

Índex

1	INTRODUCCIÓ	12
1.1	DESCRIPCIÓ	12
1.2	EL MELANOMA I ELS NEVUS	12
1.3	LA VISIÓ PER COMPUTADOR	13
1.4	L'ESTAT DE L'ART	14
1.4.1	<i>MIRROR</i>	14
1.4.2	<i>MOLEMAX</i>	15
1.4.3	<i>FOTOFINDER</i>	15
1.4.4	ALTRES APLICACIONS	16
1.5	L'ENTORN DE TREBALL	17
1.6	OBJECTIUS	18
1.7	ABAST	18
1.8	PLANIFICACIÓ	19
1.9	METODOLOGIA	20
1.10	ESTRUCTURA DE LA MEMÒRIA	20
2	LES DADES DE TREBALL	22
2.1	ELS CONJUNTS DE DADES	22
2.1.1	EL CONJUNT DE DADES REALS 1	22
2.1.2	EL CONJUNT DE DADES REALS 2	24
2.1.3	EL CONJUNT DE DADES REALS 3	25
2.2	L'OBTENCIÓ DE LES IMATGES	25
2.3	L'OBTENCIÓ DE MOSTRES	27
3	EL DETECTOR DE NEVUS	29
3.1	LA BINARITZACIÓ DE LA IMATGE	29
3.1.1	MÈTODES	29
3.1.1.1	LES PRIMERES PROVES	29
3.1.1.2	LA BINARITZACIÓ LOCAL	31
3.1.1.3	LA SEGMENTACIÓ SUPERVISADA A PARTIR DE DISTÀNCIES	37
3.1.1.4	LA SEGMENTACIÓ SUPERVISADA A PARTIR DE PROBABILITATS	45

ÍNDIX	2
3.1.2 RESULTATS	52
3.1.3 LA COMPOSICIÓ DE MÈTODES	62
3.2 L'ETIQUETATGE DELS NEVUS	66
4 EL COMPARADOR	70
4.1 LA CORRESPONDÈNCIA ENTRE NEVUS	70
4.1.1 MÈTODES	71
4.1.1.1 LA CERCA EXHAUSTIVA	71
4.1.1.2 EL REGISTRE	90
4.1.2 RESULTATS	95
5 EL GESTOR DE PACIENTS	105
5.1 DISSENY I IMPLEMENTACIÓ	105
5.1.1 EL MÒDUL DE GESTIÓ	106
5.1.2 EL MÒDUL DE VISUALITZACIÓ	109
6 CONCLUSIONS I TREBALLS FUTURS	111
6.1 CONCLUSIONS EXTRETES	111
6.2 PROJECTES FUTURS	113
A MANUAL D'USUARI	115
A.1 INSERCIÓ D'UN NOU PACIENT	115
A.2 MODIFICACIÓ D'UNA O MÉS DADES D'UN PACIENT SELECCIONAT	116
A.3 ELIMINACIÓ D'UN PACIENT SELECCIONAT	117
A.4 CERCA D'UN PACIENT A PARTIR D'UN CRITERI	117
A.5 ORDENACIÓ DE LA LLISTA DE PACIENTS	118
A.6 MOSTREIG DE LES DADES D'UN PACIENT SELECCIONAT	118
A.7 INSERCIÓ D'UNA NOVA EXPLORACIÓ A UN PACIENT	119
A.8 PAS A LA INTERFÍCIE DE VISUALITZACIÓ D'UN PACIENT SELECCIONAT	120
A.9 DETECCIÓ DELS NEVUS EN LES IMATGES SELECCIONADES	121
A.10 COMPARACIÓ DELS NEVUS DE DUES IMATGES AMB LA DETECCIÓ REALITZADA	122
A.11 RESTAURACIÓ DE LES IMATGES SELECCIONADES	122

Índex de figures

1.1	Diverses captures de pantalla de <i>Mirror</i>	14
1.2	Diverses captures de pantalla de <i>Molemax</i>	15
1.3	Diverses captures de pantalla de FotoFinder.	16
1.4	Matlab 7.	17
2.1	Imatges del conjunt de dades reals 1.	23
2.2	Imatges d'un mateix braç capturades amb les dues càmeres diferents.	24
2.3	Imatges del conjunt de dades reals 2.	24
2.4	Imatges del conjunt de dades reals 3.	25
2.5	Càmeres utilitzades en la captura de les imatges.	26
2.6	Set de captura de les imatges.	26
2.7	Captura de les imatges del braç d'un voluntari.	27
2.8	Mostres de pell de la base de dades d'una imatge d'un conjunt d'imatges.	28
2.9	Exemple de mostra de no-pell d'un conjunt d'imatges.	28
3.1	Imatge binaritzada globalment amb llindar 128 ([0,255]).	30
3.2	Imatge binaritzada globalment amb llindar 128 ([0,255]).	30
3.3	Imatge binaritzada globalment amb llindar 110 ([0,255]).	30
3.4	Imatge binaritzada amb llindar obtingut pel mètode otsu ([0,255]).	31
3.5	Imatge binaritzada amb llindar obtingut pel mètode otsu ([0,255]).	31
3.6	Imatge binaritzada localment amb llindar obtingut pel mètode otsu i finestra de 5x5 ([0,255]).	32
3.7	Imatge binaritzada localment amb llindar obtingut pel mètode otsu i finestra de 50x50 ([0,255]).	32
3.8	Imatge binaritzada localment amb llindar obtingut pel mètode otsu i finestra de 100x100 ([0,255]).	32
3.9	Fragment ampliat d'una imatge binaritzada localment amb llindar obtingut pel mètode otsu i finestra de 100x100 ([0,255]).	33
3.10	Imatge binaritzada localment amb mitjana com a llindar i finestra de 5x5 ([0,255]).	34
3.11	Imatge binaritzada localment amb mitjana com a llindar i finestra de 50x50 ([0,255]).	34

3.12	Imatge binaritzada localment amb mitjana com a llindar i finestra de 100x100 ([0,255]).	34
3.13	Histograma uniforme (unimodal) i histograma no uniforme dels nivells de gris de dues subimatges, la primera amb pell únicament, i la segona amb pell i nevus ([0,255]).	35
3.14	Subimatge binaritzada localment amb la mitjana com a llindar ([0,255]).	36
3.15	Subimatge binaritzada localment amb la mitjana com a llindar per a les finestres amb histogrames no uniformes, i mitjana menys 15 per a les finestres amb histogrames uniformes ([0,255]).	36
3.16	Imatge binaritzada localment amb mitjana com a llindar (finestres amb histogrames no uniformes), mitjana menys 15 com a llindar (finestres amb histogrames uniformes) i finestra de 10x10 ([0,255]).	37
3.17	Imatge binaritzada localment amb mitjana com a llindar (finestres amb histogrames no uniformes), mitjana menys 15 com a llindar (finestres amb histogrames uniformes) i finestra de 10x10 ([0,255]).	37
3.18	Mostres de pell utilitzades per extreure característiques.	38
3.19	Mapeig dels píxels de les mostres de pell en l'espai HSV.	40
3.20	Mapeig de la pell amb entrenament fet a partir del mètode <i>Kfold Crossvalidation</i> ($k = 2$).	41
3.21	Imatge binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.2 ([0,1]).	41
3.22	Imatge binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.5 ([0,1]).	41
3.23	Imatge binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.35 ([0,1]).	42
3.24	Imatge binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.35 ([0,1]).	42
3.25	Mapeig dels píxels de les mostres de pell en l'espai LAB.	43
3.26	Mapeig de la pell amb entrenament fet a partir del mètode <i>Kfold Crossvalidation</i> ($k = 2$).	44
3.27	Imatge binaritzada mitjançant distàncies en l'espai LAB amb distància màxima per a píxels de pell respecte la mitjana de 0.35 ([0,1]).	44
3.28	Imatge binaritzada mitjançant distàncies en l'espai LAB amb distància màxima per a píxels de pell respecte la mitjana de 0.1 ([0,1]).	44
3.29	Imatge binaritzada mitjançant distàncies en l'espai LAB amb distància màxima per a píxels de pell respecte la mitjana de 0.2 ([0,1]).	45
3.30	Imatge binaritzada mitjançant distàncies en l'espai LAB amb distància màxima per a píxels de pell respecte la mitjana de 0.28 ([0,1]).	45
3.31	Imatge de prova per a l'entrenament de la pell per a la segmentació a partir de probabilitats i mostres de pell agafades per a l'entrenament.	46
3.32	Probabilitat que un píxel pertanyi a la classe pell.	47
3.33	Probabilitat que un píxel pertanyi a la classe no-pell.	47
3.34	Probabilitat que un píxel sigui pell.	47
3.35	Imatge binaritzada a partir de probabilitats amb llindar 0.5.	48

3.36	Imatge binaritzada a partir de probabilitats amb llindar 0.5.	48
3.37	Imatge binaritzada a partir de probabilitats en l'espai de color RGB amb llindar 0.5.	49
3.38	Imatge binaritzada a partir de probabilitats en l'espai de color RGB amb llindar 0.5.	49
3.39	Imatge binaritzada a partir de probabilitats en l'espai de color HSV amb llindar 0.5.	49
3.40	Imatge binaritzada a partir de probabilitats en l'espai de color HSV amb llindar 0.5.	50
3.41	Imatge binaritzada a partir de probabilitats amb les components R, G, B, H i S amb llindar 0.5.	50
3.42	Imatge binaritzada a partir de probabilitats amb les components R, G, B, H i S amb llindar 0.5.	50
3.43	Imatge binaritzada a partir de probabilitats amb en l'espai de color RGB i amb llindar 0.5.	51
3.44	Imatge binaritzada a partir de probabilitats amb en l'espai de color RGB i amb llindar 0.5.	51
3.45	Imatge binaritzada a partir de probabilitats amb en l'espai de color RGB i amb llindar 0.5.	51
3.46	Imatge d'exemple del primer conjunt de dades reals binaritzada localment amb mitjana com a llindar i (finestres amb histogrames no uniformes), mitjana menys 15 (finestres amb histogrames uniformes) i finestra de 10x10 ([0,255]).	52
3.47	Imatge d'exemple del primer conjunt de dades reals binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.32 ([0,1]).	52
3.48	Imatge d'exemple del primer conjunt de dades reals binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.28 ([0,1]).	53
3.49	Imatge d'exemple del primer conjunt de dades reals binaritzada a partir de probabilitats amb en l'espai de color RGB i amb llindar 0.5.	53
3.50	Imatge d'exemple del segon conjunt de dades reals binaritzada localment amb mitjana com a llindar i (finestres amb histogrames no uniformes), mitjana menys 20 (finestres amb histogrames uniformes) i finestra de 10x10 ([0,255]).	54
3.51	Imatge d'exemple del segon conjunt de dades reals binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.35 ([0,1]).	54
3.52	Imatge d'exemple del segon conjunt de dades reals binaritzada mitjançant distàncies en l'espai LAB amb distància màxima per a píxels de pell respecte la mitjana de 0.2 ([0,1]).	54
3.53	Imatge d'exemple del segon conjunt de dades reals binaritzada a partir de probabilitats amb en l'espai de color RGB i amb llindar 0.5.	55

3.54	Imatge d'exemple del tercer conjunt de dades reals binaritzada localment amb mitjana com a llindar i (finestres amb histogrames no uniformes), mitjana menys 20 (finestres amb histogrames uniformes) i finestra de 10x10 ([0,255]).	55
3.55	Imatge d'exemple del tercer conjunt de dades reals binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.21 ([0,1]).	56
3.56	Imatge d'exemple del tercer conjunt de dades reals binaritzada mitjançant distàncies en l'espai LAB amb distància màxima per a píxels de pell respecte la mitjana de 0.2 ([0,1]).	56
3.57	Imatge d'exemple del tercer conjunt de dades reals binaritzada a partir de probabilitats amb en l'espai de color RGB i amb llindar 0.5.	56
3.58	Resultats del mètode de segmentació supervisada a partir de probabilitats utilitzant el mètode <i>Kfold Crossvalidation</i> ($k = 2$) en l'entrenament.	58
3.59	Resultats del mètode de segmentació supervisada a partir de distàncies en l'espai de color HSV utilitzant el mètode <i>Kfold Crossvalidation</i> ($k = 2$) en l'entrenament.	59
3.60	Resultats del mètode de segmentació supervisada a partir de distàncies en l'espai de color LAB utilitzant el mètode <i>Kfold Crossvalidation</i> ($k = 2$) en l'entrenament.	60
3.61	Resultats del mètode de segmentació supervisada a partir de probabilitats utilitzant el mètode <i>Leave One Out</i> en l'entrenament.	61
3.62	Imatge original que serà binaritzada amb els diferents mètodes.	62
3.63	Imatge binaritzada amb tots els mètodes.	62
3.64	Imatge original que serà binaritzada amb els diferents mètodes.	63
3.65	Imatge binaritzada amb tots els mètodes.	63
3.66	Imatge binaritzada amb els quatre diferents mètodes.	64
3.67	Imatge binaritzada amb els quatre diferents mètodes.	64
3.68	Imatge binaritzada amb els la composició de la binarització local i de la binarització per probabilitats.	64
3.69	Imatge binaritzada amb els la composició de la binarització local i de la binarització per probabilitats.	65
3.70	Imatge binaritzada amb la composició de la binarització local i de la binarització per probabilitats i amb els contorns corregits mitjançant un erode.	65
3.71	Imatge binaritzada amb la composició de la binarització local i de la binarització per probabilitats i amb els contorns corregits mitjançant un erode.	66
3.72	Funcionament teòric de l'algorisme CCL.	66
3.73	Imatge amb les regions detectades destacades.	67
3.74	Imatge amb les regions detectades destacades.	67
3.75	Imatge amb les regions detectades destacades amb un filtratge dels falsos positius.	68

3.76	Imatge amb les regions detectades destacades amb un filtratge dels falsos positius.	68
3.77	Imatge amb les regions detectades destacades amb un segon filtratge dels falsos positius.	69
3.78	Imatge amb les regions detectades destacades amb un segon filtratge dels falsos positius.	69
4.1	Primera parella d'imatges sintètiques (cas senzill) per realitzar proves amb el mètode de comparació de cerca exhaustiva.	72
4.2	Segona parella d'imatges sintètiques (cas complex) per realitzar proves amb el mètode de comparació de cerca exhaustiva.	72
4.3	Enumeració dels nevus detectats de la primera imatge sintètica del cas complex.	73
4.4	Enumeració dels nevus detectats de la segona imatge sintètica del cas complex.	73
4.5	Primera imatge sintètica (cas senzill) amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.	74
4.6	Segona imatge sintètica (cas senzill) amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.	74
4.7	Primera imatge sintètica (cas complex) amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.	76
4.8	Segona imatge sintètica (cas complex) amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.	77
4.9	Primera imatge de la primera parella d'imatges del segon conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.	77
4.10	Segona imatge de la primera parella d'imatges del segon conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.	78
4.11	Primera imatge de la segona parella d'imatges del segon conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.	78
4.12	Segona imatge de la segona parella d'imatges del segon conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.	79
4.13	Primera imatge de la primera parella d'imatges del tercer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.	79
4.14	Segona imatge de la primera parella d'imatges del tercer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.	80
4.15	Primera imatge de la segona parella d'imatges del tercer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.	80

4.16	Segona imatge de la segona parella d'imatges del tercer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.	81
4.17	Etiquetatge dels nevus de la primera imatge de la parella d'imatges d'exemple del primer conjunt de dades reals.	82
4.18	Etiquetatge dels nevus de la segona imatge de la parella d'imatges d'exemple del primer conjunt de dades reals.	82
4.19	Primera imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus representatius realitzada a partir del mètode de cerca exhaustiva.	85
4.20	Segona imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus representatius realitzada a partir del mètode de cerca exhaustiva.	86
4.21	Primera imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.	87
4.22	Segona imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.	87
4.23	Primera imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva corregint aproximadament el punt d'obertura de les finestres en la segona imatge a partir de la mitjana de la orientació en els eixos X i Y.	88
4.24	Segona imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva corregint aproximadament el punt d'obertura de les finestres en la segona imatge a partir de la mitjana de la orientació en els eixos X i Y.	88
4.25	Primera imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva assignant cada nevus no representatiu als tres representatius més propers.	89
4.26	Segona imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva assignant cada nevus no representatiu als tres representatius més propers.	89
4.27	Imatges sintètiques destinades a fer proves en els dos mètodes de registre.	91
4.28	Primera imatge sintètica registrada mitjançant mètode de registre afí.	92
4.29	Primera imatge sintètica registrada mitjançant mètode de registre <i>Thin Plate Splines</i>	92
4.30	Primera imatge binaritzada registrada mitjançant el mètode de registre afí i segona imatge binaritzada.	93

4.31	Primera imatge binaritzada registrada mitjançant el mètode de registre <i>Thin Plate Splines</i> segona imatge binaritzada.	93
4.32	Resta de la primera imatge binaritzada registrada mitjançant el mètode de registre afí, i la segona imatge binaritzada.	94
4.33	Primera imatge binaritzada registrada mitjançant el mètode de registre afí i segona imatge binaritzada.	94
4.34	Primera imatge binaritzada registrada mitjançant el mètode de registre <i>Thin Plate Splines</i> segona imatge binaritzada.	94
4.35	Resta de la primera imatge binaritzada registrada mitjançant el mètode de registre <i>Thin Plate Splines</i> , i la segona imatge binaritzada.	95
4.36	Comparació dels nevus de la primera imatge de la primera parella d'imatges del primer conjunt de dades.	96
4.37	Comparació dels nevus de la segona imatge de la primera parella d'imatges del primer conjunt de dades.	96
4.38	Comparació dels nevus de la primera imatge de la segona parella d'imatges del primer conjunt de dades.	96
4.39	Comparació dels nevus de la segona imatge de la segona parella d'imatges del primer conjunt de dades.	97
4.40	Comparació dels nevus de la primera imatge de la tercera parella d'imatges del primer conjunt de dades.	97
4.41	Comparació dels nevus de la segona imatge de la tercera parella d'imatges del primer conjunt de dades.	97
4.42	Comparació dels nevus de la primera imatge de la quarta parella d'imatges del primer conjunt de dades.	98
4.43	Comparació dels nevus de la segona imatge de la quarta parella d'imatges del primer conjunt de dades.	98
4.44	Comparació dels nevus de la primera imatge de la cinquena parella d'imatges del primer conjunt de dades.	98
4.45	Comparació dels nevus de la segona imatge de la cinquena parella d'imatges del primer conjunt de dades.	99
4.46	Comparació dels nevus de la primera imatge de la primera parella d'imatges del segon conjunt de dades.	99
4.47	Comparació dels nevus de la segona imatge de la primera parella d'imatges del segon conjunt de dades.	100
4.48	Comparació dels nevus de la primera imatge de la segona parella d'imatges del segon conjunt de dades.	100
4.49	Comparació dels nevus de la segona imatge de la segona parella d'imatges del segon conjunt de dades.	100
4.50	Comparació dels nevus de la primera imatge de la tercera parella d'imatges del segon conjunt de dades.	101
4.51	Comparació dels nevus de la segona imatge de la tercera parella d'imatges del segon conjunt de dades.	101
4.52	Comparació dels nevus de la primera imatge de la quarta parella d'imatges del segon conjunt de dades.	101

4.53	Comparació dels nevus de la segona imatge de la quarta parella d'imatges del segon conjunt de dades.	102
4.54	Comparació dels nevus de la primera imatge de la primera parella d'imatges del tercer conjunt de dades.	102
4.55	Comparació dels nevus de la segona imatge de la primera parella d'imatges del tercer conjunt de dades.	103
4.56	Comparació dels nevus de la primera imatge de la segona parella d'imatges del tercer conjunt de dades.	103
4.57	Comparació dels nevus de la segona imatge de la segona parella d'imatges del tercer conjunt de dades.	103
5.1	Aparença del mòdul de gestió en l'editor de Matlab.	106
5.2	Aparença de la interfície d'inserció de pacients.	108
5.3	Aparença de la interfície de modificació de pacients.	108
5.4	Aparença de la interfície de cerca de pacients.	109
5.5	Aparença de la interfície d'inserció de noves exploracions de pacients.	109
5.6	Aparença del mòdul de visualització	110
A.1	Inserció d'un nou pacient.	116
A.2	Modificació d'una o més dades d'un pacient seleccionat.	117
A.3	Cerca d'un pacient a partir d'un criteri.	118
A.4	Ordenació de la llista de pacients i mostreig de les dades d'un pacient.	119
A.5	Inserció d'una nova exploració a un pacient.	120
A.6	Tria de les imatges de les exploracions seleccionades d'un pacient.	121
A.7	Detecció dels nevus en les imatges seleccionades.	122
A.8	Comparació dels nevus de dues imatges amb la detecció realitzada.	123

Índex de taules

3.1	Mitjana i desviació estàndard de les components de les mostres en l'espai de color RGB ([0,255]).	39
3.2	Mitjana i desviació estàndard de les components de les mostres en l'espai de color HSV ([0,1]).	39
3.3	Mitjana i desviació estàndard de les components de les mostres en l'espai de color LAB ([0,1]).	43
4.1	Nevus representatius trobats en la primera imatge i la correspondència trobada en la segona.	75
4.2	Correspondències trobades entre les dues imatges sintètiques (cas complex) utilitzant la mida i la distància al nevus gran al que estan relacionats en el criteri de semblança.	75
4.3	Nevus grans trobats en la primera imatge de l'exemple del primer conjunt de dades.	83
4.4	Nevus grans trobats en la primera imatge de l'exemple del primer conjunt de dades, correspondències trobades en la segona imatge, i els encerts i errors que s'han produït.	83
4.5	Nevus grans de la primera imatge de l'exemple del primer conjunt de dades, correspondències trobades en la segona imatge i orientació de cada correspondència en els eixos X i Y.	84
4.6	Nevus grans de la primera imatge de l'exemple del primer conjunt de dades i correspondències trobades en la segona imatge un cop descartades les parelles de nevus que no segueixen el patró d'orientació de correspondències.	85

Capítol 1

INTRODUCCIÓ

1.1 DESCRIPCIÓ

Aquest projecte ha estat desenvolupat dins del grup de Visió per Computador i Robòtica (VICOROB), que forma part del departament d'Arquitectura i Tecnologia de Computadors de la Universitat de Girona.

La major part del projecte està dins el marc de la Visió per Computador, i per tant, treballarem amb moltes de les tècniques que giren entorn seu. Mitjançant aquestes tècniques haurem de desenvolupar una aplicació capaç de segmentar la pell, detectar nevus (pigues i altres taques) i poder comparar imatges de pacients amb risc de contreure melanoma preses en moments diferents.

