela 3.9 encontram-se os tempos de execução conhecidos de alguns dos métodos participantes.

Posição	Utilizador	E^1	E^2	T (s)
3	Palmeida	0.018	0.089	210
6	CATE	0.029	0.163	0.83
8	Font	0.031	0.136	180
-	Método Proposto	0.036	0.138	0.62

Tabela 3.9: Tempos de execução de algumas participações no NICE.1, de acordo com os autores.

A comparação de tempos pode não ser muito justa porque os autores entregaram as participações em linguagens diferentes e sem o critério de tempo mínimo de execução como preocupação, à excepção de CATE.

A figura 3.12 mostra o resultado da aplicação do método proposto à imagem 3.12(a), que devolve o mapa binário da localização da íris 3.12(c). A imagem 3.12(b) corresponde ao mapa binário oficial da localização da íris. A imagem 3.12(a) do conjunto de teste é uma das que apresentam um maior erro com E^1 igual a 0.0756, no método com 8 características. Podemos observar que a medida não é correcta porque foi obtida a partir da máscara 3.12(b). As marcações circulares na imagem 3.12(c) representam zonas em que o método proposto foi capaz de identificar íris e não-íris correctamente e que na máscara oficial do concurso se encontram incorrectamente




Figura 3.12: Segmentação da íris pelo método proposto. 3.12(a) Imagem original. 3.12(b) Máscara binária oficial de localização dos píxeis íris empregue no concurso NICE.1. 3.12(c) Máscara obtida pelo método de segmentação proposto.

classificadas.

Comparando os resultados da segmentação da imagens 3.13(a) e 3.14(a) das figuras 3.13 e 3.14, podemos ver que a medida de erro E^2 é mais representativa de uma boa ou má segmentação que a medida E^1 , na avaliação do classificador.




Figura 3.13: Segmentação da íris pelo método proposto com maior E^1 . 3.13(a) Imagem original. 3.13(b) Máscara binária oficial 3.13(c) Máscara obtida pelo método de segmentação proposto. $E^1 = 0.1161$ e $E^2 = 0.2381$.

Apesar da imagem 3.13(a) estar melhor segmentada que a imagem 3.14(a), o valor do erro E^1 não transmite essa informação, muito pelo contrário. A imagem 3.13(a) apresenta o pior valor de E^1 no conjunto de teste, e o dobro do E^1 da imagem 3.14(a) em que nem um pixel da íris tem correctamente classificado. Isto deve-se à desproporção existente entre o número de píxeis íris e não-íris. A medida E^2 tem este factor em conta uma vez que recorre às medidas FPR e FNR. Com E^2 a imagem

3.13(a) tem metade do erro de .




Figura 3.14: Segmentação da íris pelo método proposto em que falha a delimitação da íris. 3.14(a) Imagem original. 3.14(b) Máscara binária oficial 3.14(c) Máscara obtida pelo método de segmentação proposto. $E^1 = 0.0436$ e $E^2 = 0.5093$.

No anexo B encontram-se mais resultados de íris do conjunto de teste, segmentadas pelo método apresentado neste trabalho.

Capítulo 4

Conclusão

O uso de sistemas de segurança através do reconhecimento de indivíduos em áreas de grande afluência como em serviços de fronteira, aeroportos, estádios de futebol, etc, é uma tarefa bastante incómodo e morosa. É com o propósito de reduzir ou eliminar estas desvantagens que surge a área de trabalho desta tese inserida no reconhecimento biométrico não-cooperativo.

A precisão obtida neste trabalho pode ser inferior aos resultados pretendidos e dos métodos existentes, mas a relação precisão/velocidade é bastante superior ao trabalho existente nas mesmas condições.

Apesar de a configuração do método submetido às mesmas condições do concurso NICE.1 ter sido direccionada para a minimização do erro E^1 , na aplicação real num sistema de reconhecimento não-cooperativo é possível que melhores resultados sejam alcançados no sistema global se o método de segmentação for desenvolvido para minimizar a segunda medida de erro E^2 .