Aquest projecte està relacionat amb la recerca i el que pretenem és oferir diferents eines informàtiques als dermatòlegs per a propòsits relacionats amb la investigació. Intentarem enfocar cada part de l'aplicació des de més d'un punt de vista, per així poder veure el funcionament de diversos mètodes, extreure el millor de cadascun i aconseguir algorismes més complets.

1.2 EL MELANOMA I ELS NEVUS

El melanoma és un tipus de càncer de pell que apareix quan unes cèl·lules anomenades melanòcits esdevenen malignes. Aquestes cèl·lules són les encarregades d'elaborar un pigment anomenat melanina, responsable del color de la pell, dels cabells i de l'iris dels ulls, a banda d'actuar com a fotoprotector dels raigs del sol. Quan un grup de melanòcits creix apareix una taca a la pell o una piga, el que científicament coneixem com a nevus (del llatí *naevus*).

Una persona adulta sol tenir de mitjana entre 10 i 40 nevus. Els podem dividir en congènits (són de naixement) i adquirits (apareixen en la infància o l'adolescència i poden canviar de mida i forma al llarg dels anys i els podem distingir entre típics o atípics). El número de nevus d'una persona va canviant amb l'edat.

Així doncs, en el pitjor dels casos un nevus o un grup d'ells, poden convertir-se en melanoma, el càncer de pell més agressiu i que pot desenvolupar-se en qualsevol

part del cos. Com en tots els càncers la millor manera de tractar-los és descobrir-los en etapes poc avançades, realitzant tractaments de prevenció.

Els canvis importants de mida, color, forma en els nevus poden ser un indicatiu de melanoma. Les persones amb més probabilitat de contreure melanoma són les que en tenen algun cas en algun membre de la família, les que tenen la pell molt clara, les que tenen una gran quantitat de nevus, les que hagin pogut sofrir cremades en la pell, etc. Tots aquests pacients són considerats d'alt risc [15] [16].

D'aquí ve la importància de desenvolupar una aplicació que sigui capaç de detectar aquests canvis en la pell dels pacients. La utilització d'una eina que pugui ajudar als dermatòlegs a realitzar una ràpida i eficient detecció d'aquests canvis, pot afavorir a la tasca de prevenció del melanoma.

Les dades d'aquesta aplicació informàtica seran per tant un seguit d'imatges de diferents zones de pell de diversos pacients. En elles haurem de detectar els nevus que hi puguin haver i si disposem d'imatges d'un mateix subjecte d'èpoques diferents realitzar una comparació i en conseqüència un seguiment de l'estat dels nevus.

1.3 LA VISIÓ PER COMPUTADOR

L'afany per dotar un ordinador amb la capacitat d'interpretar imatges i actuar a partir d'aquestes interpretacions va fer possible l'aparició de la Visió per Computador. L'objectiu d'aquesta ciència és obtenir la màxima similitud amb les particularitats biològiques de l'ull humà per poder aplicar-les en l'àmbit informàtic.

Així, salvant la distància, podríem comparar les diverses parts de l'ull amb les parts de què consta una càmera. La còrnea actua com a lent fixa i transmet impulsos elèctrics al cervell, mentre que l'iris i el cristal·lí s'encarreguen de l'obertura de la pupila i l'enfoc dels objectes a diferents distàncies; el sistema de lents de les càmeres actua de la mateixa forma que aquestes tres parts de l'ull. La retina actua com a fotosensor; està formada per uns sensors anomenats cons (s'encarreguen de detectar el color) i d'uns altres anomenats bastons (s'encarreguen de captar la intensitat de la llum) [17].

Les imatges que captem amb les nostres càmeres són digitalitzades, vénen donades com a funció bidimensional (una matriu), on cada valor de cada component d'aquesta correspon a un píxel. Els píxels poden tenir una sola component (imatge a nivell de gris) o bé tres, R, G i B (imatge en color). Cada component del píxel correspon a una intensitat (normalment entre 0 i 255 o bé entre 0 i 1, on el 0 representa el color negre i el 255 o l'1 el blanc, i els enters entre aquests dos valors, diferents grisos més foscos o més clars) i la unió de totes les components origina el color del píxel que percebem.

Les aplicacions més usals de la Visió per Computador poden estar enfocades al control de qualitat, a la robòtica, a la seguretat, a l'entreteniment, o com en el cas d'aquest projecte, a l'àmbit mèdic. Cada cop més els metges disposen de suports informàtics que els ajuden a realitzar tasques que resultarien més complicades

sense aquesta tecnologia.

1.4 L'ESTAT DE L'ART

Aquesta no serà la primera investigació que es realitzarà sobre un sistema informàtic amb la capacitat d'ajudar els dermatòlegs en la detecció i seguiment dels nevus, i evidentment no serà l'últim. Existeixen un bon nombre d'aplicacions que treballen sobre aquest tema i considerem molt oportú estudiar el seu funcionament i veure quines capacitats i funcionalitats tenen. Algunes d'aquestes aplicacions disposen fins i tot de sistemes d'adquisició d'imatges dermatològiques (veure *Molemax* i *FotoFinder*).

1.4.1 MIRROR

El *Mirror* [13] és un software propietari desenvolupat per *Canfield*, enfocat a l'àmbit mèdic estructurat en mòduls (*PhotoFile*, *PhotoTules*, *Body Mapping*, ...) que proporciona molta flexibilitat en la gestió d'imatges de pacients.

El mòdul *PhotoFile* proporciona una ràpida gestió de les imatges de cada pacient. Permet inserció, modificació i eliminació de pacients, importació d'imatges, i sobre aquestes, ampliar, rotar, afegir comentaris, ... També tenim la possibilitat de veure dues imatges l'una al costat de l'altre per realitzar comparacions, realitzar impressions avançades d'imatges, entre d'altres.

Un altre mòdul de què disposa és el *PhotoTools*. Aquest, proporciona eines per al processament de les imatges capturades amb el mòdul *PhotoFiles*. Podem ajustar el color entre imatges per evitar grans diferències de contrast, també es poden realitzar ajustaments d'escala i orientació seleccionant uns punts de referència (per exemple les pupil·les), podem calibrar les dimensions de certes zones de la imatge, podem activar una opció que converteix una imatge en una espècie de pissarra (marcar, acolorir, fer línies o fletxes, anotar comentaris, etc), ...

El darrer mòdul que ens ha cridat l'atenció ha estat el *Body Mapping*. Ofereix la possibilitat de veure en diferents perspectives les imatges de les parts del cos d'un pacient, podem guardar conjunts d'imatges com a sessions i fer-ne comparacions, tenim la possibilitat de tractar zones de la imatge de forma particular, etc.



Figura 1.1: Diverses captures de pantalla de *Mirror*.

1.4.2 MOLEMAX

Molemax [12] és un software integrat desenvolupat per *Mecamed*. Es tracta d'un sistema útil en la dermatologia que combina un microscopi fàcil d'usar i de gran qualitat òptica i un software amb la capacitat d'emmagatzemar, imprimir i comparar imatges. Utilitza el concepte de microscòpia d'episluminiscència digital (MELD) basada en un nou concepte d'il·luminació. Aquesta tecnologia permet no només veure la superfície de la pell, sinó que també és capaç d'oferir imatges de les capes inferiors, fet que permet entre d'altres coses, deteccions precoces de melanoma maligne i diferenciació entre tumors benignes i malignes.

El software de *Molemax* permet tenir una documentació completa de les lesions cutànies de la pell, una comparació entre imatges preses en diferents dates per tal de veure possibles canvis en nevus (una al costat de l'altra o bé superposades), disposa d'un sistema de mapeig corporal especialment per pacients considerats d'alt risc, disposa d'una funció avançada de detecció i classificació de lesions a partir de la regla ABCD¹, té incorporat un sistema basat en intel·ligència artificial que proporciona suport pel què fa a consultes, discussions i diagnòstics, etc.



Figura 1.2: Diverses captures de pantalla de *Molemax*.

1.4.3 FOTOFINDER

També hem analitzat *FotoFinder* [11] (aplicació de *FotoFinder Systems*). És una eina apta per a diferents branques de la medicina que ofereix una gran flexibilitat en la gestió de pacients. Pel què fa a l'àmbit de la dermatologia disposa d'alguns mòduls especials.

El mòdul *Mediscope* permet tenir una base de dades SQL d'imatges mèdiques de pacients. Aquesta eina funciona a partir de la interacció d'una càmera i d'un software en contacte a través d'una línia de control de manera que la configuració dels paràmetres (flash, zoom, il·luminació) s'efectua de forma automàtica. El fet de tenir aquests dos elements junts permet unes imatges de molt alta qualitat. Ofereix la possibilitat d'obtenir imatges de la cara i de la resta del cos d'alta definició, realitzar comparacions, i altres funcions sobre les imatges.

El mòdul *Dermoscope* permet l'anàlisi de la pell amb risc de desenvolupar

¹Quan un nevus és Assimètric, té les Bandes irregulars, pren un Color fosc o irregular i el seu Diàmetre augmenta, tot indica que és un melanoma.

càncer. Partint de la base d'una tècnica anomenada dermatoscòpia digital, és capaç de la detecció precoç del melanoma maligne (o altres lesions cutànies) i la delimitació de les zones afectades. Si es vol també es pot utilitzar com a instrument de documentació i seguiment dels nevus del pacient.

Finalment el mòdul *BodyStudio* permet la monitorització de la pell de tot el cos del pacient, oferint una fàcil comparació de les imatges d'un pacient. Mitjançant un mapeig tindrem la possibilitat de detectar anomalies ràpidament en la pell de pacients considerats d'alt risc. Cada possible lesió es pot analitzar de forma particular (més detallada).




Figura 1.3: Diverses captures de pantalla de FotoFinder.

1.4.4 ALTRES APLICACIONS

A banda dels tres sistemes comentats anteriorment hem trobat altres aplicacions, cadascuna amb les seves particularitats:

- *MoleExpert*: es tracta d'un software especialitzat en l'anàlisi automatitzat de lesions cutànies. Va ser desenvolupat com a suport a l'hora de diagnosticar possibles lesions en la pell. De fet no dona exactament un diagnòstic del nevus, sinó que a partir de l'assimetria, el tamany, la forma i el color (regla ABCD) calcula un estadístic. Els valors més alts d'aquest estadístic significaran més possibilitats de contreure melanoma [14].
- *SkinSeg*: és una eina molt bàsica que permet detectar els límits d'un melanoma a partir d'una successió de tècniques de Visió per Computador (binaritzacions, aplicació de filtres gaussians, ...) [14].
- *DermAlert*: permet la comparació entre imatges de parts del cos preses en diferents èpoques, seguidament i visualització de les diferències existents. És lògic que l'aplicació més comuna, per tant, sigui la comparació de nevus. També disposa de tècniques d'alineació de les imatges per a la correcta comparació, i de la capacitat d'introduir comentaris i marques en la imatge [14].
- *DullRazor*: aquest programa és capaç d'eliminar els possibles pèls que hi puguin haver sobre els nevus d'una imatge mitjançant tècniques de Visió per

Computador (operació morfològica de close, interpolació per substituir els píxels on anteriorment hi havia un pèl i uniformització de la zona a partir d'un filtre de la mitjana), i així, eliminar possibles problemes que es podrien produir en cas de no eliminar-los [14].

1.5 L'ENTORN DE TREBALL

Com ja hem dit, les imatges són matrius, i per tant necessitem d'un entorn que ens permeti treballar amb matrius i a ser possible, disposi de comandes de processat d'imatge. Per això hem escollit *Matlab*. Es tracta d'un software molt utilitzat en universitats i en centres d'investigació, entre les prestacions del qual trobem la manipulació de matrius, la representació de dades i funcions, la implementació d'algorismes, la creació d'interfícies d'usuari i la comunicació amb altres programes d'altres llenguatges de programació.

Matlab a vegades pot ser lent, les seves interfícies no tenen una presentació molt agradable i es tracta d'un llenguatge interpretat. En definitiva, podríem dir que es tracta d'un entorn poc adequat per a la construcció de sistemes per comercialitzar. Però aquest no és el cas d'aquest PFC, ja que s'emmarca en l'àmbit de la recerca i és per això que *Matlab* resulta més adequat.

De les múltiples llibreries de funcions de què disposa, utilitzarem molt la *Image Processing Toolbox*, que proporciona una col·lecció molt àmplia de funcions enfocades al processat d'imatges. També farem ús de GUI, que ofereix la possibilitat de crear interfícies gràfiques d'usuari d'una forma molt flexible, per a la implementació de l'aplicació.

Hem utilitzat la versió 7.04 de *Matlab* ja que amb versions anteriors a la 7 no disposàvem d'algunes de les comandes que necessitem.




Figura 1.4: Matlab 7.

Pel què fa a l'edició de la documentació utilitzarem l'entorn \LaTeX . Funciona a partir d'un conjunt de macros creades per facilitar el disseny de documents. Es tracta d'una eina de gran potència molt utilitzada en l'edició d'articles acadèmics,

documents científics i tècnics, d'articles, ... La seva potència es basa al fet de no haver de posar tanta atenció en el format del document (ho gestiona de forma bastant automàtica), i poder centrar-se en el contingut.

1.6 OBJECTIUS

Aquest projecte està orientat al desenvolupament d'un sistema informàtic que proporcioni als dermatòlegs agilitat a l'hora de gestionar les dades dels pacients amb les seves imatges corresponents, ajudar-los en la realització de deteccions dels nevus d'aquestes imatges, i ajudar-los en la comparació d'exploracions (amb les deteccions realitzades) de diferents èpoques d'un mateix pacient. Aquest és l'objectiu principal, però el podem dividir en diferents punts:

- Cercar informació sobre algunes aplicacions informàtiques ja existents, que realitzin tasques similars a les que tenim per objectiu. Pretenem veure quines utilitats fan falta als dermatòlegs i a la vegada tenir algun model d'exemple.
- Crear unes bases de dades d'imatges dividides en conjunts amb unes característiques pròpies per cada conjunt. Aquestes imatges seran les dades principals amb les que testejarem els algorismes del projecte, i amb les que es realitzaran tots els experiments i entrenaments pertinents (com veurem alguns algorismes necessiten d'imatges per aprendre a segmentar, detectar, etc). També volem analitzar i extreure conclusions dels resultats.
- Adquirir majors coneixements en el camp de la Visió per Computador i tots els aspectes que giren entorn seu.
- Crear una interfície gràfica d'usuari per interactuar amb els algorismes que implementarem i fer-ne més senzilla i intuïtiva l'execució i la manipulació de les imatges.
- Aconseguir detectar la major quantitat possible de nevus d'una imatge, intentant reduir al mínim el número de deteccions errònies. Destacar-los o marcar-los en la imatge per fer-los ràpidament visibles.
- Realitzar comparacions dels nevus detectats en diferents imatges pel què fa a similitud. Obtenir una taula de correspondències entre els nevus de les diferents imatges per a futurs anàlisis i seguiments.
- Aprendre a documentar un projecte de les dimensions d'un PFC.

1.7 ABAST

Un cop finalitzat el projecte tindrem:

- Un sistema informàtic dissenyat per als dermatòlegs dotat amb les utilitats indispensables de tota eina de gestió informàtica (inserció, modificació, eliminació, cerca, ...), així com un entorn de visualització d'imatges amb la possibilitat de realitzar deteccions de nevus i comparacions del conjunt de nevus de diverses imatges.
- Una col·lecció d'experiments i resultats dels diferents mètodes utilitzats en el projecte, amb la seva interpretació i les conclusions extretes.
- Una documentació de tot el treball que hem realitzat, que podrà servir en recerques i investigacions futures.

1.8 PLANIFICACIÓ

El primer esbós del pla de treball del projecte que vam realitzar el vam dividir en les següents etapes:

- Anàlisi de l'estat de l'art (aplicacions ja existents) (octubre i novembre de 2007).
- Disseny del gestor de pacients: aparença, utilitats, dades necessàries (desembre del 2007).
- Implementació d'un primer prototip del gestor amb les utilitats bàsiques i amb la visualització de les imatges. Disseny del sistema de detecció (gener i febrer del 2008).
- Finalització de la implementació del gestor (a excepció de la detecció i la comparació), proves d'usuari i documentació. Implementació d'un detector de nevus senzill. Disseny del comparador. (març i abril del 2008).
- Experiments, resultats, perfeccionament i documentació del detector. Implementació d'un sistema de comparació senzill. (maig del 2008).
- Proves, resultats, perfeccionament i documentació del comparador. Finalització de la memòria (juny 2008).

Finalment però, algunes dates previstes han sofert modificacions (avançaments o retards). A més l'ampliació d'alguna de les àrees d'investigació va fer que el desenvolupament del projecte variés en alguns aspectes. Tot seguit podem veure una descripció detallada de la organització final del treball:

- Anàlisi de l'estat de l'art. Cerca i estudi de les diferents aplicacions informàtiques de l'àmbit de la dermatologia, i més concretament en la detecció i/o comparació de nevus (octubre i novembre del 2007).

- Disseny d'un senzill detector de nevus. Primeres proves de binarització d'imatges mitjançant binarització local i segmentació supervisada a partir de mètodes basats en distàncies. (desembre del 2007 i gener i febrer del 2008).
- Primeres proves amb els mètodes implementats del detector i inici de la redacció de la documentació d'aquesta part. Disseny d'un senzill comparador de nevus a partir d'imatges sintètiques (març i abril del 2008). Captura de les imatges dels conjunts de proves.
- Proves i experiments de binarització a partir del mètode supervisat per probabilitats, perfeccionament del detector i finalització de la memòria d'aquesta part. Realització d'un primer comparador preparat per a imatges reals dels conjunts de prova a partir del mètode de cerca exhaustiva (maig del 2008).
- Proves, experiments, perfeccionament i inici de la documentació del comparador (juny del 2008).
- Proves amb el mètode de registre i finalització de la documentació del comparador. Disseny del primer prototip del gestor de pacients (juliol del 2008).
- Perfeccionament, proves d'usuari i documentació del gestor de pacients. Finalització de la documentació (agost del 2008).

1.9 METODOLOGIA

La metodologia emprada ha sigut dissenyar els algorismes i llavors testear-los i depurar-los (millorar-los) contínuament utilitzant un conjunt petit d'imatges. Primer senzilles imatges sintètiques, i després imatges reals dels diferents conjunts de dades. Aquest conjunt d'imatges reduït ha de servir per trobar els paràmetres dels algorismes que després hem de testear i evaluar, utilitzant totes des dades disponibles del conjunt.

Per això en el segon capítol presentarem les dades de treball i en el tercer i el quart explicarem el disseny i desenvolupament dels algorismes a partir d'aquesta metodologia.

1.10 ESTRUCTURA DE LA MEMÒRIA

- **Capítol 1:** Introducció
Situem el lector en el tema del projecte. Fem una pinzellada al melanoma i als nevus, a la visió per computador i a l'estat de l'art. Mostrem els objectius i l'abast del projecte així com la planificació de les tasques a realitzar.
- **Capítol 2:** Les dades de treball
Presentem els diferents conjunts de dades de treball i el seu origen. Veiem com vam capturar les imatges i com extreiem mostres de pell i de no pell de les imatges dels diferents conjunts.

- **Capítol 3:** El detector de nevus
En aquest capítol expliquem els diferents mètodes que hem utilitzat per a realitzar les binaritzacions de les imatges, la detecció de les regions i l'eliminació dels falsos positius. També mostrem els resultats obtinguts i exposem les conclusions que n'hem extret.
- **Capítol 4:** El comparador
En aquest punt analitzem les diferents estratègies de comparació que hem escollit. Veiem resultats tan del mètode de cerca exhaustiva com de registre i en treiem les conclusions pertinents.
- **Capítol 5:** El gestor de pacients
Comentem els aspectes més destacables del disseny i la implementació del gestor de pacients. Veiem com hem decidit les funcions necessàries i com hem estructurat les interfícies.
- **Capítol 6:** Conclusions i treballs futurs
Analitzem els resultats obtinguts en les diferents parts del projecte i n'extreiem conclusions. També proposem futurs fils d'investigació per continuar el desenvolupament d'aquest PFC.
- **Apèndix A:** Manual d'usuari
En aquest annex hi trobem un manual d'usuari de l'aplicació. Comentem breument les diferents funcions que és capaç de realitzar, donat que l'aplicació ha de ser utilitzada per investigadors ja avesats a treballar amb aquest tipus d'aplicacions.

Capítol 2

LES DADES DE TREBALL

Per poder dur a terme el desenvolupament d'aquest projecte necessitem un seguit de dades d'entrada, o sigui imatges, tant per poder aplicar els algorismes que implementem com per poder realitzar entrenaments i proves. A més també volem veure el comportament dels diferents mètodes sobre imatges de diferents característiques, com la resolució de la càmera, la distància de captura de les imatges, la zona del cos de la qual s'ha captat la imatge, etc. Disposem de tres conjunts de dades principals. El primer està format per un seguit d'imatges cedides per l'Hospital Clínic de Barcelona d'un pacient real, mentre que els altres dos conjunts el formen imatges de zones de pell de pacients ficticis amb nevus reals i pintats.

2.1 ELS CONJUNTS DE DADES

Seguidament podem veure tots els conjunts de dades que utilitzarem per a la realització d'entrenaments i d'experiments. Cada conjunt té unes característiques diferents que ens aporten uns resultats determinats.

A banda dels conjunts de dades reals que presentarem, en el transcurs del projecte també ens hem vist obligats a utilitzar dades sintètiques per poder realitzar les proves que hem cregut necessàries. Aquestes imatges seran comentades en el moment en què se'n faci ús.

2.1.1 EL CONJUNT DE DADES REALS 1

En aquest conjunt tenim imatges d'un pacient amb una gran quantitat de nevus (considerat d'alt risc). Les imatges són de la zona del tronc, tant de la part anterior com de la posterior. La seva mida és de 640x480 píxels. Les imatges han estat proporcionades pels dermatòlegs de l'Hospital Clínic i corresponen a un pacient real. Disposem d'un total de 10 imatges que han estat adquirides en dues exploracions diferents. Per tant, és un bon conjunt de test, donat que són dades reals i tenim la possibilitat de comparar dues exploracions.



Figura 2.1: Imatges del conjunt de dades reals 1.