4.1 Trabalho Futuro

A interpretação da segmentação da íris como um problema de reconhecimento de padrões mostrou bons resultados em performance temporal, apesar de sacrificar alguma precisão.

O desempenho do método proposto pode ser melhorado com o uso de outras características, classificadores, ou conjunto de treino. Em métodos de aprendizagem supervisionados é fundamental que o ruído existente nos exemplos do conjunto de

treino seja inexistente. Como referido na secção 3.4, as máscaras de localização de píxeis de íris facultadas pela organização do concurso NICE.1 apresentam algumas falhas. Por esta razão, é objectivo futuro a criação de máscaras mais precisas que melhorem não só o treino dos classificadores utilizados, como o cálculo da precisão do método de segmentação.

É também objectivo futuro estudar outras abordagens alternativas ou adicionais para todas as etapas do método proposto, desde a delimitação da área de procura da íris, ao classificador utilizado para aumentar a precisão do classificador e manter o mínimo tempo de execução.

Por fim, o uso de uma representação alternativa dos dados é também um dos objectivos a implementar futuramente, de forma a que o conjunto de dados possa ser mais reduzido e permita o uso de outros métodos de aprendizagem automática que não puderam ser testados neste trabalho.

Apêndice A

Resultados mRMR

Ordem	Índice	Característica	Pontuação
1	33	Contraste Aumentado	0.449
2	27	Filtro íris Y - YIQ	0.021
3	159	Entropia 3x3 Y - YIQ	0.060
4	31	Filtro íris Cb - YCbCr	0.100
5	6	Eliminação de pele 1	0.112
6	7	Eliminação de pele 2	0.014
7	163	Entropia 3x3 Y - YCbCr	0.009
8	87	Média 7x7 Q - YIQ	0.044
9	17	Alinhamento maior área em Y - YCbCr	-0.000
10	3	R - RGB	-0.003
11	26	Filtro íris V - HSV	-0.005
12	18	Imagem Média RGB	-0.005
13	29	Filtro íris Q - YIQ	-0.007
14	158	Entropia 3x3 I - YIQ	-0.004
15	22	Filtro íris G - RGB	-0.015
16	154	Entropia 3x3 H - HSV	-0.016
17	24	Filtro íris H - HSV	-0.016
18	16	Cr - YCbCr	-0.014
19	162	Entropia 3x3 B - RGB	-0.018
20	63	Média 3x3 Q - YIQ	-0.025

Ordem	Índice	Característica	Pontuação
21	155	Entropia 3x3 S - HSV	-0.026
22	25	Filtro íris S - HSV	-0.026
23	164	Entropia 3x3 Cb - YCbCr	-0.029
24	14	Y - YCbCr	-0.020
25	160	Entropia 3x3 R - RGB	-0.029
26	161	Entropia 3x3 G - RGB	-0.039
27	32	Filtro íris Cr - YCbCr	-0.029
28	183	Entropia 7x7 Q - YIQ	-0.040
29	28	Filtro íris I - YIQ	-0.049
30	165	Entropia 3x3 Cr - YCbCr	-0.049
31	107	Desvio Padrão 3x3 S - HSV	-0.054
32	46	Média H - HSV	-0.057
33	75	Média 5x5 Q - YIQ	-0.070
34	157	Entropia 3x3 Y - YIQ	-0.086
35	2	coluna	-0.088
36	15	Cb - YCbCr	-0.086
37	23	Filtro íris B - RGB	-0.093
38	119	Desvio Padrão 5x5 S - HSV	-0.095
39	156	Entropia 3x3 V - HSV	-0.094
40	171	Entropia 5x5 Q - YIQ	-0.090
41	166	Entropia 5x5 H - HSV	-0.108
42	111	Desvio Padrão 3x3 Q - YIQ	-0.113
43	10	V - HSV	-0.110
44	21	Filtro íris R - RGB	-0.122
45	114	Desvio Padrão 3x3 B - RGB	-0.122
46	129	Desvio Padrão 5x5 Cr - YCbCr	-0.130
47	93	Média 7x7 Cr - YCbCr	-0.128
48	167	Entropia 5x5 S - HSV	-0.140
49	116	Desvio Padrão 3x3 Cb - YCbCr	-0.141
50	112	Desvio Padrão 3x3 R - RGB	-0.144
51	4	G - RGB	-0.143
52	30	Filtro íris Y - YCbCr	-0.147
53	106	Desvio Padrão 3x3 H - HSV	-0.150
54	113	Desvio Padrão 3x3 G - RGB	-0.157
55	110	Desvio Padrão 3x3 I - YIQ	-0.161

Ordem	Índice	Característica	Pontuação
56	140	Desvio Padrão 7x7 Cb - YCbCr	-0.165
57	96	Desvio Padrão V - HSV	-0.164
58	135	Desvio Padrão 7x7 Q - YIQ	-0.165
59	1	linha	-0.168
60	174	Entropia 5x5 B - RGB	-0.170
61	5	B - RGB	-0.176
62	117	Desvio Padrão 3x3 Cr - YCbCr	-0.176
63	172	Entropia 5x5 R - RGB	-0.177
64	131	Desvio Padrão 7x7 S - HSV	-0.180
65	20	Distancia Ponto Mais Claro	-0.189
66	123	Desvio Padrão 5x5 Q - YIQ	-0.194
67	88	Média 7x7 R - RGB	-0.195
68	128	Desvio Padrão 5x5 Cb - YCbCr	-0.202
69	8	H - HSV	-0.202
70	125	Desvio Padrão 5x5 G - RGB	-0.206
71	141	Desvio Padrão 7x7 Cr - YCbCr	-0.209
72	94	Desvio Padrão H - HSV	-0.215
73	178	Entropia 7x7 H - HSV	-0.215
74	109	Desvio Padrão 3x3 Y - YIQ	-0.224
75	122	Desvio Padrão 5x5 I - YIQ	-0.230
76	81	Média 5x5 Cr - YCbCr	-0.230
77	126	Desvio Padrão 5x5 B - RGB	-0.243
78	124	Desvio Padrão 5x5 R - RGB	-0.251
79	134	Desvio Padrão 7x7 I - YIQ	-0.259
80	173	Entropia 5x5 G - RGB	-0.258
81	57	Média Cr - YCbCr	-0.260
82	76	Média 5x5 R - RGB	-0.260
83	118	Desvio Padrão 5x5 H - HSV	-0.268
84	108	Desvio Padrão 3x3 V - HSV	-0.271
85	179	Entropia 7x7 S - HSV	-0.278
86	13	Q - YIQ	-0.288
87	136	Desvio Padrão 7x7 R - RGB	-0.291
88	138	Desvio Padrão 7x7 B - RGB	-0.299
89	176	Entropia 5x5 Cb - YCbCr	-0.301
90	104	Desvio Padrão Cb - YCbCr	-0.300

Ordem	Índice	Característica	Pontuação
91	115	Desvio Padrão 3x3 Y - YCbCr	-0.305
92	64	Média 3x3 R - RGB	-0.309
93	168	Entropia 5x5 V - HSV	-0.311
94	82	Média 7x7 H - HSV	-0.318
95	169	Entropia 5x5 Y - YIQ	-0.328
96	69	Média 3x3 Cr - YCbCr	-0.328
97	177	Entropia 5x5 Cr - YCbCr	-0.331
98	137	Desvio Padrão 7x7 G - RGB	-0.336
99	19	Média Imagem RGB	-0.336
100	92	Média 7x7 Cb - YCbCr	-0.342
101	130	Desvio Padrão 7x7 H - HSV	-0.352
102	170	Entropia 5x5 I - YIQ	-0.357
103	127	Desvio Padrão 5x5 Y - YCbCr	-0.358
104	188	Entropia 7x7 Cb - YCbCr	-0.366
105	91	Média 7x7 Y - YCbCr	-0.370
106	152	Entropia Cb - YCbCr	-0.372
107	120	Desvio Padrão 5x5 V - HSV	-0.374
108	189	Entropia 7x7 Cr - YCbCr	-0.376
109	58	Média 3x3 H - HSV	-0.381
110	139	Desvio Padrão 7x7 Y - YCbCr	-0.387
111	42	Média linha-coluna Q - YIQ	-0.395
112	184	Entropia 7x7 R - RGB	-0.399
113	86	Média 7x7 I - YIQ	-0.402
114	186	Entropia 7x7 B - RGB	-0.410
115	54	Média B - RGB	-0.407
116	175	Entropia 5x5 Y - YCbCr	-0.416
117	79	Média 5x5 Y - YCbCr	-0.420
118	70	Média 5x5 H - HSV	-0.428
119	132	Desvio Padrão 7x7 V - HSV	-0.430
120	68	Média 3x3 Cb - YCbCr	-0.434
121	100	Desvio Padrão R - RGB	-0.439
122	121	Desvio Padrão 5x5 Y - YIQ	-0.441
123	84	Média 7x7 V - HSV	-0.447
124	62	Média 3x3 I - YIQ	-0.465
125	133	Desvio Padrão 7x7 Y - YIQ	-0.469