2.1.2 EL CONJUNT DE DADES REALS 2

Aquest conjunt està format per imatges de la part superior i de la inferior d'un braç d'una trentena de persones. Vam voler agafar mostres de pell de diverses persones per poder-ne tenir de diferents tons i diferents tipus de pells. Vam utilitzar dues càmeres (comentades el l'apartat 2.2) diferents per poder treballar amb diferents mides i resolucions d'imatges. En algunes imatges s'han afegit alguns nevus pintats per poder tenir casos per a la comparació (simulem dues exploracions). Aquest conjunt a banda d'estar destinat a realitzar proves en els mètodes de detecció i comparació, també ens servirà per a realitzar millors entrenaments en els mètodes de segmentació supervisada. Tenim imatges de dues mides diferents, 480x640 píxels (càmera *Olympus*) i 3000x4000 píxels (càmera *Canon*). En les imatges apareixen a sobre i a sota del braç unes marques per saber la resolució amb què estem treballant i per així poder-les calibrar. En aquest conjunt totes les imatges s'han capturat amb la càmera a la mateixa distància. La resolució és aproximadament de 1.6 píxels per mil·límetre per les imatges de la càmera *Olympus* i de 10 píxels per mil·límetre per les de la càmera *Canon*.




Figura 2.2: Imatges d'un mateix braç capturades amb les dues càmeres diferents.



Figura 2.3: Imatges del conjunt de dades reals 2.

Val a dir que després de certes proves vam optar per utilitzar tan sols les imatges

de la càmera *Olympus*, ja que l'aplicació dels diferents algorismes en les imatges de la *Canon* comportava costos computacionals en temps molt elevats (tenint en compte entre d'altres coses l'ús de *Matlab* com a entorn en un portàtil amb processador *Intel Centrino*), i que amb les imatges de la primera càmera el nombre de dades del conjunt és més que suficient.

2.1.3 EL CONJUNT DE DADES REALS 3

Aquest tercer conjunt consta d'imatges del braç d'un pacient fictici. Se li han pintat algunes pigues de més per poder tenir dues imatges de prova pels mètodes de detecció i comparació. La seva mida és de 2816x2112 píxels. Podem veure com en totes les imatges del conjunt existeix un petit quadrat. Es tracta d'una marca que farem servir per saber la resolució de la càmera (la distància en què s'han adquirit les imatges). El quadrat és de 20 mm², i per tant les respectives resolucions (arrodonides a un decimal) de les quatre imatges són de 9.6, 10.5, 11.4 i 12 píxels per mil·límetre respectivament.




Figura 2.4: Imatges del conjunt de dades reals 3.

2.2 L'OBTENCIÓ DE LES IMATGES

A banda del conjunt de dades que ens ha cedit l'Hospital Clínic, la resta d'imatges les hem capturat nosaltres mateixos. Les càmeres que hem utilitzat són la *Olympus X-725* (6 MP) en dues resolucions diferents: 480x640 (qualitat baixa) i 2112x2816 (qualitat alta) i la *Canon PowerShot A650-IS* (12 MP).



Figura 2.5: Càmeres utilitzades en la captura de les imatges.

El set de captura de les imatges es va situar en el Laboratori de Visió per Computador i Robòtica de l'edifici P4 de l'Escola Politècnica Superior (UdG) i va estar dispostat tal i com es mostra a la figura següent:



Figura 2.6: Set de captura de les imatges.

Podem veure a les dues càmeres (la *Olympus* a l'esquerra i la *Canon* a la dreta) subjectades amb trípodes. Les dues enfoquen a una superfície blava amb les corresponents marques de calibració. Entre les dues marques hi ha l'espai suficient com per poder-hi fotografiar un braç.

Vam realitzar fotografies de la part superior i inferior dels braços dels diferents voluntaris, amb l'objectiu de tenir diferents tonalitats de pell, i aconseguir imatges amb diversos nevus (en alguns casos se'ls en van pintar alguns).



Figura 2.7: Captura de les imatges del braç d'un voluntari.

2.3 L'OBTENCIÓ DE MOSTRES

En el desenvolupament del PFC ha fet falta segmentar la pell, és a dir, donada una imatge com la de la figura 2.8, intentar diferenciar les diferents regions (pell i fons per exemple). Per aquest motiu hem utilitzat uns algorismes de segmentació supervisada que primer aprenen quines característiques tenen els píxels que corresponen a la pell i quines característiques tenen els altres píxels. Necessitem pertant mostres de pell i exemples que corresponguin a zones de no-pell. Per això veiem la necessitat de crear una base de dades per cada conjunt d'imatges on hi hagi diverses subimatges de pell únicament de cada imatge. Aquesta base de dades, tal i com hem dit, la utilitzarem en els entrenaments de la classe pell en els mètodes de segmentació supervisada (distàncies en els espais de color HSV i RGB i probabilitat bayesiana). Intentarem agafar mostres amb diferents tonalitats.

També necessitarem mostres de píxels que no corresponguin a pell en el mètode de detecció de nevus per probabilitats. Agafarem mostres de no-pell per cada conjunt. En la no-pell han de constar-hi píxels del fons i de les marques de la resolució. Com a exemple mostrem el que hem agafat en el conjunt de dades de la imatge anterior:

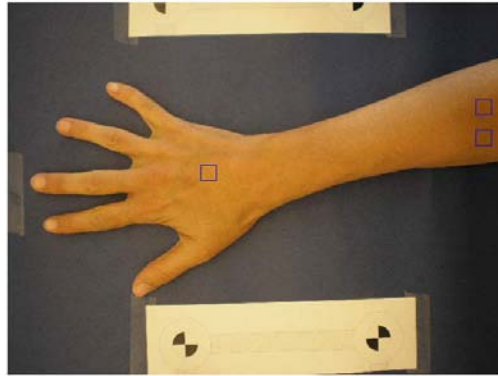


Figura 2.8: Mostres de pell de la base de dades d'una imatge d'un conjunt d'imatges.



Figura 2.9: Exemple de mostra de no-pell d'un conjunt d'imatges.

Capítol 3

EL DETECTOR DE NEVUS

En aquest capítol de la memòria estudiarem, analitzarem i proposarem mètodes per a la detecció dels nevus (pigues i altres taques) per a posteriors seguiments. A partir d'algunes tècniques de Visió per Computador, els nevus han de quedar clarament marcats en les imatges, i hem d'emmagatzemar un seguit d'informació referent a cadascun d'ells per poder-los classificar i comparar adequadament.

Com que a partir d'una imatge han de quedar destacades un seguit de zones concretes, una tècnica de segmentació ens pot ser útil. La idea és realitzar una binarització de la imatge per a posteriorment aplicar un algorisme que sigui capaç de segmentar-la, i així, localitzar les regions d'interès.

3.1 LA BINARITZACIÓ DE LA IMATGE

Un cop hem decidit l'estratègia a seguir, el primer pas és fer una bona binarització de la imatge (passar d'una imatge amb 8 bits de nivell de gris a una d'1 bit mitjançant un llindar). A simple vista hem pogut veure que no és gens fàcil, ja que depèn de molts factors, com per exemple, la resolució i la il·luminació de la imatge, l'obtenció d'un llindar de binarització adequat, l'aparició o no de fons, entre altres. A més d'aquests aspectes, la dificultat recau sobretot, en el fet d'implementar un algorisme suficientment robust com per a efectuar una correcta llindarització en diferents imatges, de diferents mides i preses en situacions i condicions diferents.

3.1.1 MÈTODES

Proposarem diferents mètodes per a realitzar aquestes dues tasques com una binarització local, i alguns mètodes de segmentació supervisada (mitjançant mètodes de distàncies, probabilitat bayesiana, ...).

3.1.1.1 LES PRIMERES PROVES

Comencem les proves de binarització de la imatge amb mètodes senzills sobre imatges d'un braç i d'una eskena amb diversos nevus. El primer pas que hem

realitzat és l'aplicació d'una comanda que simplement binaritza globalment una imatge amb un llindar determinat (experimental). Una binarització global consisteix en explorar tots els píxels de la imatge i assignar-los 0 o 1 segons un llindar predeterminat.




Figura 3.1: Imatge binaritzada globalment amb llindar 128 ([0,255]).



Figura 3.2: Imatge binaritzada globalment amb llindar 128 ([0,255]).



Figura 3.3: Imatge binaritzada globalment amb llindar 110 ([0,255]).

Ràpidament hem observat que aquesta opció té certes mancances. Les zones de pell menys il·luminades apareixen negres en la imatge llindaritzada, i alguns nevus ni tan sols hi figuren. El fet de reajustar el llindar per fer desaparèixer les zones ombrējades comporta la desaparició d'alguns dels nevus de la imatge. També

és obvi que imatges diferents necessitaran llindars diferents. Per tant haurem de realitzar un seguit de canvis per aproximar-nos més a la binarització ideal.

En la primera temptativa l'obtenció del llindar ha estat de forma experimental. Potser podem aconseguir-ne un de millor amb algun mètode de cerca del llindar òptim. Hem optat per otsu [6], ja que es traca d'un dels mètodes més utilitzats en la obtenció de llindars òptims. Funciona a partir de la distribució dels píxels de la imatge en dues classes, de tal forma que la variància dins una mateixa classe sigui mínima.




Figura 3.4: Imatge binaritzada amb llindar obtingut pel mètode otsu ([0,255]).



Figura 3.5: Imatge binaritzada amb llindar obtingut pel mètode otsu ([0,255]).

Malgrat tot, com es pot observar en les imatges de les figures 3.4 i 3.5 els resultats no han estat els esperats. La imatge resultant no ha millorat gaire les aconseguïdes anteriorment, ja que en la divisió lògica entre la pell i la no pell (nevus i fons) la variància de les dues classes és mínima quan les zones ombrejades formen part de la classe no pell. Per tant deduïm que cal utilitzar mètodes més complexos per aconseguir millor resultats.

3.1.1.2 LA BINARITZACIÓ LOCAL

Una bona manera per binaritzar imatges poc uniformes, amb possibles zones ombrejades, és l'aplicació d'una binarització local (*local threshold*). Es tracta de passar per la imatge una finestra lliscant de mida predeterminada que llindaritz

apropiadament cada subimatge resultant. Òbviament existeixen un seguit de paràmetres que ofereixen diferents resultats, com són la mida de la finestra i el llindar utilitzat. La primera prova escollida l'hem fet amb un llindar obtingut a partir del mètode otsu, i amb diferents mides de la finestra. Un fet que cal tenir en compte és que la mida de la finestra serà proporcional a la mida de la imatge, i que la que obtenim en aquestes proves serà per aquest conjunt d'imatges. En els altres s'haurà d'aplicar la mateixa relació que la trobada en aquestes proves:




Figura 3.6: Imatge binaritzada localment amb llindar obtingut pel mètode otsu i finestra de 5x5 ([0,255]).



Figura 3.7: Imatge binaritzada localment amb llindar obtingut pel mètode otsu i finestra de 50x50 ([0,255]).



Figura 3.8: Imatge binaritzada localment amb llindar obtingut pel mètode otsu i finestra de 100x100 ([0,255]).

Amb aquest primer intent hem obtingut unes imatges molt pixel·lades. Les zones marcades com a blanques en la imatge són bastant correctes, però apareixen problemes en porcions de pell amb ombra, que adopten un to diferent a la resta, fet que les marca com a negres. Amb llindars petits pràcticament no es poden distingir els contorns de les imatges, i a mesura que es va augmentant el llindar la imatge es va definint, però apareixen els defectes d'ombra comentats anteriorment.



Figura 3.9: Fragment ampliat d'una imatge binaritzada localment amb llindar obtingut pel mètode otsu i finestra de 100x100 ([0,255]).

El problema recau en el fet que en cada una de les finestres que obtenim, el mètode otsu intenta aconseguir-ne un llindar òptim que sigui capaç de diferenciar-ne les zones amb un nivell de gris més alt de les que tenen un nivell de gris més baix. Això implica que otsu i altres mètodes de cerca automàtica funcionen bé amb histogrames bimodals, però malament amb unimodals. En zones on apareixen pell i nevus, el llindar seleccionat permet diferenciar les dues parts força bé, en canvi en imatges amb una escala de grisos més uniforme (pell únicament), intenta trobar un llindar que proporcioni dues zones diferenciades, quan això no és correcte. El llindar que hauríem d'utilitzar hauria d'actuar de forma diferent en imatges amb tons de gris uniformes, evitant que tonalitats de pell diferents siguin considerades com a zones diferents.

En la segona prova el llindar que hem utilitzat és la mitjana de la finestra. A priori es pot intuir que aquest mètode no ens oferirà el resultat desitjat, però es podrà saber si millora la prova anterior, on hem utilitzat el mètode otsu.




Figura 3.10: Imatge binaritzada localment amb mitjana com a llindar i finestra de 5x5 ([0,255]).




Figura 3.11: Imatge binaritzada localment amb mitjana com a llindar i finestra de 50x50 ([0,255]).



Figura 3.12: Imatge binaritzada localment amb mitjana com a llindar i finestra de 100x100 ([0,255]).

Tal com es pot observar no hi ha molta diferència entre la binarització amb llindar obtingut pel mètode otsu o amb mitjana com a llindar. Apareixen problemes semblants als que es teníem amb el mètode anterior. Tot i això un d'aquests dos mètodes ens pot servir com a punt de partida, en la nova estratègia que seguirem: diferenciar les subimatges amb un nivell de gris relativament uniforme de les que no el tenen.

La manera que hem pensat per saber si una subimatge és o no uniforme és mitjançant els histogrames. En principi les finestres uniformes tindran una distribució bastant semblant a una normal (campana de Gauss), mentre que les altres molt segurament tindran dos modes. Per tant hem de trobar un mètode efectiu capaç de diferenciar finestres unimodals de bimodals (o no uniformes).

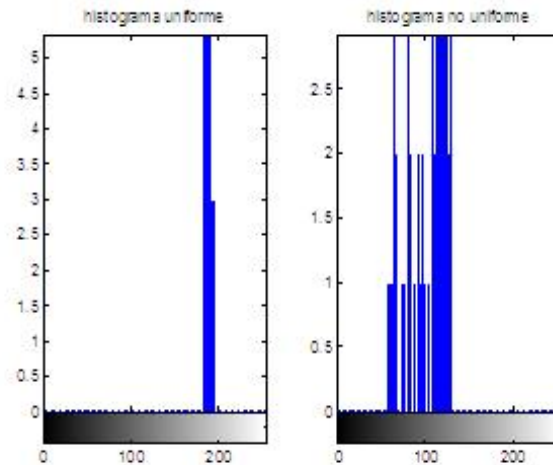


Figura 3.13: Histograma uniforme (unimodal) i histograma no uniforme dels nivells de gris de dues subimatges, la primera amb pell únicament, i la segona amb pell i nevus ([0,255]).

La forma que hem trobat per distingir els histogrames uniformes dels que no són, és a partir de la seva desviació estàndard. Podem considerar que una porció de pell té una escala de grisos uniformes si la seva desviació no és molt gran. Resulta obvi aquest fet, ja que el rang de nivells de gris que trobarem en els histogrames unimodals normalment sempre serà més petit que els que no tenen aquesta distribució. Això significa que necessitarem un nou llindar que ens digui fins a quin punt és uniforme una subimatge. Per trobar una aproximació d'aquest llindar podem agafar diferents fragments d'una imatge, uns amb un tros on només tinguem pell (si pot ser amb canvis en la tonalitat per trobar casos extrems, tot i que amb mides de finestra petita no és provable que hi hagi molta varietat de nivells de gris) i els altres on apareguin pell i nevus. Per exemple hem agafat la següent subimatge composta per pell i per un nevus, i l'hem binaritzat localment amb la mitjana com a llindar.



Figura 3.14: Subimatge binaritzada localment amb la mitjana com a llindar ([0,255]).

Analitzant la desviació estàndard hem trobat que una mostra de píxels de pell d'aquesta subimatge té una desviació de 7.5847, mentre que la de tota la subimatge (i per tant, de pell i nevus) és de 8,1629. Podem provar de fixar el llindar a 8.

Un cop sapiguem quina distribució té l'histograma de la finestra caldrà actuar en conseqüència: per a histogrames bimodals fer servir com a llindar la mitjana ja serveix, en canvi per a unimodals caldrà fer alguna modificació. Les zones de pell solen ser força clares, o sigui que si partim de la mitjana per al llindar i reduïm una mica, molts dels píxels de pell que no s'haguessin considerats com a tal, ara si seran tractats correctament. En definitiva, del que es tracta és d'abaixar el llistó per tal de considerar tota una regió uniforme. Cal tenir en compte que si en la imatge hi ha fons possiblement també serà d'una gamma de tons similars, i per tant, si es tracta d'un fons fosc és possible que en la imatge binaritzada els seus píxels apareguin blancs. Aquest fet no és important, ja que el veritable objectiu de l'aplicació és la detecció de pigues i altres taques, obviant si cal el fons. Si a les finestres amb histograma uniforme, considerem per exemple el llindar com la mitjana menys 15 el resultat és el següent:



Figura 3.15: Subimatge binaritzada localment amb la mitjana com a llindar per a les finestres amb histogrames no uniformes, i mitjana menys 15 per a les finestres amb histogrames uniformes ([0,255]).

Si provem algunes imatges una mica complexes podem veure com realment aquest mètode funciona molt bé.



Figura 3.16: Imatge binaritzada localment amb mitjana com a llindar (finestres amb histogrames no uniformes), mitjana menys 15 com a llindar (finestres amb histogrames uniformes) i finestra de 10x10 ([0,255]).




Figura 3.17: Imatge binaritzada localment amb mitjana com a llindar (finestres amb histogrames no uniformes), mitjana menys 15 com a llindar (finestres amb histogrames uniformes) i finestra de 10x10 ([0,255]).

Els resultats obtinguts són satisfactoris, ja que la gran majoria de nevus han quedat ben destacats. Cal però eliminar un seguit de falsos positius que s'han produït en zones conflictives com els contorns del cos o en zones molt fosques, però ho deixarem com a pas final de la detecció, just després de la segmentació, i per tant ho tractarem més endavant (veure apartat 3.2).

3.1.1.3 LA SEGMENTACIÓ SUPERVISADA A PARTIR DE DISTÀNCIES

Paral·lelament al mètode de binarització local, vam treballar amb el que s'anomenen segmentacions supervisades. Es tracta de realitzar una segmentació d'una imatge (en el nostre cas una segmentació en dues regions, és a dir, una binarització) amb un entrenament previ d'un seguit de característiques que ens permetin diferenciar les diferents classes que volem distingir. Ja que nosaltres tenim un coneixement a priori de quins tons poden adquirir els píxels de pell, podem fer una divisió entre dues classes: la classe pell i la classe no-pell (nevus i fons). Necessitem per tant, una caracterització de la pell, un tret que ens facin poder assegurar que el píxel que estem tractant correspon a aquesta classe.

Com acabem de dir, a l'hora de treballar amb segmentacions supervisades, és important realitzar un bon entrenament per obtenir els resultats esperats. Per això provarem dos mètodes d'entrenament (veure els resultats en l'apartat 3.1.2). Veurem com el segon mètode que exposarem (*Leave One Out*) és més robust que el primer (*Kfold Crossvalidation*), i genera una distinció més gran entre les classes pell i no-pell. Aquests entrenaments també els utilitzarem en la segmentació supervisada a partir de probabilitat bayesiana (la veurem més endavant).

EL MÈTODE *KFOLD CROSSVALIDATION* Consisteix en dividir el conjunt d'imatges en k conjunts (en el nostre cas hem apostat per $k = 2$), dedicant uns conjunts a l'entrenament i els altres a la experimentació. L'assignació d'una imatge a un conjunt es realitza aleatòriament.

EL MÈTODE *LEAVE ONE OUT* Aquesta estratègia encara realitza un entrenament més exhaustiu. Consisteix en testejar un algorisme en una imatge d'un conjunt, utilitzant la resta d'imatges del conjunt per a l'entrenament.

Les primeres proves senzilles però, les realitzarem amb les següents mostres de pell i intentarem extreure'n característiques:



Figura 3.18: Mostres de pell utilitzades per extreure característiques.

Una de les mostres de pell (la del centre) l'hem capturat d'una zona que no estava gaire il·luminada. El color que té és una mica diferent a les altres, i per tant pot arribar a modificar sensiblement alguna de les característiques.

Cal analitzar quines característiques de color tenen aquestes mostres de pell. Una bona manera és veure la mitjana que té cada component en cada imatge. La imatge per defecte ve representada en l'espai RGB, per tant cal veure quines característiques tenen els píxels en cada component. Ens fixem en la mitjana i la desviació estàndard.

	Mitjana R	Mitjana G	Mitjana B	Desviació R	Desviació G	Desviació B
Mostra 1	230.3	171.5	141.4	2.005	1.318	1.137
Mostra 2	184.9	121	98.9	2.047	2.047	2.627
Mostra 3	95.8	62.6	46.8	0.955	1.501	1.378
Mostra 4	189.2	129.3	107.3	1.982	1.982	1.982
Mostra 5	207.3	149.2	124.9	4.437	5.357	5.095

Taula 3.1: Mitjana i desviació estàndard de les components de les mostres en l'espai de color RGB $([0,255])$.

Tant la mitjana com la desviació de les components en l'espai RGB varia molt entre mostres, i per tant és molt difícil reconèixer quins píxels són de pell i quins no. Els valors no tenen cap mena de relació, i es fa difícil l'obtenció d'estadístics. Aquest fet és degut a que l'espai de color RGB no és perceptualment lineal, i que dos colors que a simple vista són semblants poden tenir una distància molt gran en l'espai de color.

Fa falta doncs un canvi en l'espai de color, i per això necessitem analitzar quins són els millors per a segmentar la pell. Segons la informació trobada, existeixen molts estudis sobre quins espais de colors són els millors a l'hora de treballar amb pell: el ja comentat RGB, RGB normalitzat, HSV (també anomenat HSI, HSL,...), TSL, YCrCb, CIELAB, CIELUV, etc. D'entre aquests en destaquen dos, que s'han convertit en els més utilitzats ja que s'ha demostrat que funcionen millor [1] [2] [3]: HSV i CIELAB. Així doncs, seran aquests dos els espais de color que escollim a l'hora de segmentar la pell.

L'espai HSV (Hue, Saturation, Value) descriu més intuïtivament els colors, ja que es basa en una percepció més pròxima a la que entenem les persones. Les seves components representen el to (longitud d'ona dominant), la saturació (puresa del color) i la lluminositat (intensitat del color). És popular entre els espais de color pel que fa a la segmentació de la pell degut a la seva intuïtivitat i a la discriminació explícita entre les seves propietats de crominància i lluminància.

Per corroborar que és un bon espai de color cal veure com hem fet anteriorment amb l'espai RGB, la mitjana i la desviació de les mostres convertides a HSV.