Ordem	Índice	Característica	Pontuação
126	102	Desvio Padrão B - RGB	-0.469
127	67	Média 3x3 Y - YCbCr	-0.468
128	80	Média 5x5 Cb - YCbCr	-0.476
129	182	Entropia 7x7 I - YIQ	-0.481
130	180	Entropia 7x7 V - HSV	-0.487
131	45	Média linha-coluna Cr - YCbCr	-0.492
132	60	Média 3x3 V - HSV	-0.500
133	95	Desvio Padrão S - HSV	-0.506
134	89	Média 7x7 G - RGB	-0.511
135	185	Entropia 7x7 G - RGB	-0.515
136	74	Média 5x5 I - YIQ	-0.517
137	83	Média 7x7 S - HSV	-0.530
138	103	Desvio Padrão Y - YCbCr	-0.534
139	78	Média 5x5 B - RGB	-0.540
140	37	Média linha-coluna H - HSV	-0.547
141	65	Média 3x3 G - RGB	-0.555
142	34	Média linha-coluna R - RGB	-0.561
143	59	Média 3x3 S - HSV	-0.570
144	72	Média 5x5 V - HSV	-0.573
145	97	Desvio Padrão Y - YIQ	-0.573
146	181	Entropia 7x7 Y - YIQ	-0.584
147	11	Y - YIQ	-0.589
148	151	Entropia Y - YCbCr	-0.596
149	71	Média 5x5 S - HSV	-0.602
150	41	Média linha-coluna I - YIQ	-0.608
151	90	Média 7x7 B - RGB	-0.612
152	187	Entropia 7x7 Y - YCbCr	-0.620
153	99	Desvio Padrão Q - YIQ	-0.626
154	77	Média 5x5 G - RGB	-0.629
155	39	Média linha-coluna V - HSV	-0.637
156	66	Média 3x3 B - RGB	-0.646
157	85	Média 7x7 Y - YIQ	-0.656
158	48	Média V - HSV	-0.655
159	35	Média linha-coluna G - RGB	-0.668
160	61	Média 3x3 Y - YIQ	-0.680

Ordem	Índice	Característica	Pontuação
161	12	I - YIQ	-0.681
162	52	Média R - RGB	-0.683
163	40	Média linha-coluna Y - YIQ	-0.694
164	44	Média linha-coluna Cb - YCbCr	-0.701
165	36	Média linha-coluna B - RGB	-0.709
166	73	Média 5x5 Y - YIQ	-0.716
167	56	Média Cb - YCbCr	-0.721
168	38	Média linha-coluna S - HSV	-0.729
169	98	Desvio Padrão I - YIQ	-0.757
170	43	Média linha-coluna Y - YCbCr	-0.769
171	9	S - HSV	-0.773
172	105	Desvio Padrão Cr - YCbCr	-0.782
173	143	Entropia S - HSV	-0.805
174	153	Entropia Cr - YCbCr	-0.828
175	101	Desvio Padrão G - RGB	-0.850
176	145	Entropia Y - YIQ	-0.872
177	148	Entropia R - RGB	-0.894
178	149	Entropia G - RGB	-0.916
179	146	Entropia I - YIQ	-0.938
180	51	Média Q - YIQ	-0.959
181	144	Entropia V - HSV	-0.980
182	53	Média G - RGB	-1,001
183	147	Entropia Q - YIQ	-1,022
184	150	Entropia B - RGB	-1,042
185	49	Média Y - YIQ	-1,062
186	55	Média Y - YCbCr	-1,082
187	50	Média I - YIQ	-1,102
188	47	Média S - HSV	-1,121
189	142	Entropia H - HSV	-1,140