	Mitjana H	Mitjana S	Mitjana V	Desviació H	Desviació S	Desviació V
Mostra 1	0.056	0.386	0.903	0.001	0.009	0.014
Mostra 2	0.042	0.465	0.725	0.005	0.17	0.012
Mostra 3	0.053	0.511	0.376	0.006	0.022	0.007
Mostra 4	0.045	0.433	0.741	0.004	0.013	0.020
Mostra 5	0.049	0.398	0.813	0.003	0.021	0.027

Taula 3.2: Mitjana i desviació estàndard de les components de les mostres en l'espai de color HSV $([0,1])$.

Pel que fa a les mitjanes, podem veure que totes són semblants (potser en la component V hi ha valors més dispersos), fet que ens permet utilitzar la mitjana amb força fiabilitat. En canvi les desviacions no ens serveixen de gaire degut als valors tant petits que hem obtingut.

Veiem com queda mapejada la classe pell en l'espai HSV:

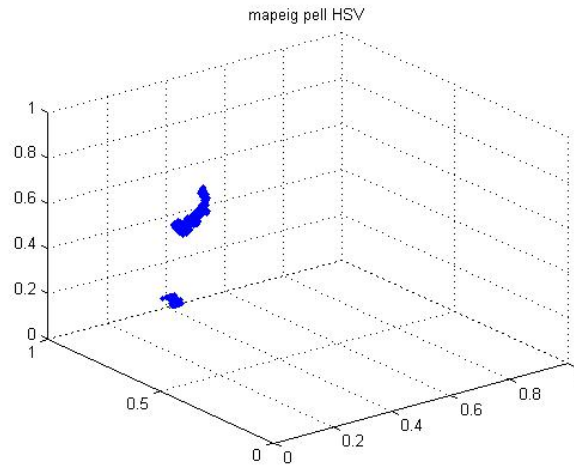


Figura 3.19: Mapeig dels píxels de les mostres de pell en l'espai HSV.

Ara doncs cal binaritzar les imatge partint de la mitjana de cada component com a característica. Analitzant cada píxel i mirant a quina distància euclidiana es troba de la mitjana de la classe pell podem dir si el considerem o no com a píxel de pell. Fa falta un llindar per diferenciar la pell de la no-pell, que podem trobar de forma experimental.

Però amb les petites mostres de pell que hem utilitzat per extreure alguna característica no en fem prou. Necessitem moltes mostres de pell de les imatges de cada conjunt de proves per poder tenir un algorisme robust. Per això veiem la necessitat d'utilitzar les bases de dades dels conjunts d'imatges. Per cada imatge de cada conjunt tindrem un seguit de mostres de pells (de diferents tonalitats), i així podem obtenir una bona caracterització de la pell, i en conseqüència una millor binarització de la imatge.

En l'entrenament de la classe pell no agafarem totes les imatges del conjunt, sinó que provarem amb la meitat (les seleccionarem aleatòriament), i després binaritzarem la imatge amb un llindar que ajustarem experimentalment. Primer podem observar algunes imatges sense nevus per veure si realment és capaç de detectar la pell en aquest espai de color:

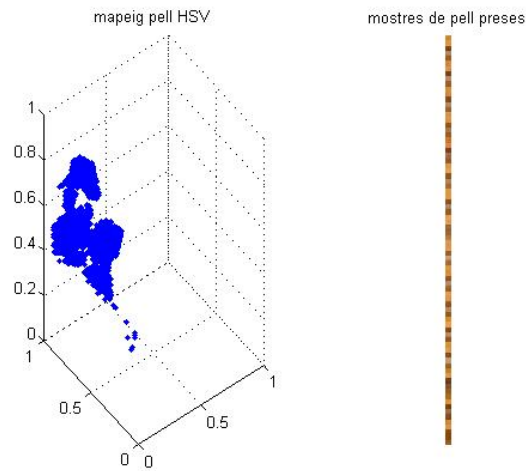


Figura 3.20: Mapeig de la pell amb entrenament fet a partir del mètode *Kfold Crossvalidation* ($k = 2$).




Figura 3.21: Imatge binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.2 ($[0,1]$).

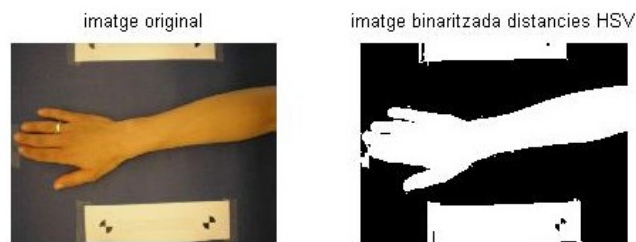


Figura 3.22: Imatge binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.5 ($[0,1]$).




Figura 3.23: Imatge binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.35 ([0,1]).

Sembla que aquest últim llindar és bo, per acabar de veure-ho provem alguna imatge amb algun nevus:



Figura 3.24: Imatge binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.35 ([0,1]).

Sembla que es tracta d'un mètode molt fiable en la detecció de pell, i bastant bo en la detecció de nevus (potser és més bo en aquest aspecte el mètode de binarització local). En definitiva, que disposem d'un altre forma de binaritzar a tenir en compte.

Ara també repetirem les mateixes proves però per a l'espai de color LAB (CIELAB). Aprofitarem la base de dades de cada conjunt per a realitzar les mateixes proves i veure si a l'igual que en l'espai HSV, podem tenir en compte aquest espai per a la segmentació supervisada.

Es tracta d'un espai de color perceptualment uniforme, que significa que un petit canvi en els valors de les components donen lloc a un altre color similar al primer. Per tant estem parlant d'un espai amb moltes similituds a la percepció humana. La transformació de RGB a LAB és complexa, i això comporta que es requereixin més bits per codificar en LAB. Va ser el primer espai de color utilitzat en segmentació de pell [1].

Com també hem fet anteriorment veurem com es comporten les mitjanes i les desviacions estàndard de les components de les mostres convertides a LAB, i com queda el mapeig de la classe pell en aquest espai:

	Mitjana L	Mitjana A	Mitjana B	Desviació L	Desviació A	Desviació B
Mostra 1	191.8	147.4	152.2	1.581	0.647	0.661
Mostra 2	146.1	152	150.9	2.659	0.835	0.872
Mostra 3	76.8	141.3	144	1.098	0.538	1.090
Mostra 4	152.8	150	149.8	4.219	0.701	0.612
Mostra 5	171.1	148.1	150	5.055	1.385	0.328

Taula 3.3: Mitjana i desviació estàndard de les components de les mostres en l'espai de color LAB $([0,1])$.

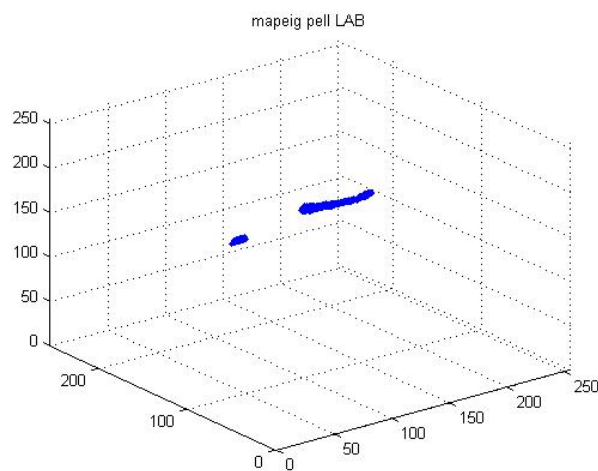


Figura 3.25: Mapeig dels píxels de les mostres de pell en l'espai LAB.

Tornarem a caracteritzar la pell a partir de la mitjana. Comparant cada píxel amb la mitjana de la classe pell obtindrem una distància, amb la qual podrem decidir si es tracta de pell o no amb un llindar experimental. Al tractar-se d'un mètode semblant al de l'espai HSV molta feina ja està feta, i per tant tindrem resultats més ràpidament.

Tornarem a seleccionar aleatòriament la meitat del conjunt de proves per entrenar la classe pell (*Kfold Crossvalidation*), i anirem obtenint les imatges binaritzades. L'espai de color LAB té un rang de valors en les seves components entre 0 i 255, en canvi l'espai HSV té els valors entre 0 i 1. Per poder comparar aquests dos espais amb més facilitat normalitzarem les imatges convertides a LAB entre 0 i 1 en els algorismes.

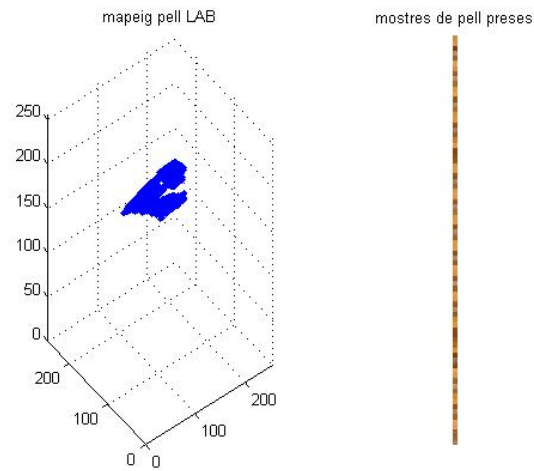


Figura 3.26: Mapeig de la pell amb entrenament fet a partir del mètode *Kfold Crossvalidation* ($k = 2$).




Figura 3.27: Imatge binaritzada mitjançant distàncies en l'espai LAB amb distància màxima per a píxels de pell respecte la mitjana de 0.35 ($[0,1]$).




Figura 3.28: Imatge binaritzada mitjançant distàncies en l'espai LAB amb distància màxima per a píxels de pell respecte la mitjana de 0.1 ($[0,1]$).




Figura 3.29: Imatge binaritzada mitjançant distàncies en l'espai LAB amb distància màxima per a píxels de pell respecte la mitjana de 0.2 ([0,1]).

Provem també una imatge amb nevus per veure com actua l'algorisme:




Figura 3.30: Imatge binaritzada mitjançant distàncies en l'espai LAB amb distància màxima per a píxels de pell respecte la mitjana de 0.28 ([0,1]).

Els resultats són molt similars als obtinguts amb l'altre espai de color. Es tracta doncs, d'un bon algorisme de detecció de pell.

3.1.1.4 LA SEGMENTACIÓ SUPERVISADA A PARTIR DE PROBABILITATS

Continuant amb les segmentacions supervisades hem decidit provar una darrera estratègia. Aquest cop utilitzarem probabilitats bayesianes per dividir els píxels d'una imatge en pell i no-pell [4] [5]. A partir d'un seguit de característiques (en principi agafarem les mitjanes de cada component, vistos els bons resultats obtinguts en els mètodes anteriors) podrem ser capaços de modelar uns píxels de pell perquè es comportin com una distribució normal. També modelarem els píxels de no-pell seguint una distribució gaussiana. Per obtenir aquestes distribucions aplicarem la següent fórmula:

$$\mathcal{N}(x|\mu, \Sigma) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma|^{\frac{1}{2}}} \exp\left(-\frac{1}{2}(x - \mu)^T \Sigma^{-1} (x - \mu)\right)$$

On:

- x correspon al píxel del qual es vol obtenir la probabilitat (les seves components)
- μ és el vector de característiques (les mitjanes de cada component en el nostre cas)
- Σ és la matriu de covariàncies de les diferents components
- n és la mida del vector de característiques

Un cop tenim les classes pell i no-pell modelades, podem trobar la probabilitat de que un píxel sigui pell així:

$$p(\text{pell}|x) = \frac{p(x|\text{pell})}{p(x|\text{pell}) + p(x|\text{no - pell})}$$

Això significa que haurem d'aplicar la primera fórmula per a les dues classes diferents i després utilitzar la segona per saber quina probabilitat té un píxel de ser pell. Amb un llindar binaritzarem la imatge (per exemple que consideri pell a tots aquells píxels amb probabilitat major que 0.5). De moment començarem les proves en l'espai de color RGB, i més endavant ja analitzarem si hi ha cap altre espai que ens funcioni millor.

Abans de passar als experiments importants farem una petita prova amb un conjunt d'imatges on apareixen diverses persones (tal com [4]) per demostrar que el mètode implementat funciona correctament. Agafarem unes petites mostres de pell de les cares i les mans de les persones que apareixen en una de les imatges així com de fons. Partim de la següent imatge, de la que hem agafat manualment tots els fragments de pell que han sigut possibles:



Figura 3.31: Imatge de prova per a l'entrenament de la pell per a la segmentació a partir de probabilitats i mostres de pell agafades per a l'entrenament.

Podem veure ara la probabilitat de que un píxel pertanyi a les classes pell i no pell:




Figura 3.32: Probabilitat que un píxel pertanyi a la classe pell.




Figura 3.33: Probabilitat que un píxel pertanyi a la classe no-pell.

També veiem la probabilitat de que un píxel sigui pell (després d'aplicar la segona fórmula):

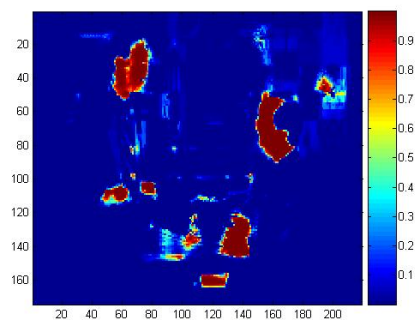


Figura 3.34: Probabilitat que un píxel sigui pell.

En aquest darrer cas les probabilitats ja han pres valors coherents, ja que han quedat normalitzats entre 0 i 1. A més també podem apreciar com les regions on hi

ha pell han adquirit una probabilitat més alta. Per últim podem binaritzar la imatge amb un llindar igual a 0.5:




Figura 3.35: Imatge binaritzada a partir de probabilitats amb llindar 0.5.

Podem afirmar que els resultats obtinguts han sigut molt satisfactoris, i la segmentació de la pell ha estat correcta. Provem alguna altra imatge per veure si el mètode funciona bé:




Figura 3.36: Imatge binaritzada a partir de probabilitats amb llindar 0.5.

Hem obtingut una bona detecció de la pell. Ara ja haurem de ser capaços de binaritzar les imatges dels diferents conjunts de prova. Utilitzarem també les bases de dades de cada conjunt per a l'entrenament de la pell, i haurem d'obtenir també algunes regions de fons. Abans de res mirem quin espai de color dóna millors resultats.

Comencem veient algunes proves en l'espai RGB:




Figura 3.37: Imatge binaritzada a partir de probabilitats en l'espai de color RGB amb llindar 0.5.




Figura 3.38: Imatge binaritzada a partir de probabilitats en l'espai de color RGB amb llindar 0.5.

En l'espai HSV:




Figura 3.39: Imatge binaritzada a partir de probabilitats en l'espai de color HSV amb llindar 0.5.




Figura 3.40: Imatge binaritzada a partir de probabilitats en l'espai de color HSV amb llindar 0.5.

L'espai LAB ha donat problemes en alguna de les seves components a l'hora de fer el determinant (la matriu de covariàncies és singular, degut a que alguna de les seves components és combinació lineal d'alguna altra, i per tant el determinant és 0). Provem també com queda la imatge utilitzant les components dels espais RGB i HSV (de fet la component V provoca que la matriu de covariàncies sigui singular, i per tant no l'agafem):




Figura 3.41: Imatge binaritzada a partir de probabilitats amb les components R, G, B, H i S amb llindar 0.5.



Figura 3.42: Imatge binaritzada a partir de probabilitats amb les components R, G, B, H i S amb llindar 0.5.

Després d'analitzar detingudament els resultats, les imatges que han quedat

més ben binaritzades corresponen a l'espai RGB, ja que en els altres espais apareixen píxels negres on realment hi ha pell. En aquest punt també ens adonem que potser aquest mètode no serà capaç de binaritzar tal i com volíem els nevus, ja que zones ombrejades de pell que potser tenen un color semblant a aquests han quedat correctament binaritzats. Així doncs, aquest mètode el podem utilitzar més aviat com a màscara per a delimitar la zona de pell de les imatges i aplicar algun dels altres algorismes com a mètode de detecció.

Provem aquesta segmentació amb algunes imatges:




Figura 3.43: Imatge binaritzada a partir de probabilitats amb en l'espai de color RGB i amb llindar 0.5.




Figura 3.44: Imatge binaritzada a partir de probabilitats amb en l'espai de color RGB i amb llindar 0.5.



Figura 3.45: Imatge binaritzada a partir de probabilitats amb en l'espai de color RGB i amb llindar 0.5.

Hem obtingut unes imatges binaritzades tal i com les esperàvem. Tal i com havíem previst aquest mètode no ens serà gaire útil en la detecció dels nevus, però possiblement és el millor que hem aconseguit en la classificació de la pell.

3.1.2 RESULTATS

Tot seguit mostrarem alguns resultats dels diferents mètodes de binarització de les imatges. Provarem imatges de tots els conjunts en tots els algorismes: primer el de binarització local, després el de distàncies en l'espai HSV, seguirem amb el de distàncies en l'espai LAB i acabarem amb el basat en probabilitats (repetirem aquest ordre d'experiments en tots els conjunts). Finalment també veurem alguns mosaics amb el resultat dels diferents mètodes d'entrenament en la segmentació supervisada. A partir d'aquests experiments intentarem extreure conclusions del funcionament dels mètodes.

Comencem amb el primer conjunt de dades reals. Provem de binaritzar una imatge amb tots els mètodes. Els paràmetres són els comentats en els apartats anteriors:




Figura 3.46: Imatge d'exemple del primer conjunt de dades reals binaritzada localment amb mitjana com a llindar i (finestres amb histogrames no uniformes), mitjana menys 15 (finestres amb histogrames uniformes) i finestra de 10x10 ([0,255]).




Figura 3.47: Imatge d'exemple del primer conjunt de dades reals binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.32 ([0,1]).




Figura 3.48: Imatge d'exemple del primer conjunt de dades reals binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.28 ([0,1]).



Figura 3.49: Imatge d'exemple del primer conjunt de dades reals binaritzada a partir de probabilitats amb en l'espai de color RGB i amb llindar 0.5.

Aquest conjunt ens serveix per comprovar el funcionament dels mètodes, degut a la gran quantitat de nevus que té el pacient i la seva disposició molt concentrada. Hem obtingut la detecció de la majoria de nevus en la binarització local, uns quants en els mètodes supervisats a partir de la distància, i una bona detecció de la pell en el mètode supervisat a partir de les probabilitats.

Passem al segon conjunt de dades reals. En aquest cas disposem d'una regió més petita de pell però capturada a menys distància. La mida de les imatges d'aquest conjunt és la mateixa que en l'anterior, i com que de moment els paràmetres no tenen res a veure amb la distància de captura, només hem hagut de reajustar mínimament els paràmetres per obtenir bons resultats.




Figura 3.50: Imatge d'exemple del segon conjunt de dades reals binaritzada localment amb mitjana com a llindar i (finestres amb histogrames no uniformes), mitjana menys 20 (finestres amb histogrames uniformes) i finestra de 10x10 ([0,255]).




Figura 3.51: Imatge d'exemple del segon conjunt de dades reals binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.35 ([0,1]).




Figura 3.52: Imatge d'exemple del segon conjunt de dades reals binaritzada mitjançant distàncies en l'espai LAB amb distància màxima per a píxels de pell respecte la mitjana de 0.2 ([0,1]).




Figura 3.53: Imatge d'exemple del segon conjunt de dades reals binaritzada a partir de probabilitats amb en l'espai de color RGB i amb llindar 0.5.

En aquest conjunt els mètodes de distàncies no funcionen tal i com esperàvem. Amb l'espai de color HSV no realitza la detecció de cap nevus, mentre que amb l'espai LAB apareixen falsos positius i falsos negatius. Els altres dos mètodes funcionen correctament.

Ara realitzarem proves amb el tercer conjunt de dades reals. En aquest cas si que haurem de canviar notablement algun paràmetre degut a la diferència entre les mides de les imatges (2112x2816 píxels respecte els 480x640 dels altres dos conjunts). La mida de la finestra en la binarització local la multipliquem per quatre (que és més o menys la relació entre els conjunts), mentre que els altres paràmetres en principi només necessiten petits ajustaments. Al ser imatges de diferents mides però que contenen zones de pell semblants la seva resolució també és diferent (passem d'1.6 píxels per mil·límetre del conjunt anterior als com a mínim 9.6 píxels per mil·límetre del conjunt actual).




Figura 3.54: Imatge d'exemple del tercer conjunt de dades reals binaritzada localment amb mitjana com a llindar i (finestres amb histogrames no uniformes), mitjana menys 20 (finestres amb histogrames uniformes) i finestra de 10x10 ([0,255]).




Figura 3.55: Imatge d'exemple del tercer conjunt de dades reals binaritzada mitjançant distàncies en l'espai HSV amb distància màxima per a píxels de pell respecte la mitjana de 0.21 ([0,1]).




Figura 3.56: Imatge d'exemple del tercer conjunt de dades reals binaritzada mitjançant distàncies en l'espai LAB amb distància màxima per a píxels de pell respecte la mitjana de 0.2 ([0,1]).




Figura 3.57: Imatge d'exemple del tercer conjunt de dades reals binaritzada a partir de probabilitats amb en l'espai de color RGB i amb llindar 0.5.

Tal i com ha passat en el conjunt anterior, els mètodes supervisats basats en la distància no ens aporten els resultats que esperàvem, ja que en aquest cas no detecten tots els nevus i dels que sí que ho fa, només en detecta la part central (redueix la seva àrea real). Si fem més restrictiu el llindar de pertinença a la classe pell llavors obtindrem molts més falsos positius. A més en l'espai de color LAB

apareixen zones considerades com a pell en el fons de la imatge. També cal que destaquem que els altres dos mètodes també han funcionat segons el previst, i que la mida i la resolució de les imatges no altera els resultats dels algorismes. El que sí que s'ha vist incrementat considerablement és el temps d'execució de l'algorisme, degut a que ha d'explorar un nombre molt més grans de píxels. Pel què fa als mètodes d'entrenament podem constatar que els dos actuen correctament.

Per acabar l'apartat d'experiments, com a exemple per veure els resultats de l'entrenament (veurem els experiments units en mosaics), treballarem sobre les imatges del segon conjunt de dades reals. Aplicarem sobre el conjunt els diferents algorismes de segmentació supervisada amb l'entrenament prèviament realitzat amb els dos mètodes comentats.

Observem els resultats de la segmentació a partir de probabilitats en la figura 3.58, els de segmentació a partir de distàncies en els les figures següents, en l'espai HSV en la figura 3.59 i en l'espai LAB en la figura 3.60.

Veiem en la figura 3.61 com han quedat les imatges binaritzades del segon conjunt de dades reals amb aquest tipus d'entrenament en el mètode de segmentació supervisada mitjançant probabilitats.




Figura 3.58: Resultats del mètode de segmentació supervisada a partir de probabilitats utilitzant el mètode *Kfold Crossvalidation* ($k = 2$) en l'entrenament.




Figura 3.59: Resultats del mètode de segmentació supervisada a partir de distàncies en l'espai de color HSV utilitzant el mètode *Kfold Crossvalidation* ($k = 2$) en l'entrenament.




Figura 3.60: Resultats del mètode de segmentació supervisada a partir de distàncies en l'espai de color LAB utilitzant el mètode *Kfold Crossvalidation* ($k = 2$) en l'entrenament.




Figura 3.61: Resultats del mètode de segmentació supervisada a partir de probabilitats utilitzant el mètode *Leave One Out* en l'entrenament.

3.1.3 LA COMPOSICIÓ DE MÈTODES

Disposem de quatre formes diferents de binaritzar una imatge de tal manera que quedi destacada la pell dels nevus i del fons. Cada mètode per separat funciona bastant bé i en alguns casos els resultats són complementaris (és a dir, on un mètode no funciona del tot bé, l'altre sí detecta). De manera que la hipòtesi de què partim és la de cercar una estratègia per unir els mètodes, amb la finalitat de millorar els resultats. Veiem un parell d'exemples dels diferents mètodes desenvolupats:



Figura 3.62: Imatge original que serà binaritzada amb els diferents mètodes.

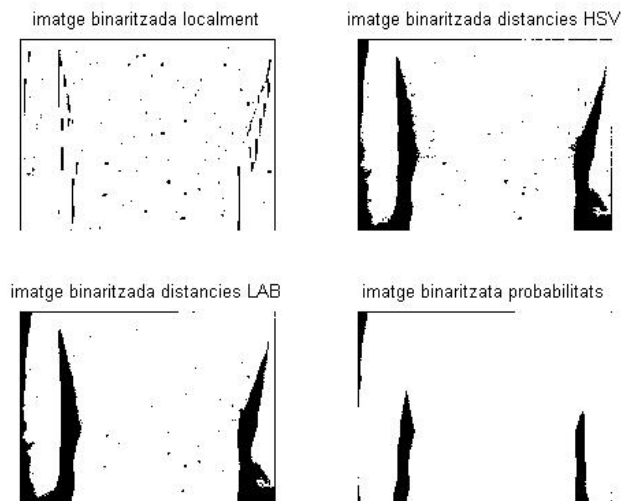


Figura 3.63: Imatge binaritzada amb tots els mètodes.



Figura 3.64: Imatge original que serà binaritzada amb els diferents mètodes.

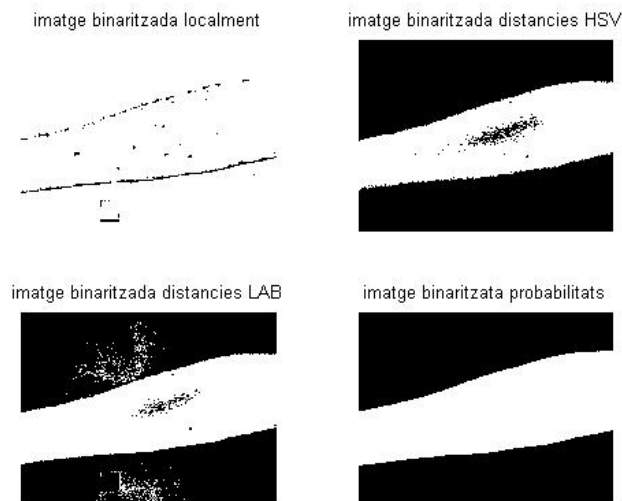


Figura 3.65: Imatge binaritzada amb tots els mètodes.

Vistos tots els resultats podem veure que si fem la intersecció entre tots els mètodes la zona de fons quedarà negra pel rol de màscara que realitza la segmentació per probabilitats (i en la seva mesura els mètodes de distàncies). A més també ens adonem de que els dos mètodes de distàncies són bastant complementaris, i que per tant proporcionaran modificacions semblants. Per això provarem de compondre-los així:

$$im_bin = im_bin_local \& im_bin_prob \& (im_bin_dist_hsv | im_bin_dist_lab)$$

Els resultats obtinguts són els següents:



Figura 3.66: Imatge binaritzada amb els quatre diferents mètodes.




Figura 3.67: Imatge binaritzada amb els quatre diferents mètodes.

Mitjançant aquesta forma d'unir els mètodes ens trobem amb què els de distàncies poden afegir zones ombrejades a la imatge binaritzada resultant, fet que provoca l'aparició de falsos positius. Podríem retocar el llindar d'aquests dos algorismes en els conjunts d'imatges que ho requerissin, però això podria comportar pèrdua de nevus. Per això potser el millor és només realitzar una composició de la binarització local i de la per probabilitats:

$$im_bin = im_bin_local \& im_bin_prob$$

Els nous resultats són:



Figura 3.68: Imatge binaritzada amb els la composició de la binarització local i de la binarització per probabilitats.




Figura 3.69: Imatge binaritzada amb els la composició de la binarització local i de la binarització per probabilitats.

Els nous resultats han millorat els anteriors. Tot i això els contorns de la imatge queden irregulars i afavoreixen l'aparició de falsos positius. Per solucionar-ho hem decidit provar d'erosionar la imatge binaritzada per probabilitats per tal de polir aquest contorns. Aquesta solució però, pot comportar que, si en aquest mètode hi ha algun píxel negre a la zona de pell, es veurà augmentat el seu tamany. Per això un altre operació que podríem fer prèviament a l'eroide és un dilate (que ve a ser una operació morfològica d'open [19]), però amb un element estructural de tamany més petit al de l'eroide. Així aconseguim eliminar aquests pocs píxels de soroll que podríem trobar en el darrer mètode desenvolupat, i no veure reduït l'efecte de l'eroide.




Figura 3.70: Imatge binaritzada amb la composició de la binarització local i de la binarització per probabilitats i amb els contorns corregits mitjançant un eroide.




Figura 3.71: Imatge binaritzada amb la composició de la binarització local i de la binarització per probabilitats i amb els contorns corregits mitjançant un erode.

Finalment hem aconseguït una bona binarització amb un algorisme que funciona per a totes les imatges dels conjunts d'entrenament i test, i que les deixa a punt per a la segmentació i posterior detecció de nevus. És normal que quedin alguns falsos positius encara, que s'hauran d'analitzar en les següents etapes.

3.2 L'ETIQUETATGE DELS NEVUS

El següent pas, un cop tenim la imatge binaritzada és realitzar un etiquetatge dels nevus que han quedat de color negre juntament amb el fons, en contrast amb la pell, que ha quedat de color blanc. Ara doncs, cal que apliquem un filtre per eliminar els falsos positius que hi ha en la imatge, i per això procedirem aplicant un algorisme de segmentació de la imatge per tal de dividir-la en diferents regions (intentant així que cada nevus sigui una petita regió de la imatge). Hem decidit segmentar la imatge a partir de l'algorisme CCL (*Connected Component Labelling*) per la seva eficiència. Aquest algorisme considera els píxels negres com a fons, i els blancs com a possibles regions a segmentar. L'algorisme etiqueta tltls els píxels adjacents que considera que pertanyen a una mateixa regió.




Figura 3.72: Funcionament teòric de l'algorisme CCL.

Així doncs, cal que prèviament realitzem el complement de la imatge bina-

ritzada per adequar-nos al CCL. A més, de cada regió que trobem n'extraurem un seguit de característiques (l'àrea en píxels, la distància dels seus eixos, els píxels que la conformen, ...) per així poder considerar-la com a nevus o bé rebutjar-la. Mitjançant aquestes característiques també podrem emmarcar la regió dins un rectangle (*bounding box*) que el faci fàcilment visible en cas de que l'hàgim considerat com a nevus. Primer de tot anem a veure quines regions apareixen en les imatges sense eliminar cap falsa detecció:




Figura 3.73: Imatge amb les regions detectades destacades.




Figura 3.74: Imatge amb les regions detectades destacades.

Veiem que hi ha alguns falsos positius que cal no considerar: zones de fons, zones ombrejades, entre d'altres. La primera premissa que tindrem en compte a l'hora d'eliminar falses deteccions és la mida de la regió. No considerarem com a nevus aquelles que siguin excessivament grans com per poder ser un nevus en la imatge en qüestió, ni aquelles que siguin extremadament petites, ja que si realment són nevus, la seva mida fa que tinguin un risc pràcticament nul (segons els dermatòlegs, un nevus sol tenir-se en consideració quan supera el mil·límetre de

diàmetre). A més les regions formades per escassos píxels molt probablement no es veuen ni a simple vista, i es fa difícil poder-les emmarcar. La mida d'una regió ens vindrà donada per la seva àrea (número de píxels):



Figura 3.75: Imatge amb les regions detectades destacades amb un filtratge dels falsos positius.




Figura 3.76: Imatge amb les regions detectades destacades amb un filtratge dels falsos positius.

També podem obtenir la desviació estàndard del nivell de gris dels píxels que hi ha dintre el *boundig box* d'una regió, i tractar-la en conseqüència, és a dir, si es tracta d'un valor inferior a un llindar experimental voldrà dir que les tonalitats de la regió són semblants i per tant que estarem tractant amb pell, o sigui, un fals positiu; per contra si el valor té una desviació que supera el llindar, voldrà dir que ens trobem amb un veritable nevus.



Figura 3.77: Imatge amb les regions detectades destacades amb un segon filtratge dels falsos positius.




Figura 3.78: Imatge amb les regions detectades destacades amb un segon filtratge dels falsos positius.

Amb totes aquestes condicions, la detecció ha estat satisfactòria. Poden quedar en la imatge alguns falsos positius, però, que en principi no han d'afectar als següents algorismes de comparació. Ja tenim la primera etapa de l'aplicació llesta, i per tant podem passar a la segona. Les imatges de sortida d'aquesta part de detecció seran l'entrada de la següent etapa de comparació.

Capítol 4

EL COMPARADOR

Arribats a aquest punt, disposem de la detecció dels nevus de les imatges. En aquesta part de l'aplicació pretenem implementar una eina que sigui capaç de fer comparacions entre imatges d'un mateix pacient d'exploracions fetes en èpoques diferents, per tal de poder veure com han anat evolucionant totes les pigues que se li havien detectat en la primera exploració. Cal doncs crear una eina capaç d'emmagatzemar un seguit d'informació de tots els nevus detectats (color, forma, àrea en píxels, posició, etc) en una primera imatge d'una zona concreta de la pell per poder analitzar els possibles canvis que s'hi hagin pogut produir.

A més de tota aquesta informació necessària, cal que sapiguem la posició relativa de totes les regions d'interès detectades en diferents imatges d'un mateix subjecte d'estudi, ja que poden haver sofert modificacions, ja sigui per canvis en el seu aspecte físic (el pacient pot estar més gras, més prim, més morè, pot haver crescut, ...) o bé per canvis en la captura de la imatge (diferent màquina, diferent resolució, diferent posició dels implicats, diferent orientació, diferent il·luminació, ...). És molt difícil disposar de dues fotografies de temps diferents, que s'hagin pres en les mateixes condicions. Per tant caldrà que intentem solucionar i/o tractar aquests problemes per poder garantir una comparació amb un mínim de qualitat. En principi ja disposem d'un seguit d'informació de cada detecció bé guardada en taules, o bé implícita en la imatge original.

Ens interessaran veure tant els nevus nous que hagin aparegut com els antics que hagin desaparegut. El comparador pot millorar si també tenim en compte els que han augmentat o disminuït la seva mida o bé els que han canviat de forma o els que han vist modificat el seu color, entre d'altres canvis.

4.1 LA CORRESPONDÈNCIA ENTRE NEVUS

Abans de res, cal saber la correspondència entre els nevus de dues imatges, és a dir, saber identificar cada nevu d'una imatge presa cronològicament primer, en una segona imatge presa més tard. Hem de ser capaços de fer-ho de la forma més fiable possible, ja que en aquest punt recau tota la importància del comparador de

nevus.

4.1.1 MÈTODES

Per això proposem dos mètodes que exposem tot seguit: el primer, i al que dedicarem més esforços, basat en una cerca exhaustiva (comparació tots amb tots); el segon, sobre el que en principi només volem realitzar simples experiments, basat en registre (més endavant explicarem més detalladament aquesta tècnica).

4.1.1.1 LA CERCA EXHAUSTIVA

Aquest mètode pretén generar una taula de correspondències entre els nevus de les dues imatges tot comparant cada nevus amb la resta. En aquesta comparació es tindran en compte la posició relativa d'un nevus de la primera imatge respecte la segona (distàncies, orientacions), i la diferència entre les seves àrees relatives. A partir d'una llista amb tots els nevus d'una imatge determinada, podrem construir una taula on a partir de la distància euclidiana de les característiques entre tots els nevus podem establir-ne un grau de similitud. A la vegada aquesta taula també ens mostra les adjacències del graf, tot i que al tractar-se d'un graf complet, les úniques caselles amb valor 0 seran les que un nevus estigui relacionat amb si mateix.

Tot seguit hem de trobar una sèrie de punts de la primera imatge que amb seguretat es podran identificar fàcilment en la segona, per exemple les pigues amb l'àrea més gran (ja que amb una probabilitat molt alta, aquests nevus també seran en la segona imatge i també tindran una mida considerable). Si a la segona imatge hi obrim una finestra de cerca de mida predeterminada (una distància relativament curta) en una posició ¹ on en la primera imatge hi ha el centre de masses d'una piga gran, quasi amb tota seguretat hi haurà un altre nevus gran corresponent al primer. A partir d'això podem construir una taula de correspondències entre les pigues més representatives per tal de tenir-les localitzades.

A continuació, busquem per cada nevus dels que no han estat considerats com a grans quin és el representatiu ² que té més a la vora (per fer l'algorisme més robust podem relacionar cada nevus no gran amb més d'un de gran). Creem doncs, un lligam de distància entre tots els nevus de cada imatge. Seguidament guardem una llista amb les pigues petites que són veïnes més pròximes de cada piga gran.

Ara ja podem intentar identificar tots els nevus de la primera imatge en la segona. Agafant cada nevus representatiu i buscant pel seu voltant (obrint també una finestra on hi apareguin la relació de nevus que pegen d'ell), podem buscar la correspondència entre pigues petites que hi ha d'una imatge a l'altra, a partir d'un seguit d'informació com pot ser la distància, la orientació, la mida, etc. No cal que aquests valors es corresponguin exactament, n'hi ha prou de que siguin més o

¹Tenim en compte la posició dels nevus en la imatge per cercar localment i no haver de fer-ho per tota la imatge, fent el codi més eficient en temps

²Entenem per nevus representatiu aquells nevus que amb quasi tota seguretat estaran presents en les dues imatges. Un exemple poden ser els que tenen una àrea més gran.

menys semblants. Tot seguit podrem completar la taula d'equivalències de nevus amb els petits. En cas de que alguna piga de la primera imatge no l'haguem trobat en la segona o viceversa, en la taula hi quedarà constància de que no existeix correspondència mitjançant algun tipus de valor o amb un símbol. Pot estar bé també crear un valor estadístic que ens digui la semblança que hi ha entre les dues imatges, o bé el percentatge de nevus equivalents que ha trobat, ...

Per assegurar-nos de que l'algorisme funciona correctament, no provarem de realitzar directament la comparació de nevus amb imatges dels conjunts de proves (amb la detecció de nevus ja acabada), ja que podria ser complicat. Així doncs, començarem fent proves amb unes imatges sintètiques, fetes amb un editor de dibuix (Paint, en el nostre cas). La primera parella està formada per dues imatges en què els nevus han sofert petites translacions. En la segona parella els nevus a banda de les translacions també han sofert rotacions, i a més han aparegut i desaparegut nevus, i en alguns casos l'àrea d'aquests s'ha modificat.




Figura 4.1: Primera parella d'imatges sintètiques (cas senzill) per realitzar proves amb el mètode de comparació de cerca exhaustiva.




Figura 4.2: Segona parella d'imatges sintètiques (cas complex) per realitzar proves amb el mètode de comparació de cerca exhaustiva.

Es tracta de dues parelles d'imatges que representen una part d'un cos amb diversos nevus. Són en blanc i negre per tal de simular que han estat binaritzades. El primer que hem de fer sobre cadascuna d'aquestes dues imatges és aplicar-los l'algorisme de detecció de nevus, per poder procedir amb la comparació.

En l'algorisme que hem dissenyat existeixen un seguit de paràmetres que cal ajustar: el criteri que diu si un nevus és representatiu (gran), la mida de la finestra que s'obre en la segona imatge on en la primera hi ha un nevus, el llindar sobre la diferència de mida màxima que pot tenir un nevus gran i la correspondència, el nivell de semblança entre dos nevus (que pot ser una distància euclidiana amb un seguit de característiques dels dos nevus que es volen comparar), ... Tots aquests paràmetres els provarem i analitzarem en l'apartat de resultats.

Necessitem algun tipus d'etiqueta per poder referir-nos als diferents nevus. Per exemple podem enumerar-los:




Figura 4.3: Enumeració dels nevus detectats de la primera imatge sintètica del cas complex.




Figura 4.4: Enumeració dels nevus detectats de la segona imatge sintètica del cas complex.

Hem pensat que un nevus és representatiu si supera un llindar que s'ha obtingut a partir de dividir per dos la diferència entre l'àrea del nevus més gran i la mediana de totes les àrees. O bé també podem agafar el 20% dels nevus que té una àrea més gran.

Provem la comparació que realitza el mètode de cerca exhaustiva en el cas sintètic senzill.




Figura 4.5: Primera imatge sintètica (cas senzill) amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.




Figura 4.6: Segona imatge sintètica (cas senzill) amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.

Els resultats que hem pogut observar proporcionen una correcta correspondència entre tots els nevus. Anem a provar el cas complex (analitzant una mica més detingudament el funcionament de l'algorisme). En l'exemple de la figura 4.3 hem trobat tres nevus representatius en la primera imatge, que són el 4, el 12 i el 15 (utilitzant el primer criteri de selecció de nevus representatius). A cadascun d'aquests el busquem en l'altra imatge. Ho fem obrint una finestra (per exemple de 50x50 píxels) en la segona imatge en el píxel on es troba el centroid del nevus en la primera, i comparant la mida del nevus en qüestió amb la de tots els nevus candidats que es troben dins la finestra. La cerca dels nevus grans funciona bé amb el llinar escollit i dona la següent taula de correspondències provisionals:

Nevus Representatius (primera imatge)	Correspondència (segona imatge)
4	4
12	14
15	17

Taula 4.1: Nevus representatius trobats en la primera imatge i la correspondència trobada en la segona.

Tot seguit, en les dues imatges, assignem cada nevus no gran al gran més proper, ja que fàcilment podrem comparar la distància que tenen aquests dos nevus en l'altra imatge, i reduir el número de nevus a explorar considerablement (només caldrà que fem comparacions amb els nevus que estan relacionats amb el mateix representatiu en les dues imatges).

Ara ja podrem anar a buscar cada nevus petit d'una imatge en l'altra. Només ens fixem en els nevus que estan relacionats al mateix representatiu, i a partir d'això, establim un criteri de semblança: podem utilitzar l'àrea i la distància respecte el nevus gran, i extreure'n un estadístic de similitud. El nevus que tingui aquest paràmetre més petit serà molt probablement el corresponent. Les correspondències que hem trobat amb aquest exemple amb les imatges sintètiques són les següents:

Nevus Representatius (primera imatge)	Correspondència (segona imatge)
1	1
2	2
3	3
5	5
6	-1
7	8
8	9
9	10
10	11
11	12
13	15
14	16
16	-1
-1	6
-1	7
-1	13

Taula 4.2: Correspondències trobades entre les dues imatges sintètiques (cas complex) utilitzant la mida i la distància al nevus gran al que estan relacionats en el criteri de semblança.

Ens trobem que hi ha tres correspondències errònies: (6 i -1), (7 i 8) i (-1 i 7) (-1 significa que el nevus no apareix en la imatge). Analitzant el que ha passat ens trobem en què aquests errors són deguts a dos problemes. El primer (és el que ens diu que el nevus 6 de la primera imatge ha desaparegut en la segona) confon

dos nevus que tenen una mida i una distància respecte al nevus representatiu molt semblants. El podem solucionar fàcilment afegint la orientació respecte el representatiu com a nova característica del paràmetre semblança. El segon problema (que relaciona el nevus 7 de la primera imatge amb el 8 de la segona) es produeix pel fet de que un nevus petit està a distàncies semblants de més d'un nevus gran, i en una imatge és relacionat amb un i en l'altra amb l'altre. La manera com ho solucionarem és fent una segona iteració de cerca de correspondències en la que només ens fixarem en els que no han estat relacionats fins al moment, i en la que no tindrem en compte el nevus gran amb què està relacionat el nevus amb què estem treballant. Resolent aquest dos problemes també resollem l'error de la correspondència (-1 i 7), ja que ara el nevus 8 de la segona imatge ja no està mal assignat i podem veure realment que només apareix en la segona imatge.

Així les correspondències entre nevus de les dues imatges ja són correctes, i ja podem detectar les primeres modificacions. Veiem enquadrats de color verd els nevus que s'han relacionat amb algun de l'altra imatge, i de color vermell els que no, i que per tant han aparegut o desaparegut en una de les dues imatges.




Figura 4.7: Primera imatge sintètica (cas complex) amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.



Figura 4.8: Segona imatge sintètica (cas complex) amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.

Veiem com amb les dues parelles d'imatges sintètiques l'algorisme de cerca exhaustiva funciona correctament. Anem a veure si també ho fa amb imatges reals. Segurament, per cada conjunt de proves haurem de tenir uns valors diferents pels paràmetres, pel fet que els trobem experimentalment. Comencem amb el segon conjunt de proves, ja que és el que té una distribució de nevus més simple. Provarem un parell d'exemples d'aquest conjunt.




Figura 4.9: Primera imatge de la primera parella d'imatges del segon conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.



Figura 4.10: Segona imatge de la primera parella d'imatges del segon conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.

Observem en aquest senzill exemple com el nevus comú a les dues imatges és correctament emmarcat dins un rectangle verd, mentre que el nou aparegut en la segona imatge és vermell pel fet de no tenir una correspondència en la primera. Val a dir que hem hagut de modificar els paràmetres per obtenir aquests resultats. Anem a provar alguns exemples amb més nevus.



Figura 4.11: Primera imatge de la segona parella d'imatges del segon conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.



Figura 4.12: Segona imatge de la segona parella d'imatges del segon conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.

Anem a provar imatges amb encara més nevus, com les del tercer conjunt d'imatges reals. També provarem l'algorisme de cerca exhaustiva en dues parelles d'imatges. En cas de que es produeixi algun error en la correspondència revisarem l'algorisme afegint-hi tot el que faci falta.