Tabela A.1: Resultados do método de selecção de características mRMR

Apêndice B

Resultados da segmentação

Neste anexo encontram-se algumas imagens de íris segmentadas pelo método proposto. Cada imagem de íris é acompanhada pelas máscaras oficial do concurso NICE.1 e obtida pelo método desenvolvido. Todas as imagens de íris seguintes pertencem ao conjunto de teste.




Figura B.1: Íris segmentada pelo método proposto com menor E^1 . B.1(a) Imagem original. B.1(b) Máscara binária oficial. B.1(c) Máscara obtida pelo método de segmentação proposto. $E^1 = 0.0058$ e $E^2 = 0.0657$.



Figura B.2: Íris segmentada pelo método proposto com menor E^2 B.2(a) Imagem original. B.2(b) Máscara binária oficial. B.2(c) Máscara obtida pelo método de segmentação proposto. $E^1 = 0.0088$ e $E^2 = 0.0044$.




Figura B.3: Íris segmentada pelo método proposto com maior E^1 B.3(a) Imagem original. B.3(b) Máscara binária oficial. B.3(c) Máscara obtida pelo método de segmentação proposto. $E^1 = 0.1161$ e $E^2 = 0.2381$.




Figura B.4: Íris segmentada pelo método proposto com maior E^2 B.4(a) Imagem original. B.4(b) Máscara binária oficial. B.4(c) Máscara obtida pelo método de segmentação proposto. $E^1 = 0.0779$ e $E^2 = 0.5244$.




Figura B.5: Íris ocluída por cabelo segmentada pelo método proposto. B.5(a) Imagem original. B.5(b) Máscara binária oficial. B.5(c) Máscara obtida pelo método de segmentação proposto. $E^1 = 0.0291$ e $E^2 = 0.0938$.




Figura B.6: Íris fora de ângulo segmentada pelo método proposto. B.6(a) Imagem original. B.6(b) Máscara binária oficial. B.6(c) Máscara obtida pelo método de segmentação proposto. $E^1 = 0.0084$ e $E^2 = 0.0976$.




Figura B.7: Íris ocluída por óculos segmentada pelo método proposto. B.8(a) Imagem original. B.8(b) Máscara binária oficial. B.8(c) Máscara obtida pelo método de segmentação proposto. $E^1 = 0.0299$ e $E^2 = 0.2465$.




Figura B.8: Íris ocluída por reflexos especular e difuso segmentada pelo método proposto. B.8(a) Imagem original. B.8(b) Máscara binária oficial. B.8(c) Máscara obtida pelo método de segmentação proposto. $E^1 = 0.03677$ e $E^2 = 0.1312$.




Figura B.9: Íris segmentada pelo método proposto. B.9(a) Imagem original. B.9(b) Máscara binária oficial. B.9(c) Máscara obtida pelo método de segmentação proposto. $E^1 = 0.0334$ e $E^2 = 0.1621$.