Figura 4.13: Primera imatge de la primera parella d'imatges del tercer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.




Figura 4.14: Segona imatge de la primera parella d'imatges del tercer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.

Ràpidament ens adonem que el nevus etiquetat com a 5 està mal correspost (hauria de ser el 9 de la primera imatge que estigués assignat al 5 de la segona). Això es produeix arran de la petita diferència d'escala que hi ha en les dues imatges, fet que fa que la semblança es vegi modificada per aquesta diferència d'àrees. Creiem que ho podem solucionar treballant amb àrees relatives en comptes d'absolutes. Necessitem una mesura que ens pugui indicar a quina escala estan les dues imatges una respecte l'altra.




Figura 4.15: Primera imatge de la segona parella d'imatges del tercer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.




Figura 4.16: Segona imatge de la segona parella d'imatges del tercer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.

El més senzill que se'ns ha acudit (i que a més ha ofert bons resultats, veure les figures 4.15 i 4.16) ha estat agafar algun patró de referència en les dues imatges. Podem utilitzar la marca que hem utilitzat per calibrar les imatges (l'escala) en les imatges en que hi figuri. En les imatges del conjunt de dades de l'Hospital Clínic, no disposem d'aquesta marca, i ho podem fer a partir de l'àrea de pell de cada imatge.

Finalment anem als pacients reals per veure com actua l'algorisme. Com que cal reajustar els paràmetres i és poc probable que la correspondència es realitzi satisfactòriament a la primera, anirem pas per pas. Treballarem amb imatges del primer conjunt de dades reals. Començarem amb la correspondència entre els nevus grans de la primera imatge respecte la segona. Primer de tot enumerem els nevus de les dues imatges. Veiem en l'exemple del conjunt com el número de nevus detectats no és el mateix, però això és un fet que sabem que es podia produir.




Figura 4.17: Etiquetatge dels nevus de la primera imatge de la parella d'imatges d'exemple del primer conjunt de dades reals.




Figura 4.18: Etiquetatge dels nevus de la segona imatge de la parella d'imatges d'exemple del primer conjunt de dades reals.

Hem agafat com a nevus representatius de la primera imatge el 20% amb àrea més gran.

Nevus Representatius (primera imatge)
4
17
18
30
33
35
40
41
42
48
50
51
75
77
79

Taula 4.3: Nevus grans trobats en la primera imatge de l'exemple del primer conjunt de dades.

Anem a veure tot seguit quina correspondència troba entre aquests nevus i els de la segona imatge:

Nevus Representatius (primera imatge)	Correspondència (segona imatge)	Encert/Error
17	12	✓
18	16	✓
30	49	x
33	41	✓
35	34	✓
40	47	✓
41	49	✓
42	48	✓
48	54	✓
50	58	✓
51	55	✓
75	89	✓
77	96	✓
79	94	x

Taula 4.4: Nevus grans trobats en la primera imatge de l'exemple del primer conjunt de dades, correspondències trobades en la segona imatge, i els encerts i errors que s'han produït.

En aquesta taula no hi figuren aquells nevus dels quals no s'ha trobat correspondència en la segona imatge. Veiem com de catorze nevus que tenim relacionats, dotze ho han estat correctament, mentre que dos no (això comporta que l'encert en la cerca exhaustiva és de moment d'un 85.7%. Per poder tenir un algorisme que ens reconegui tots els nevus que no són grans satisfactòriament necessitem un 100% d'encert. Si mirem de retocar la mida de la finestra no millorem

l'efectivitat de l'algorisme, ja que podem solucionar les correspondències errònies, però llavors n'apareixen altres de falses.

El que podem fer és descartar aquests errors d'alguna manera. Podem intentar descartar els que no segueixen el mateix patró d'orientació que la majoria de correspondències.

Nevus Representatiu (primera imatge)	Correspondència (segona imatge)	Orientació eix X	Orientació eix Y
17	12	40.964	12.091
18	16	36.29	5.552
30	49	-27.453	-37.128
33	41	30.356	-16.51
35	34	51.33	7.827
40	47	44.707	-6.557
41	49	34.725	-17.919
42	48	52.637	1.887
48	54	58.781	5.699
50	58	46.945	-10.213
51	55	56.919	3.421
75	89	57.4	-22.552
77	96	-18.681	43.164
79	94	50.178	-14.84

Taula 4.5: Nevus grans de la primera imatge de l'exemple del primer conjunt de dades, correspondències trobades en la segona imatge i orientació de cada correspondència en els eixos X i Y.

En les correspondències errònies la orientació (diferència entre les coordenades del centroide en els eixos X i Y) té uns valors que són força diferents als altres (sobretot en l'eix X). Per descartar aquests errors agafem la mediana de la orientació (per tenir un valor que representatiu i fiable) en cada eix i mirem si la diferència entre el valor de cada component i les medianes trobades sobrepassa un llindar preestablert. En cas afirmatiu, eliminem el valor erroni. Així la taula de correspondències dels nevus grans queda de la següent forma:

Nevus Representatius (primera imatge)	Correspondència (segona imatge)
17	12
18	16
33	41
35	34
40	47
41	49
42	48
48	54
50	58
51	55
75	89
79	94

Taula 4.6: Nevus grans de la primera imatge de l'exemple del primer conjunt de dades i correspondències trobades en la segona imatge un cop descartades les parelles de nevus que no segueixen el patró d'orientació de correspondències.



Figura 4.19: Primera imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus representatius realitzada a partir del mètode de cerca exhaustiva.



Figura 4.20: Segona imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus representatius realitzada a partir del mètode de cerca exhaustiva.

El número de nevus grans reconeguts en les dues imatges ha disminuït respecte els trobats inicialment en la primera imatge (de quinze a dotze), però l'encert ha augmentat fins a un 100

Tot seguit ja podem passar a tractar tots els nevus restants: els que no han estat considerats com a grans i el que si que ho estat però no els hi hem trobat una correspondència correcta. Recordem que en aquesta part relacionem cada nevus no representatiu a un que si ho és, i seguidament busquem en l'altra imatge quin nevus dels que estan associats al mateix gran de la segona imatge té una major semblança. I en una segona iteració intentem relacionar nevus sense tenir en compte el gran al qual estan assignats.




Figura 4.21: Primera imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.




Figura 4.22: Segona imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva.

El número de correspondències que realitza és bastant gran, però n'hi ha algunes que no són correctes. Per aquest motiu hem decidit canviar la forma d'analitzar la orientació en aquest conjunt de dades. Disposem dels nevus grans ja reconeguts en les dues imatges. Podem extreure la mitjana de la diferència que hi ha entre els dos eixos dels centres de masses dels nevus en les dues imatges. Així sabrem aproximadament quina translació hi ha hagut en la segona exploració i per tant podem intuir on buscar cadascun dels nevus no representatius. D'aquesta for-

ma no caldrà que obrim una finestra tan gran i la fiabilitat del reconeixement serà major. Veiem com queda en l'exemple de mostra del primer conjunt de dades:




Figura 4.23: Primera imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva corregint aproximadament el punt d'obertura de les finestres en la segona imatge a partir de la mitjana de la orientació en els eixos X i Y.




Figura 4.24: Segona imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva corregint aproximadament el punt d'obertura de les finestres en la segona imatge a partir de la mitjana de la orientació en els eixos X i Y.

Una última prova que volem fer en aquest primer conjunt d'imatges és la de relacionar cada nevus no gran amb diversos grans (els tres més pròxims, per ex-

emple). Aquesta modificació farà que l'algorisme sigui més robust pel que fa a la distribució dels nevus en la imatge i per tant aconseguirem que les correspondències siguin més fiables.




Figura 4.25: Primera imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva assignant cada nevus no representatiu als tres representatius més propers.




Figura 4.26: Segona imatge de la parella d'imatges d'exemple del primer conjunt de dades reals amb la comparació dels nevus realitzada a partir del mètode de cerca exhaustiva assignant cada nevus no representatiu als tres representatius més propers.

Arran de la seguretat que ens aporta això podem fer no tan restrictiu el llindar

de semblança, i així intentar associar correctament els nevus que encara no hem sigut capaços d'assignar al seu corresponent.

El resultat final satisfà les nostres expectatives i garanteix que la majoria de nevus de les parelles d'imatges d'aquest darrer conjunt en què hem treballat estiguin ben relacionats en les dues imatges.

4.1.1.2 EL REGISTRE

A banda de la cerca exhaustiva, també hem trobat oportú pensar en algun tipus de tècnica de registre per a la identificació de pigues equivalents entre imatges. El registre [18] consisteix en donades dues imatges, una que considerem amb eixos fixos i l'altra amb eixos mòbils, obtenir un mapejat des del sistema de coordenades de la imatge fixa al sistema de coordenades de la imatge mòbil. Aquest mapejat s'aconsegueix utilitzant un transformador, definit per un conjunt de paràmetres que passen d'un eix de coordenades a l'altre. Si aconseguim trobar un seguit de punts tant en una imatge com en l'altra, podrem veure com ha canviat la segona imatge respecte la primera, intentant trobar la rotació, la translació i el canvi d'escala que s'ha produït.

El registre és un mètode iteratiu que consta de quatre parts:

- La mètrica: mesura el grau de similitud de la imatge fixa i la mòbil en la iteració actual.
- L'interpolador: realitza interpolacions dels punts per tal de que no en quedi cap que no estigui en un punt exacte, evitant així la discontinuïtat en la imatge.
- El transformador: mapeja els punts de la imatge fixa en la imatge mòbil, a partir dels paràmetres que li passa l'optimitzador.
- L'optimitzador: intenta aconseguir valors òptims en els paràmetres del transformador per tal d'aconseguir una major similitud en la mètrica.

Provarem dos mètodes de registre diferents: un mètode afí en què el registre aplicat és rígid, i on s'apliquen transformacions geomètriques sobre tota la imatge, com un bloc (la deformació de la imatge s'aplica per igual en tota aquesta); i un altre mètode anomenat *Thin Plate Splines* on s'aplica un registre no rígid, és a dir, que depenent de les diferències que es trobin en els punts donats, la deformació serà més gran o més petita (punt a punt).

Es tracta doncs de transformar una imatge per poder obtenir-ne una de similar, on els punts de la primera imatge siguin coincidents als mateixos punts de la segona. Per fer això calen un seguit de punts, que en el nostre cas corresponen a nevus, per poder buscar la distància mínima entre ells que els faci coincidir en les dues imatges. Aquests punts han de ser molt fiables, ja que és a partir d'ells en què es basa l'algorisme de registre. Per això agafarem els centres de masses dels nevus amb àrees més grans, ja que són els més fàcilment identificables en dues

imatges. Aquesta part és comuna tant en aquest mètode com en l'anterior utilitzant el mètode de cerca exhaustiva, per tant la forma de trobar les pigues grans en les dues imatges està explicada anteriorment.

Després d'aplicar el registre tindrem dues imatges bastant semblants, i fent una resta de les dues intentarem veure els canvis que s'han produït en elles.

Anem a veure com actuen els dos mètodes sobre parells d'imatges. Farem proves sobre imatges senzilles per finalment poder provar alguna dels conjunt de proves. En el desenvolupament d'aquesta part ens hem basat en *Anàlisi, disseny i implementació d'un algorisme de registre en imatges mamogràfiques*, i en les llibreries desenvolupades pel seu autor.

EL REGISTRE AFÍ Com hem dit fa un moment aquest mètode analitza dos conjunts de punts donats que en principi apareixen en les dues imatges i intenta fer transformacions en els punts d'una de les imatges per tal d'ajustar-los als de l'altra. Les transformacions rígides d'aquest mètode són la rotació, la translació, l'afí i la perspectiva. Aquestes modificacions s'apliquen de forma homogènia en tota la segona imatge. Anem a veure un exemple d'una figura, que en la segona imatge ha sofert una rotació.




Figura 4.27: Imatges sintètiques destinades a fer proves en els dos mètodes de registre.

Apliquem l'algorisme per tal de transformar la primera imatge (mòbil) i que quedi semblant a la segona (fixa). Si al registre afí li passem les coordenades dels quatre vèrtex de la figura veiem com queda la primera imatge un cop aplicat el registre:




Figura 4.28: Primera imatge sintètica registrada mitjançant mètode de registre afí.

Podem apreciar com al centre de la nova primera imatge hi apareix una figura equivalent a la segona. Com que el registre afí és rígid, la transformació s'ha aplicat per igual en tota la imatge, i per tant pot ser que alguns dels nous punts que ha trobat el mètode de registre no estiguin dins dels límits de la nova imatge. Així mateix, alguns punts de la nova imatge no han pres el valor de cap punt de l'anterior, i han quedat negres.

EL REGISTRE *THIN PLATE SPLINES* Tot seguit realitzarem proves amb un altres tipus de registre, el *Thin Plate Splines*. Aquest mètode no rígid consta d'una part lineal basada en transformacions afines, i d'una part no lineal, que modela la part no rívida. Donat un conjunt de punts intenta buscar la funció d'interpolació que passa exactament per cada punt, i així poder realitzar les transformacions el millor possible. Aquest mètode aplicarà transformacions més o menys grans segons la diferència que hi hagi entre els mateixos punts en les dues imatges. Val a dir que si la imatge ha sofert unes modificacions homogènies en tots els seus punts, l'algorisme actuarà com si fos rígid. Provem el mètode modificant la mateixa figura que en el mètode afí:



Figura 4.29: Primera imatge sintètica registrada mitjançant mètode de registre *Thin Plate Splines*.

La imatge resultant també ens proporciona una figura central igual que la seg-

ona imatge, amb un fons modificat, i a amb unes zones negres en aquells punts on no hem trobat correspondència amb l'altra imatge.

Les imatges sobre les que hem aplicat el registre són molt senzilles. Cal que veiem com actua en imatges del nostres conjunts de proves. Veiem diferents resultats en els quals la primera imatge ha sigut modificada mitjançant registre per adaptar-la a la segona. En tots els casos s'ha fet primer amb el mètode afí i després amb el *Thin Plate Splines*:




Figura 4.30: Primera imatge binaritzada registrada mitjançant el mètode de registre afí i segona imatge binaritzada.




Figura 4.31: Primera imatge binaritzada registrada mitjançant el mètode de registre *Thin Plate Splines* i segona imatge binaritzada.




Figura 4.32: Resta de la primera imatge binaritzada registrada mitjançant el mètode de registre afí, i la segona imatge binaritzada.




Figura 4.33: Primera imatge binaritzada registrada mitjançant el mètode de registre afí i segona imatge binaritzada.




Figura 4.34: Primera imatge binaritzada registrada mitjançant el mètode de registre *Thin Plate Splines* i segona imatge binaritzada.



Figura 4.35: Resta de la primera imatge binaritzada registrada mitjançant el mètode de registre *Thin Plate Splines*, i la segona imatge binaritzada.

Les noves imatges que hem obtingut s'ajusten millor a la segona pel que fa a la distribució dels nevus. Malgrat aquesta millora en realitzar la resta de les dues imatges, tal i com havíem pensat prèviament, molts nevus no coincideixin (podem observar en la figura 4.35 com alguns nevus si que han coincidit) i a més necessitariem aplicar-los un algorisme com el de la cerca exhaustiva per tenir controlats els nevus per a comparacions i seguiments. El fet de que el mètode de registre afí no ens hagi pogut proporcionar un altra forma de trobar correspondències entre els nevus de les dues imatges és segurament pel fet de que el cos humà no es mou uniformement com altres objectes rígids, on el registre pot actuar amb més efectivitat, i la postura i la posició del pacient poden suposar grans canvis entre imatges. Pel què fa al registre *Thin Plate Splines* el problema recau molt probablement en la selecció dels punts, ja que estan molt concentrats en una zona concreta i en alguns casos no es veu reflectida la veritable transformació entre les dues imatges.

4.1.2 RESULTATS

En aquest apartat de resultats veurem parelles d'imatges de cada conjunt de dades després d'haver-hi aplicat una cerca exhaustiva en les correspondències dels seus nevus. Iniciem els experiments per poder veure com queden les comparacions d'imatges. Comencem per parelles d'imatges del primer conjunt de dades:




Figura 4.36: Comparació dels nevus de la primera imatge de la primera parella d'imatges del primer conjunt de dades.




Figura 4.37: Comparació dels nevus de la segona imatge de la primera parella d'imatges del primer conjunt de dades.




Figura 4.38: Comparació dels nevus de la primera imatge de la segona parella d'imatges del primer conjunt de dades.




Figura 4.39: Comparació dels nevus de la segona imatge de la segona parella d'imatges del primer conjunt de dades.




Figura 4.40: Comparació dels nevus de la primera imatge de la tercera parella d'imatges del primer conjunt de dades.



Figura 4.41: Comparació dels nevus de la segona imatge de la tercera parella d'imatges del primer conjunt de dades.



Figura 4.42: Comparació dels nevus de la primera imatge de la quarta parella d'imatges del primer conjunt de dades.




Figura 4.43: Comparació dels nevus de la segona imatge de la quarta parella d'imatges del primer conjunt de dades.



Figura 4.44: Comparació dels nevus de la primera imatge de la cinquena parella d'imatges del primer conjunt de dades.



Figura 4.45: Comparació dels nevus de la segona imatge de la cinquena parella d'imatges del primer conjunt de dades.

En aquest conjunt de dades el mètode funciona millor en unes imatges que d'altres. Malgrat això podem considerar els resultats obtinguts com a satisfactoris, tenint en compte que es tracta del conjunt amb les imatges amb més complexitat de nevus i que hem hagut d'utilitzar tècniques més elaborades per a realitzar la correspondència.

Provem algunes parelles del segon conjunt de dades.




Figura 4.46: Comparació dels nevus de la primera imatge de la primera parella d'imatges del segon conjunt de dades.



Figura 4.47: Comparació dels nevus de la segona imatge de la primera parella d'imatges del segon conjunt de dades.




Figura 4.48: Comparació dels nevus de la primera imatge de la segona parella d'imatges del segon conjunt de dades.



Figura 4.49: Comparació dels nevus de la segona imatge de la segona parella d'imatges del segon conjunt de dades.



Figura 4.50: Comparació dels nevus de la primera imatge de la tercera parella d'imatges del segon conjunt de dades.




Figura 4.51: Comparació dels nevus de la segona imatge de la tercera parella d'imatges del segon conjunt de dades.



Figura 4.52: Comparació dels nevus de la primera imatge de la quarta parella d'imatges del segon conjunt de dades.



Figura 4.53: Comparació dels nevus de la segona imatge de la quarta parella d'imatges del segon conjunt de dades.

En la majoria de les imatges d'aquest segon conjunt les comparacions realitzades són bones. Segurament degut a la poca quantitat de nevus que hi figuren. En la tercera parella d'imatges, però, apareixen una gran quantitat de falsos positius i falsos negatius degut als pèls del pacient.

També aplicarem l'algorisme sobre les imatges del tercer conjunt. Aquestes imatges són més grans que els dos conjunts ja analitzats, i per tant harem d'incrementar considerablement el valor dels paràmetres. Veiem com queden els resultats:




Figura 4.54: Comparació dels nevus de la primera imatge de la primera parella d'imatges del tercer conjunt de dades.




Figura 4.55: Comparació dels nevus de la segona imatge de la primera parella d'imatges del tercer conjunt de dades.




Figura 4.56: Comparació dels nevus de la primera imatge de la segona parella d'imatges del tercer conjunt de dades.



Figura 4.57: Comparació dels nevus de la segona imatge de la segona parella d'imatges del tercer conjunt de dades.

Els resultats d'aquest darrer conjunt també són bons, tot i que apareix alguns nevus als que no se'ls ha trobat correspondència. La mida més gran d'aquestes

imatges no ha afectat la comparació. A més el temps d'execució no ha incrementat gaire.

Capítol 5

EL GESTOR DE PACIENTS

Per tal de poder sintetitzar tot el treball fet fins ara i al mateix temps poder gestionar i manipular les imatges i les altres dades de tots els pacients amb els quals treballarem, necessitem crear una eina informàtica capaç de realitzar d'una forma ràpida i senzilla operacions simples de gestió de pacients, dotant-la amb les utilitats de detecció i comparació de nevus. Així doncs caldrà realitzar una interfície que permeti la interacció entre els dermatòlegs (o altres usuaris de l'aplicació) i el sistema. En aquest apartat comentarem el disseny i el desenvolupament d'aquest gestor de pacients.

5.1 DISSENY I IMPLEMENTACIÓ

Com que el veritable pes de l'aplicació recau en els algorismes de detecció i comparació ja fets, només caldrà que siguin cridats com a funció, i per tant, en el que haurem de posar més atenció és la part de gestió en si.

Hem decidit que el desenvolupament d'aquesta última etapa sigui també amb *Matlab*, ja que pel fet d'haver estat l'entorn de treball de la resta de l'aplicació hi estem molt familiaritzats, i a part, disposa d'un bon sistema de disseny i implementació d'interfícies gràfiques d'usuari (GUI).

Abans de res cal que veiem totes les funcions que ha de tenir el gestor. A banda de les ja mencionades de detecció i comparació, necessitarem:

- Un mòdul bàsic de gestió (inserció, modificació i eliminació) de pacients.
- Un llistat dels pacients registrats i la capacitat de poder veure les seves dades.
- Utilitats d'ordenació, cerques segons criteris, ...
- Un mòdul de gestió, selecció i visualització de les imatges dels pacients, on també sigui possible poder aplicar els algorismes de detecció i comparació.

La simplicitat de *Matlab* a l'hora de realitzar aquest tipus d'interfícies és molt gran, ja que disposa un editor molt intuïtiu que permet crear diversos ítems (botons,

finestres, menús, ...), afegir textos i imatges, entre d'altres coses. A cada ítem de la interfície podem assignar-li fàcilment una funció, tenint en compte que les variables que volem compartir per tota la interfície han de guardar-se en una estructura particular.

Hem decidit desenvolupar l'aplicació de forma modular. L'hem dividit en dos mòduls: el de gestió i el de comparació.

5.1.1 EL MÒDUL DE GESTIÓ

Aquest mòdul ha de permetre la interactuació entre els usuaris i el pacient pel què fa a la gestió. Ha de realitzar d'una forma ràpida i senzilla insercions, modificacions, actualitzacions, eliminacions, mostres i cerques de pacients, ha de ser capaç de mostrar una llista de pacients i poder ordenar-la, i també ha de donar pas al mòdul de visualització d'imatges. Cada una d'aquestes funcions serà executada mitjançant un botó determinat.

Podem veure l'aparença d'aquest mòdul en la figura següent. Està compost per una barra d'eines a la part superior, una zona de llistat de pacients al centre i una zona de mostratge de dades del pacient seleccionat a la part inferior.

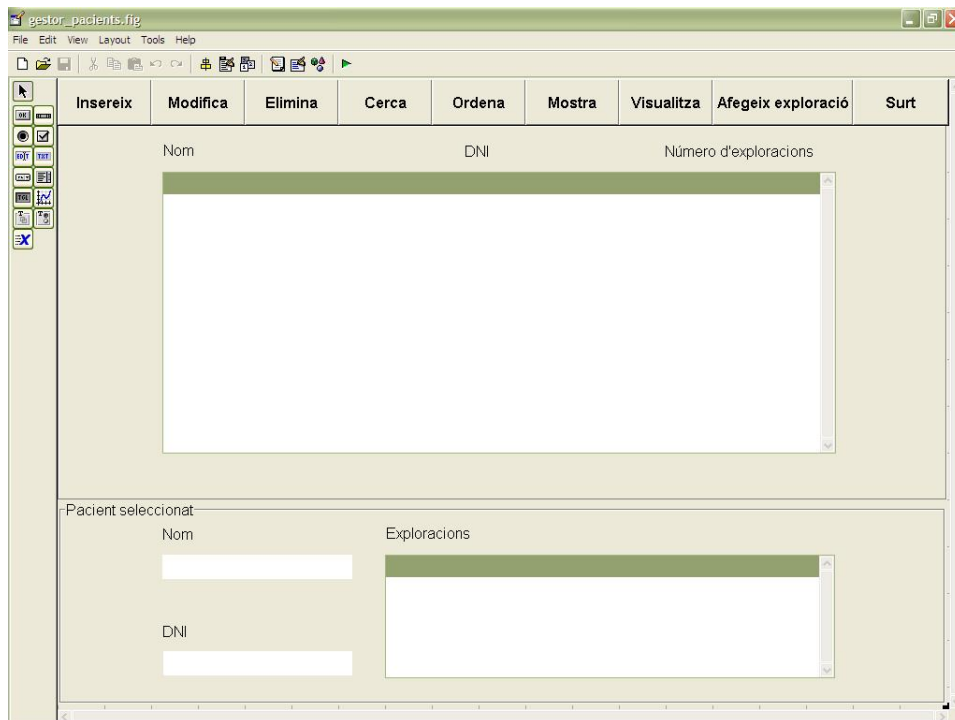


Figura 5.1: Aparència del mòdul de gestió en l'editor de Matlab.

Per a l'emmagatzematge dels diferents pacients hem pensat que seria oportú

crear una taula. Els camps que ha de tenir aquesta taula aniran associats a les diferents dades que ha de tenir el pacient: DNI, nom, cognom, i diverses exploracions. Entenem per exploració el conjunt d'imatges de diferents parts del cos d'un pacient preses en una data (una visita per exemple). Cada pacient pot arribar a tenir diverses exploracions, i en cada una d'elles hi pot haver diverses imatges. Així el camp de les exploracions serà una estructura formada per diverses estructures corresponents a cada exploració realitzada, que contindran la data i les diferents imatges. Els pacients de la taula (concretament nom, DNI i número d'exploracions) seran mostrats en forma de llista, i cada vegada que modifiquem la taula serà guardada i els valors de la llista seran restaurats. El llistat de pacients, a banda de mostrar algunes dades també ens servirà com a mitjà de selecció. En cas de que vulguem veure les dades personals i les exploracions d'un pacient en particular aquestes seran mostrades en la part inferior (zona de mostreig d'un pacient seleccionat). Som conscients que la capacitat de gestió de pacients i exploracions serà limitada degut al fet de guardar la taula com a dada de *Matlab*.

Els diferents botons de la barra d'eines i la funció que han de dur a terme són:

- **Insereix:** obté les dades d'un nou pacient i l'afegeix a la taula de pacients. Actualitza el llistat de pacients amb el nou inserit.
- **Modifica:** canvia el valor d'un dels camps d'un pacient seleccionat. Modifica els valors que s'han canviat a la taula de pacients i restaura la llista de pacients.
- **Elimina:** treu un pacient de la taula de pacients i l'elimina de la llista.
- **Cerca:** a partir de l'elecció d'un dels camps de la taula de pacients, cerca un pacient i el selecciona en el llistat en cas de que existeixi.
- **Ordena:** ordena alfabèticament (segons el cognom) els pacients del llistat.
- **Mostra:** un cop seleccionat un pacient, mostra les dades personals i el contingut de les exploracions (data i nom de les imatges) en la part inferior.
- **Visualitza:** obre el mòdul de visualització en cas de que haguem seleccionat un pacient.
- **Afegeix exploració:** insereix una nova exploració a un pacient ja existent. Actualitza el camp d'exploracions de la taula de pacients amb la data i les imatges d'aquesta nova exploració.
- **Surt:** tanca el mòdul de gestió.

Algunes d'aquestes utilitats realitzen la seva funció en la mateixa interfície de gestió, però alguns altres (concretament Insereix, Modifica, Cerca i Afegeix exploració, a banda de la ja mencionada Visualitza) donen el control de l'aplicació a un altre interfície independent, capaç de compartir dades amb la de gestió.

La interfície d'inserció d'un nou pacient demana la introducció dels diferents camps d'un pacient i la importació de les diferent imatges que compondran la seva primera exploració.

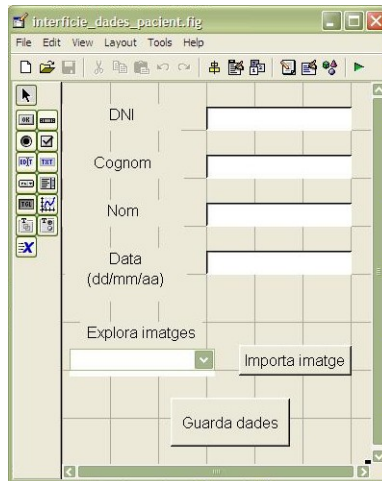


Figura 5.2: Aparença de la interfície d'inserció de pacients.

La interfície de modificació d'un pacient seleccionat permet omplir els camps que volem modificar o bé seleccionar una exploració existent i tornar a importar-ne les imatges.

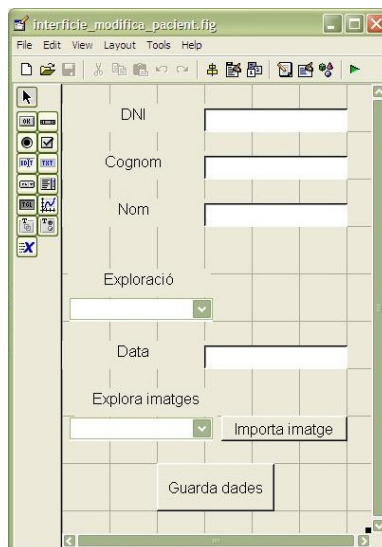


Figura 5.3: Aparença de la interfície de modificació de pacients.

La interfície de cerca d'un pacient dóna l'opció d'escollir entre els camps DNI, cognom i data d'exploració i el text a cercar. Seguidament el pacient apareix selec-

cionat en la interfície principal.

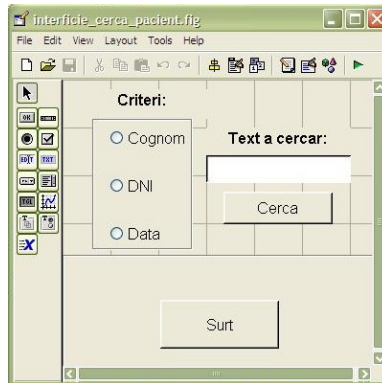


Figura 5.4: Aparença de la interfície de cerca de pacients.

La interfície d'inserció d'una nova exploració permet importar les imatges i afegir la data a una nova exploració d'un pacient seleccionat.



Figura 5.5: Aparença de la interfície d'inserció de noves exploracions de pacients.

5.1.2 EL MÒDUL DE VISUALITZACIÓ

Utilitzarem aquest mòdul per treballar amb les diferents imatges dels pacients. Estarà associat a un pacient prèviament seleccionat (el nom i el DNI del pacient actual apareixeran en el mòdul) i oferirà la possibilitat de realitzar una detecció dels nevus de les imatges i de fer comparacions entre els nevus detectats d'un parell d'imatges.

El mòdul està format per una barra d'eines i d'una zona de visualització d'una parella d'imatges a sota.

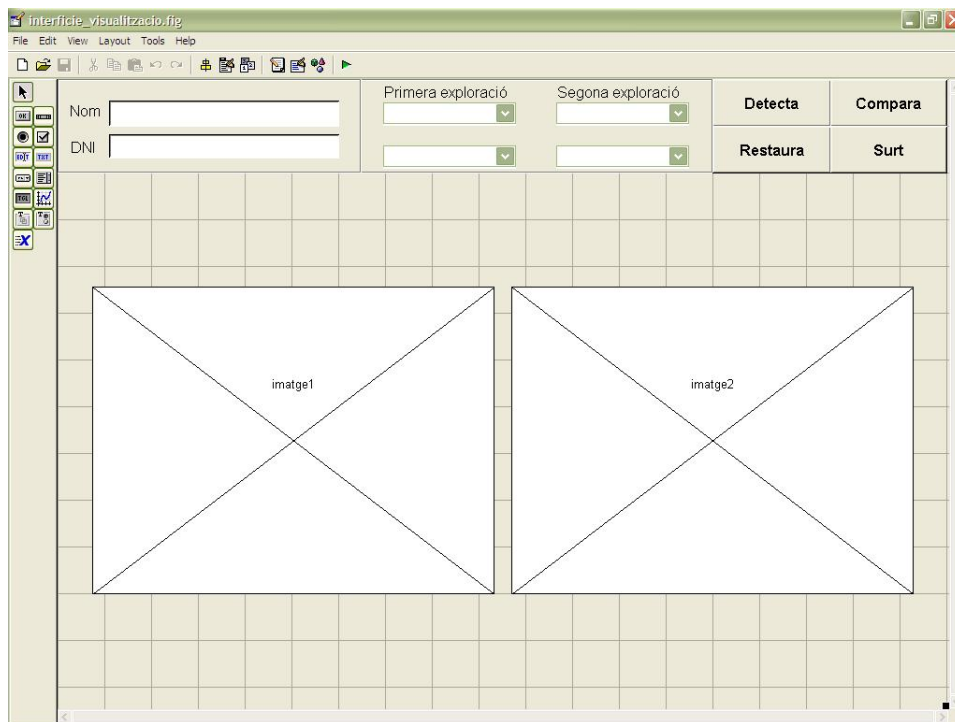


Figura 5.6: Aparència del mòdul de visualització

A l'esquerra de la barra d'eines hi apareixerà el nom i el DNI del pacient del qual utilitzarem les imatges. En el panell central haurem d'escollir dues exploracions del pacient, i de cadascuna una imatge. Quan haguem seleccionat les dues imatges, aquestes apareixeran en els requadres de visualització. A partir d'aquest moment ja podrem treballar amb els botons de més a la dreta de la barra d'eines. La seva funció serà:

- Detecta: realitza la detecció dels nevus de la imatge seleccionada i activa la funció del botó Compara.
- Compara: realitza la comparació dels nevus de les dues imatges (amb la detecció realitzada).
- Restaura: retorna la imatge a l'estat inicial (sense deteccions ni comparacions).
- Surt: tanca el mòdul de visualització d'imatges.

Capítol 6

CONCLUSIONS I TREBALLS FUTURS

6.1 CONCLUSIONS EXTRETES

Un cop arribats en aquest capítol arriba el moment d'analitzar el treball fet. Entre d'altres coses n'hem extret experiència a l'hora d'implementar una aplicació d'unes dimensions considerables, amb tot el que això suposa: un esquema de la feina prevista, una divisió del treball en etapes, la modificació d'alguna d'aquestes etapes, l'anàlisi i testeig de resultats parcials, ... Hem pogut veure en aquesta documentació que en l'inici del projecte ens vam marcar uns objectius, i vam confeccionar una planificació per a assolir-los. Malgrat això també hem observat que no sempre és fàcil cenyir-se als plans de treball previstos, i que a vegades, cal reorganitzar l'esquema inicial sobre la marxa per adaptar-se a les necessitats del projecte.

També hem notat els progressos en el redactat de documents tècnics. Ens referim a aspectes com l'estructura de la documentació, la formalitat a l'hora de redactar, la referenciació de certs continguts, ... Tot això ho ha afavorit en gran part la utilització com a eina d'edició de \LaTeX , ja que gràcies a aquest entorn, només cal centrar-se en el contingut del text, deixant de banda la feina d'ajustament del format. Recordem que aprendre a utilitzar aquest programa d'edició de textos era un dels objectius secundaris que teníem.

Hem hagut d'aprendre moltes coses noves, i per tant, hem necessitat de l'ajuda de diversos manuals, tutorials, articles, i d'altra documentació. També ens hem hagut de documentar sobre les aplicacions ja existents que hi ha en el tema de la detecció i seguiment de nevus. Per tant també hem agafat agilitat a l'hora de cercar informació, ja sigui en publicacions o bé a Internet.

A banda d'aquestes conclusions d'àmbit més personal també n'hem extret pel què fa a investigació. Hem treballat molt en l'estudi de tècniques i mètodes de Visió per Computador: binaritzacions, segmentacions, registres i altres processats d'imatge. Sempre amb la finalitat principal del projecte, que no és altra que el

desenvolupament d'una eina d'anàlisi i prevenció del melanoma a partir d'imatges.

Hem vist de que no es tracta d'una feina senzilla. En el sistema de detecció de nevus d'una imatge hem apreciat que la clau d'una detecció acceptable recau en una bona binarització de la imatge. Per això hem dedicat esforços en l'estudi de diferents tècniques de binarització d'imatges. Els resultats d'aquests mètodes han sigut diferents. La binarització local ha ofert uns bons resultats, binaritzant correctament la major part dels nevus i generant poques falses deteccions. Els mètodes supervisats a partir de distàncies potser són els que han proporcionat unes imatges menys bones, amb certes debilitats en la detecció, però han suposat un tema d'estudi molt interessant, i han comportat l'aparició d'un nou mètode que no estava inclòs en la planificació inicial: el mètode de segmentació supervisada a partir de probabilitats bayesianes. De bon principi aquest tipus de segmentació ens havia de proporcionar una binarització semblant a la local. Al final però, s'ha convertit en un bon classificador de pell, i l'hem utilitzat com a màscara per delimitar la regió de cerca de nevus pels altres mètodes. Així doncs la composició dels mètodes i la posterior detecció i eliminació de falsos positius han donat lloc a uns bons resultats. Hem pogut veure com es tracta d'un mètode robust, i que el resultat de l'algorisme no es veuen afectat pels canvis de mida i de resolució de la imatge (potser una mala il·luminació de les imatges pot provocar algun fals positiu que serà posteriorment tractat).

Potser la detecció ens va portar més temps de dedicació, però la comparació va suposar un treball més complex. El mètode de cerca exhaustiva ha acabat oferint una bona comparació. Troba la correspondència de la majoria dels nevus d'una primera imatge en una segona, i és capaç de veure aparicions i desaparicions de nevus entre imatges. Hem observat com és realment complicat obtenir una correspondència perfecta entre els nevus de dues imatges, degut a la naturalesa canviant dels nevus, a les diferències que hi pugui haver entre les dues imatges (escala, orientació, posició de la zona del cos, resolució de la imatge), a la presència de falsos positius i falsos negatius, etc. Hem intentat solventar al màxim possible aquestes diferències mitjançant alguns paràmetres de relació d'escala, orientació, de distribució espacial, entre d'altres, i ho hem aconseguit fins a cert punt. L'algorisme final proporciona una comparació acceptable, però potser una mica sensible als canvis de mida i/o resolució. Per això els paràmetres dels diferents conjunts de dades han hagut de ser reajustats. Aquesta gran quantitat de paràmetres a ajustar potser ha suposat un petit handicap.

En les proves realitzades amb el registre de seguida vam veure que el mètode no ens oferiria els resultats esperats. La transformació d'una de les imatges per ajustar-la a la posició, orientació i escala de l'altra, no sempre suposa dues imatges amb coordenades coincidents en els mateixos nevus. Molt probablement la gran mobilitat del cos humà proporciona posicions de la mateixa zona que ni amb tècniques de registre no rígid es poden arribar a comparar. Tot i això, les imatges obtingudes no tenen una disposició dels nevus tan distants, i la investigació sobre el registre ens han aportat coneixements que potser algun dia ens seran d'utilitat.

Pel què fa a l'aplicació, podríem dir que ha estat tot un repte aprendre a dis-

senyar i implementar una interfície de gestió amb una eina com *Matlab*. Hem de dir que l'eina GUI de què disposa ofereix un gran ventall d'avantatges per aconseguir aquest objectiu, orientat a la manipulació de dades com les nostres (imatges digitals).

Per últim també volem comentar la gran ajuda que ens ha ofert la confecció de diferents tipus de conjunts d'imatges, cadascun amb les seves peculiaritats, i que ens ha permès tocar tots els punts problemàtics que ens poguéssim trobar, així com proporcionar imatges adients per accomplir les tasques previstes. Per exemple hem observat que és més simple treballar amb imatges ben il·luminades, o que el temps d'execució d'alguns mètodes (com els de segmentació supervisada), són directament proporcional a la mida de les imatges.

En definitiva, podem afirmar que hem complert tots els objectius que ens vam plantejar en l'inici amb uns resultats satisfactoris.

6.2 PROJECTES FUTURS

En tots els projectes hi ha d'haver la possibilitat de realitzar ampliacions o altres enfocaments per tal d'ampliar la investigació o per altres motius que dependran de les necessitats. Seguidament proposem alguns d'aquests projectes futurs:

- La implementació d'aquesta aplicació ha estat íntegrament en *Matlab*. Això fa que els usuaris que la requereixin es vegin obligats a tenir instal·lat en el seu ordinador una versió de *Matlab* (superior a la 7 si és possible). La traducció del codi de l'aplicació a un altre llenguatge de programació que pugui actuar en diverses plataformes sense la necessitat de la instal·lació prèvia de cap software, pot facilitar l'ús d'aquesta eina d'una forma més senzilla i eficient.
- Seguint en la primera proposta, pensem que podria ser interessant la implantació d'un prototip de l'aplicació en un hospital i poder veure si realment funciona en casos reals. Podríem veure si l'estat actual de l'aplicació és suficient o calen altres utilitats, o bé algunes de les actuals requereixen modificacions. Segurament caldria gestionar les dades amb un gestor de bases de dades del tipus *MySQL*, *Oracle*, *Access*, o altres.
- Pel què fa a la binarització de les imatges, necessita uns paràmetres una mica diferents per cada conjunt de dades. Aquests paràmetres (llindars, mides de finestra, etc) els hem obtingut experimentalment. Es podria intentar dotar la binarització d'un mètode d'obtenció dels valors dels paràmetres de forma automàtica, i que aquest ofereixi els mateixos resultats que els que ofereix el sistema actual.
- Tant el detector com el comparador, tenen un seguit de paràmetres que van lligats a la mida i a la resolució de les imatges (mida mínima i màxima d'un nevus, criteri de selecció de nevus grans, ...). Podria augmentar el grau

d'automatització d'aquests sistemes intentar lligar-los a la mida i resolució de les imatges. També, a partir de la relació entre els píxels de pell i els de nevus trobats en la detecció podríem ajustar els paràmetres del comparador (ja que no és el mateix la relació pell/nevus d'una imatge d'una esquena que la d'un braç).

- Hem vist que el registre no ens ofereix unes imatges suficientment semblants com per realitzar una resta, però si que augmenta la similitud. Potser basar el comparador en els nevus detectats en les imatges registrades pot millorar el número de correspondències ben assignades.

Apèndix A

MANUAL D'USUARI

En aquest annex hi podrem trobar un manual d'usuari per a la utilització de l'aplicació. En principi, els usuaris seran investigadors (dermatòlegs i altres metges). Aquestes persones específiques estan acostumades a treballar en aquests tipus d'entorns experimentals (i per tant, també ho estan en interfícies d'usuari implementades en *Matlab*).

Un cop aparegui la interfície, apareixeran llistats els diferents pacients que tenim registrats. La majoria de funcions requereixen de la selecció d'un pacient. Per fer-ho cliquem amb el ratolí sobre la fila del llistat on hi figura el pacient que volem seleccionar.

Si volem sortir tant de la interfície de gestió com de la de visualització d'imatges ho hem de fer a partir del botó 'Surt'.

A.1 INSERCIÓ D'UN NOU PACIENT

Si volem afegir un nou pacient hem de prémer el botó 'Insereix'. Això donarà pas a la obertura d'una nova interfície on haurem d'omplir les dades del pacient i haurem d'incorporar-li la primera exploració. Per fer-ho haurem de clicar en el menú desplegable 'Explora imatges' i ens apareixeran totes les imatges (arxius amb extensió *jpg*) que existeixen al directori. Un cop seleccionada una imatge haurem de prémer 'Importa imatge'. Repetirem aquesta acció tantes vegades com imatges vulguem importar. Emmagatzemarem el nou pacient i tornarem a la interfície principal prement 'Guarda dades'. Si hi ha algun camp sense omplir i guardem, la inserció no s'efectuarà.

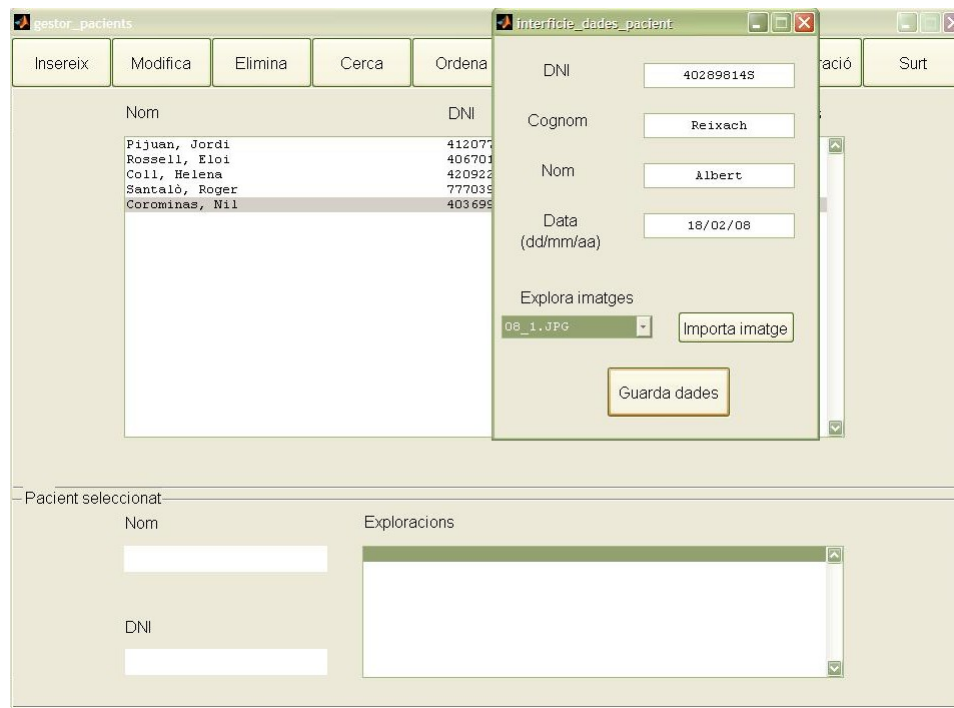


Figura A.1: Inserció d'un nou pacient.