Bibliografia

- [1] Andrea F. Abate, Michele Nappi, Daniel Riccio, and Gabriele Sabatino. 2d and 3d face recognition: A survey. *Pattern Recognition Letters*, 28(14):1885 – 1906, 2007. Image: Information and Control.
- [2] Pedro de Almeida. A knowledge-based approach to the iris segmentation problem. *Elsevier Image and Vision Computing Journal*, 2009.
- [3] Blog AutoBeat. http://autobeat.blogspot.com/2007_01_01_archive.html.
- [4] Iraídes Corrêa Batista. <http://www.naturaides.com>.
- [5] BIOREC. <http://www.di.ubi.pt/~lfbaa/biorec.html>.
- [6] R.P. Broussard, L.R. Kennell, D.L. Soldan, and R.W. Ives. Using artificial neural networks and feature saliency techniques for improved iris segmentation. In *Neural Networks, 2007. IJCNN 2007. International Joint Conference on*, pages 1283–1288, Aug. 2007.
- [7] John Canny. A computational approach to edge detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-8(6):679–698, Nov. 1986.
- [8] CASIA. Base de dados de imagens de chinese academy of sciences (casia). <http://www.cl.cam.ac.uk/~jgd1000/>.
- [9] Yu Chen, Malek Adjouadi, Changan Han, Jin Wang, Armando Barreto, Naphtali Rishe, and Jean Andrian. A highly accurate and computationally efficient approach for unconstrained iris segmentation. *Image and Vision Computing*, May 2009.

- [10] SOCIALab Soft Computing and Image Analysis Lab. <http://socia-lab.di.ubi.pt>.
- [11] G. Cybenko. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems (MCSS)*, 2(4):303–314, December 1989.
- [12] J. Daugman. Probing the uniqueness and randomness of iriscodes: Results from 200 billion iris pair comparisons. *Proceedings of the IEEE*, 94(11):1927–1935, Nov. 2006.
- [13] John Daugman. <http://www.cl.cam.ac.uk/~jgd1000/>.
- [14] John Daugman. High confidence visual recognition of persons by a test of statistical independence. *IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE*, 15(11), 1993.
- [15] John Daugman. How iris recognition works. *Circuits and Systems for Video Technology, IEEE Transactions on*, 14(1):21–30, Jan. 2004.
- [16] John Daugman. New methods in iris recognition. *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, 37(5):1167–1175, Oct. 2007.
- [17] C. Ding and H. Peng. Minimum redundancy feature selection from microarray gene expression data. In *Bioinformatics Conference, 2003. CSB 2003. Proceedings of the 2003 IEEE*, pages 523–528, Aug. 2003.
- [18] Richard O. Duda and Peter E. Hart. Use of the hough transformation to detect lines and curves in pictures. *Commun. ACM*, 15(1):11–15, 1972.
- [19] Richard O. Duda, Peter E. Hart, and David G. Stork. *Pattern Classification (2nd Edition)*. Wiley-Interscience, November 2000.
- [20] Hugo Proença e Luís A. Alexandre. A method for the identification of noisy regions in normalized iris images. *The 18th International Conference on Pattern Recognition*, 2006.
- [21] Tom Fawcett. An introduction to roc analysis. *Pattern Recognition Letters*, 27(8):861 – 874, 2006. ROC Analysis in Pattern Recognition.

- [22] Robert Fisher, Simon Perkins, Ashley Walker, and Erik Wolfart. Image processing learning resources. http://homepages.inf.ed.ac.uk/rbf/HIPR2/hipr_top.htm.
- [23] L. Flom and A. Safir. Iris recognition system. *US Patent 4 641 394*, 1987.
- [24] K. Funahashi. On the approximate realization of continuous mappings by neural networks. *Neural Netw.*, 2(3):183–192, 1989.
- [25] Eric J. Hartman, James D. Keeler, and Jacek M. Kowalski. Layered neural networks with gaussian hidden units as universal approximations. *Neural Computation*, 2(2):210–215, 1990.
- [26] Zhaofeng He, Tieniu Tan, Zhenan Sun, and Xianchao Qiu. Robust eyelid, eyelash and shadow localization for iris recognition. In *Image Processing, 2008. ICIP 2008. 15th IEEE International Conference on*, pages 265–268, Oct. 2008.
- [27] K. Hornik, M. Stinchcombe, and H. White. Multilayer feedforward networks are universal approximators. *Neural Netw.*, 2(5):359–366, 1989.
- [28] P.V.C. Hough. Method and means for recognizing complex patterns. U.S. Patent 3,069,654, Dec. 18, 1962.
- [29] Colin Howson and Peter Urbach. *Scientific Reasoning: The Bayesian Approach*. Open Court, third edition edition, April 2005.
- [30] BATH iris image database. <http://www.bath.ac.uk/elec-eng/research/sipg/irisweb/>.
- [31] IrisGuard. <http://www.irisguard.com>.
- [32] L.R. Kennell, R.W. Ives, and R.M. Gaunt. Binary morphology and local statistics applied to iris segmentation for recognition. In *Image Processing, 2006 IEEE International Conference on*, pages 293–296, Oct. 2006.
- [33] C. Ling, J. Huang, and H. Zhang. AUC: a statistically consistent and more discriminating measure than accuracy, 2003.
- [34] B. Miller. Vital signs of identity [biometrics]. *Spectrum, IEEE*, 1994.