A.2 MODIFICACIÓ D'UNA O MÉS DADES D'UN PACIENT SELECCIONAT

Quan volem realitzar alguna modificació en algun pacient l'hem de seleccionar de la llista i després hem de prémer el botó 'Modifica', i se'ns obrirà una nova interfície. En el cas de que vulguem canviar alguna de les dades personals (nom, cognom o DNI) simplement caldrà que escrivim el nou text en les caselles corresponents. En canvi si volem modificar alguna dada d'una exploració que ja existeix, primer haurem de seleccionar l'exploració en qüestió del menú desplegable 'Exploració', i seguidament modificarem les dades que desitgem. Si volem la data de l'exploració hem de posar la nova en la cassella corresponent, mentre que si el que pretenem és canviar alguna de les imatges de l'exploració, haurem de tornar a afegir-hi totes les imatges (seleccionant-les en el menú desplegable 'Explora imatges' i prement 'Importa imatge'). Un cop realitzats els canvis guardem el pacient i tornem la interfície principal mitjançant 'Guarda dades'.

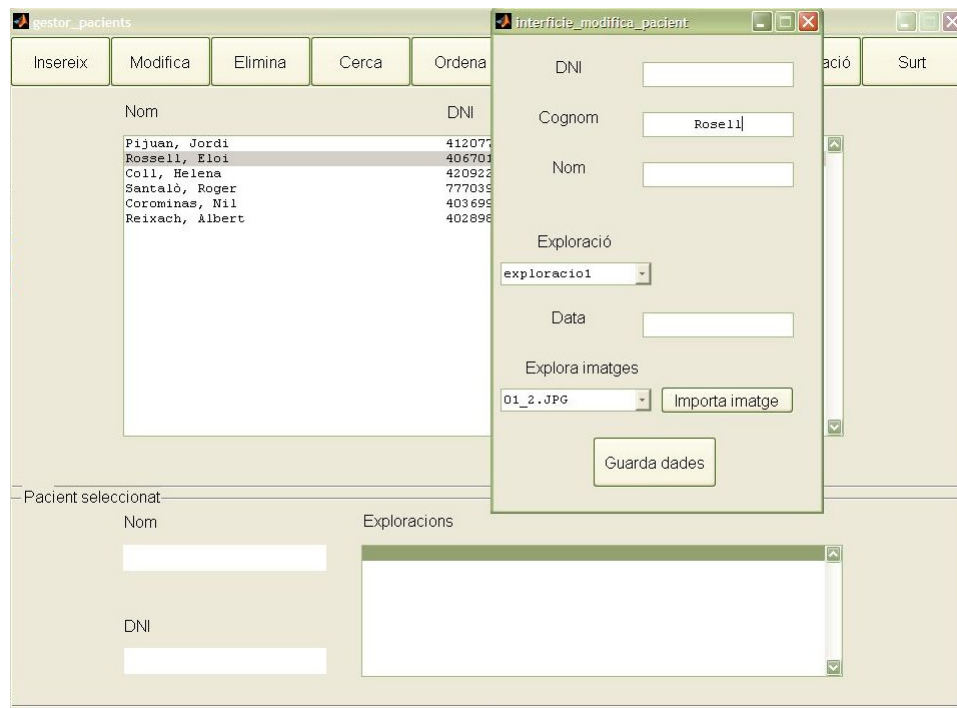


Figura A.2: Modificació d'una o més dades d'un pacient seleccionat.

A.3 ELIMINACIÓ D'UN PACIENT SELECCIONAT

Quan volem eliminar un pacient tant de la llista de pacients com de la taula de pacients (sense la possibilitat de tornar a recuperar aquest mateix pacient) tan sols hem de seleccionar-lo amb el ratolí i prémer 'Elimina'.

A.4 CERCA D'UN PACIENT A PARTIR D'UN CRITERI

Si volem trobar ràpidament un pacient a la llista premem sobre 'Cerca'. Una nova interfície independent apareixerà. El primer que hem de fer és seleccionar el criteri de cerca d'entre DNI, cognom i data (la cerca no es realitzarà si no hem seleccionat un d'aquests camps). Tot seguit introduïm el text que volem cercar en la casella 'Text a cercar'. Si trobem el pacient sortim de la interfície de cerca i aquest apareixerà a la fila de més a dalt de la llista de pacients. En cas de no trobar cap pacient que coincideixi amb el text entrat ens apareixerà el missatge 'No s'ha trobat el pacient'. Si això succeeix podem realitzar una nova cerca o bé sortir de la interfície amb el botó 'Surt'.

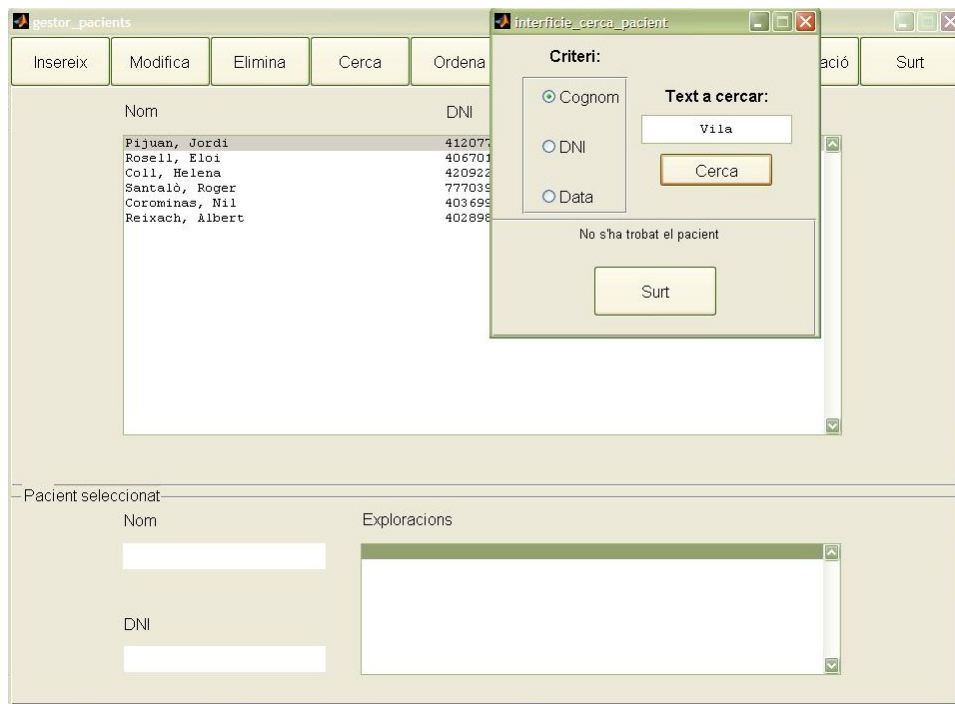


Figura A.3: Cerca d'un pacient a partir d'un criteri.

A.5 ORDENACIÓ DE LA LLISTA DE PACIENTS

En el cas de que vulguem ordenar alfabèticament a partir del cognom els pacients que figuren en el llistat de pacients simplement hem de prémer 'Ordena'.

A.6 MOSTREIG DE LES DADES D'UN PACIENT SELECCIONAT

També podem veure les dades d'un pacient seleccionat mitjançant el botó 'Mostra'. A la part inferior de la interfície ens apareixeran el nom, el cognom, el DNI i les diferents exploracions (data i nom de les imatges que les conformen).

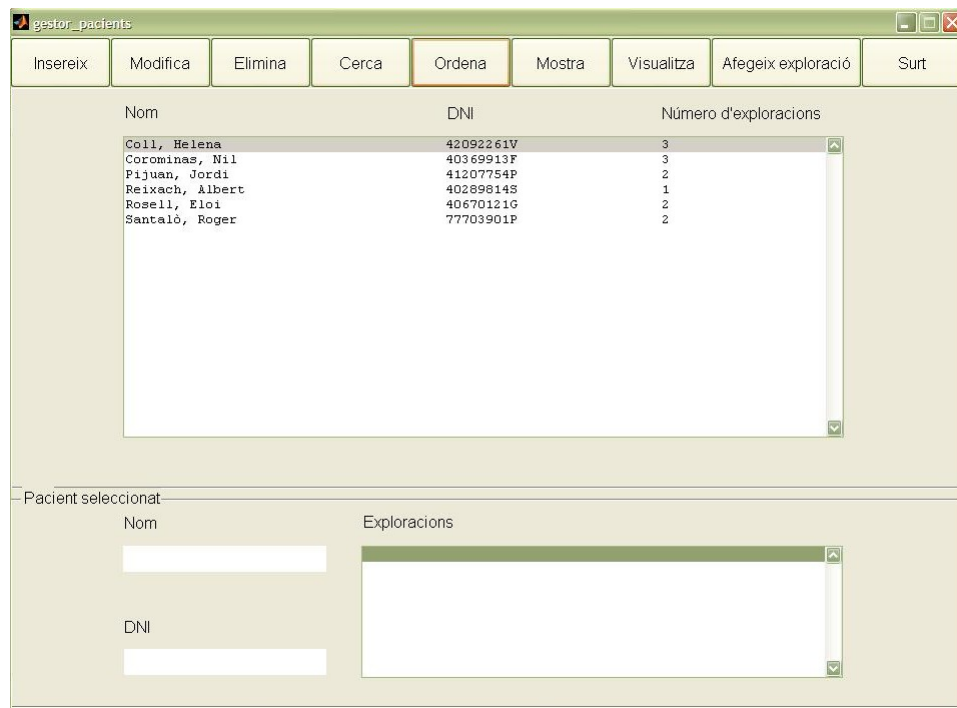


Figura A.4: Ordenació de la llista de pacients i mostreig de les dades d'un pacient.

A.7 INSERCIÓ D'UNA NOVA EXPLORACIÓ A UN PACIENT

Per poder fer comparacions entre diferents imatges necessitem diferents exploracions. La primera sempre s'afegeix en el moment d'inserir un nou pacient, però les altres cal que ho fem a partir del botó 'Afegeix exploració'. Una nova interfície ens apareixerà. Posem la data en la casella corresponent i seleccionem les imatges de l'exploració (prement cada vegada 'Importa imatge'). Un cop hem acabat guardem la nova exploració i tornem a la interfície principal amb 'Guarda dades'. Podem observar com en el llistat el número d'exploracions del pacient s'ha incrementat.

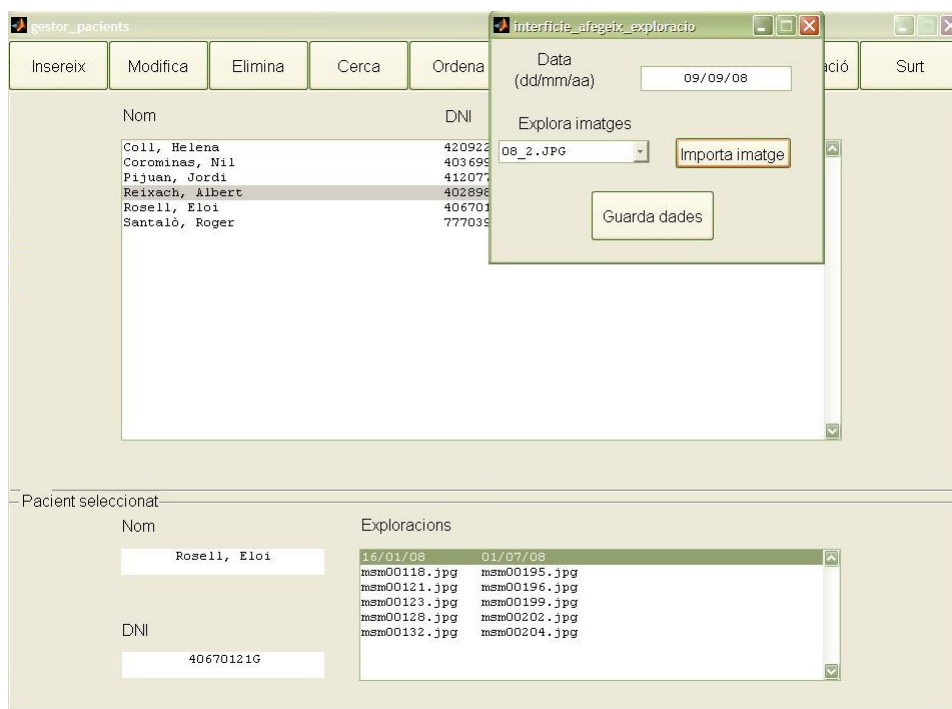


Figura A.5: Inserció d'una nova exploració a un pacient.

A.8 PAS A LA INTERFÍCIE DE VISUALITZACIÓ D'UN PACIENT SELECCIONAT

Si seleccionem un pacient de la llista i seguidament cliquem a 'Visualitza' pasarem a una nova interfície amb diferents utilitats. En la part superior (barra d'eines) hi apareixeran el nom i el DNI del pacient seleccionat. En la part central hi podem veure un panell de selecció de les exploracions i de les imatges d'aquestes. Seleccionarem una exploració del menú 'Primera exploració' i una del menú 'Segona exploració'. Tan bon punt haguem seleccionat cadascuna de les dues exploracions sobre les quals treballarem apareixeran les dates de les exploracions, i en els menús desplegable hi figuraran la col·lecció d'imatges de cada exploració. Quan haguem seleccionat les imatges les podrem visualitzar en els requadres de sota la barra d'eines. En aquest punt s'activa la funció del botó 'Detecta' encarregat de realitzar la detecció dels nevus en les imatges.



Figura A.6: Tria de les imatges de les exploracions seleccionades d'un pacient.

A.9 DETECCIÓ DELS NEVUS EN LES IMATGES SELECCIONADES

Mitjançant 'Detecta' el procés de detecció dels nevus de les imatges es posa en marxa. Cal tenir en compte que aquest procés és complex, i que no és instantani (pot trigar diversos segons, o fins i tot més d'un minut).

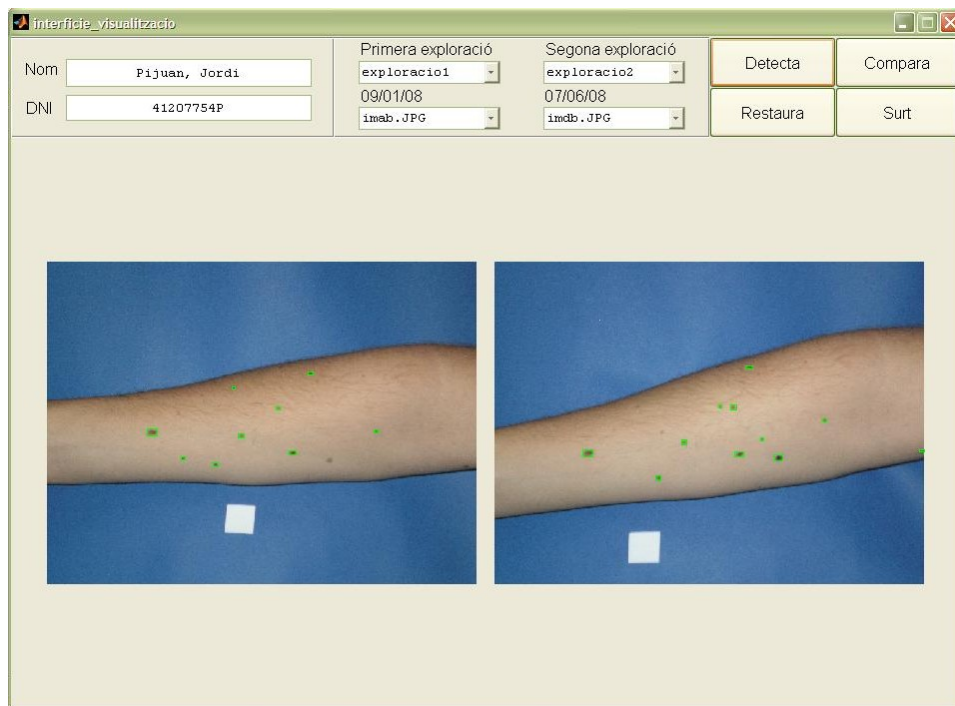


Figura A.7: Detecció dels nevus en les imatges seleccionades.

A.10 COMPARACIÓ DELS NEVUS DE DUES IMATGES AMB LA DETECCIÓ REALITZADA

Un cop la detecció ha estat realitzada la funció del botó 'Compara' s'activa, i per tant ja podem realitzar la comparació dels nevus de les dues imatges.

A.11 RESTAURACIÓ DE LES IMATGES SELECCIONADES

Després de realitzar la detecció o la comparació podem restaurar les imatges. Si premem 'Restaura' les imatges tornaran al seu estat original, és a dir, sense deteccions ni comparacions.

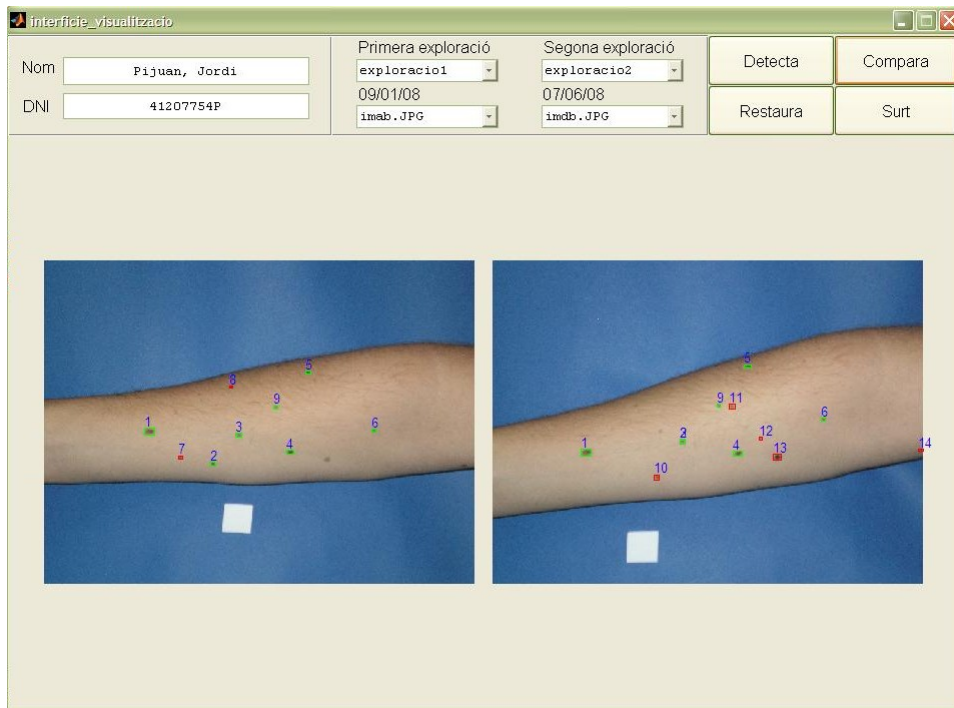


Figura A.8: Comparació dels nevus de dues imatges amb la detecció realitzada.

Bibliografia

- [1] VEZHNEVETS, V; SAZONOV, V; ANDREEVA, A. *A Survey on Pixel-Based Skin Color Detection Techniques*. Proceedings Graphicon, Moscou, 2003.
- [2] RASIWASIA Nikhil; *Color Space for Skin Detection*. Fondazione Graphitech, University of Trento.
- [3] JAYARAM, S; SCHMUGGE, S; SHIN, M; TSAP, L. *Effect of Colorspace Transformation, the Illuminance Component, and Color Modelling on Skin Detection*. Lawrence Livermore National Laboratory, Washington, 2004.
- [4] ZISSERMAN, A. *Lectures 5 & 6: Classifiers*. Hilary Term, 2007.
<http://www.robots.ox.ac.uk/~az/lectures/est/index.html> (abril 2008).
- [5] QUINLAN, R. *Decision Tree Classifier*. 1993.
- [6] MORSE, Bryan. *Lecture 4: Thresholding*. Brigham Young University, Utah, 2000.
- [7] BARRAGAN, Diego. *Manual de Interfaz Gráfica de Usuario en Matlab*. 2007.
- [8] Image Processing Toolbox. Pàgina oficial de la llibreria Image Processing Toolbox de Matlab.
<http://www.mathworks.com/access/helpdesk/help/toolbox/images/> (desembre 2007).
- [9] Binkdagger. Bloc de Matlab amb múltiples tutorials.
<http://www.blinkdagger.com/matlab> (juliol 2008).
- [10] CataLàTeX. El lloc català de LaTeX. <http://phobos.xtec.cat/jqueralt/> (juliol 2008).
- [11] FotoFinder Systems. Pàgina oficial de FotoFinder.
<http://www.fotofinder.de/es> (novembre 2008).
- [12] Mecamed Equipamiento Hospitalario. Pàgina de Molemax.
http://www.mecamed.com/MoleMax_II.htm (novembre 2008).

- [13] Canfield. Pàgina oficial de Mirror.
http://www.canfieldsci.com/Imaging_Products_Imaging.asp (octubre 2008).
- [14] Melanoma Articles. Blog amb múltiples aplicacions informàtiques sobre el melanoma. <http://melanoma.blogsome.com/> (novembre 2008).
- [15] Dmedicina. Pàgina amb múltiple informació del melanoma.
<http://www.dmedicina.com/salud/cancer/melanoma.html> (juny 2008).
- [16] Salud. Pàgina amb múltiple informació sobre els nevus.
http://www.salud.com/enfermedades/nevus_melanicos_lunares.asp (juny 2008).
- [17] LLADÓ, Xavier. *Tema 2 Sensors*.
http://pserv.udg.edu/Portal/Uploads/4136202/Tema2_sensors1.pdf (juny 2008).
- [18] ROMAGÓS, Jordi. *Anàlisi, disseny i implementació d'un algorisme de registre en imatges mamogràfiques*. Girona, 2007.
- [19] GONZÁLEZ, Javier. *Visión por Computador*. Paraninfo, Madrid, 2000.