- [35] Department of Microelectronics and Computer Science Technical Of The University Of Lodz. Reliable algorithm for iris segmentation in eye image. *Elsevier Image and Vision Computing Journal*, 2009.
- [36] Panasonic. Panasonic security global site. <http://panasonic.net/pss/security/products/iris/index.html>.
- [37] Abhijit S. Pandya and Robert B. Macy. *Pattern Recognition with Neural Network in C++*. CRC Press, Inc., Boca Raton, FL, USA, 1995.
- [38] Hanchuan Peng, Fuhui Long, and C. Ding. Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 27(8):1226–1238, Aug. 2005.
- [39] H. Proença and L. A. Alexandre. Iris segmentation methodology for non-cooperative recognition. *IEE Proc.-Vis. Image Signal Process*, 153(2), 2006.
- [40] H. Proenca and L.A. Alexandre. Iris recognition: An analysis of the aliasing problem in the iris normalization stage. In *Computational Intelligence and Security, 2006 International Conference on*, volume 2, pages 1771–1774, Nov. 2006.
- [41] H. Proenca and L.A. Alexandre. The NICE.I: Noisy iris challenge evaluation - part i. In *Biometrics: Theory, Applications, and Systems, 2007. BTAS 2007. First IEEE International Conference on*, pages 1–4, Sept. 2007.
- [42] Hugo Proença. *Towards Non-Cooperative Biometric Iris Recognition*. PhD thesis, Universidade da Beira Interior, Janeiro 2007.
- [43] Hugo Proença and Luís Alexandre. UBIRIS: A noisy iris image database. *Image Analysis and Processing – ICIAP 2005*, pages 970–977, 2005.
- [44] Hugo Proença, Sílvio Filipe, Ricardo Santos, João Oliveira, and Luís A. Alexandre. The UBIRIS.v2: A database of visible wavelength images captured on-the-move and at-a-distance. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 99(1), 5555.

- [45] D. E. Rumelhart, G. E. Hinton, and R. J. Williams. *Learning internal representations by error propagation*, chapter 8, pages 318–362. MIT Press, Cambridge, MA, USA, 1986.
- [46] Teerayoot Sawangsri, Vorapoj Patanavijit, and Somchai Jitapunkul. Face segmentation based on hue-cr components and morphological technique. In *ISCAS (6)*, pages 5401–5404, 2005.
- [47] Daniel Sieberg. Iris recognition at airports uses eye-catching technology. <http://archives.cnn.com/2000/TECH/computing/07/24/iris.explainer/index.html>, 2000.
- [48] K. Sobottka and I. Pitas. A novel method for automatic face segmentation, facial feature extraction and tracking. 12(3):263–281, June 1998.
- [49] Tieniu Tan, Zhaofeng He, and Zhenan Sun. Efficient and robust segmentation of noisy iris images for non-cooperative iris recognition. *Elsevier Image and Vision Computing Journal*, 2009.
- [50] Tieniu Tan, Zhaofeng He, and Zhenan Sun. Towards accurate and fast iris segmentation for iris biometrics. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009.
- [51] R.P. Wildes. Iris recognition: an emerging biometric technology. *Proceedings of the IEEE*, 85(9):1348–1363, Sep 1997.