



UNIVERSITAT POLITÈCNICA DE CATALUNYA
BARCELONATECH

Escola d'Enginyeria de Barcelona Est

TREBALL FI DE GRAU

Grau en Enginyeria Biomèdica

SEGMENTACIÓ D'IMATGES BIOMÈDIQUES



Memòria i Annexos

Autora: Raquel Piñeiro Martínez
Directora: Alícia Casals i Gelpí
Co-Director: Narcís Sayols Baixeras
Convocatòria: Gener 2018

Resum

Per algunes aplicacions, com el reconeixement per imatge, no es pot processar la imatge sencera directament ja que és un procés ineficient i no resulta gens pràctic. Així doncs, un dels mètodes emprats per poder processar la imatge consisteix en la classificació d'aquesta en diferents zones que comparteixin una o més característiques. Separar la imatge en regions és conegut com a segmentació d'imatges. La segmentació d'imatges juga un paper molt important en moltes aplicacions amb imatges mèdiques, permetent l'automatització i/o el fet de facilitar la delineació d'estructures anatòmiques o regions d'interès de la imatge, extreure característiques i diferenciar-les del fons. S'han proposat molts algorismes per tal de segmentar imatges biomèdiques. En aquest projecte es farà una breu descripció dels diferents tipus d'imatges biomèdiques i de les tècniques que es porten a terme per tal d'obtenir-les. A més, també s'explicaran breument els mètodes de segmentació d'imatges biomèdiques utilitzats avui en dia i es farà una comparació entre els resultats obtinguts a partir de cadascun d'ells. A més d'això, es portarà a terme la creació d'un algorisme en llenguatge de programació MATLAB que intentarà implementar els punts forts de cadascuna de les tècniques descrites prèviament per tal d'obtenir un nou mètode que permeti segmentar el major nombre de tipus d'imatges biomèdiques possibles.

Paraules clau: *Visió per ordinador, Segmentació d'imatges biomèdiques, Mètodes de binarització per llindar, Mètodes d'agrupament, Models deformables.*

Resumen

En algunas aplicaciones, como el reconocimiento por imagen, no se puede procesar la imagen entera directamente ya que es un proceso ineficiente y no resulta nada práctico. Así pues, uno de los métodos empleados para poder procesar la imagen consiste en la clasificación de ésta en diferentes zonas que compartan una o más características. Separar la imagen en regiones es conocido como segmentación de imágenes. La segmentación de imágenes juega un papel muy importante en muchas aplicaciones con imágenes médicas, permitiendo la automatización y / o el hecho de facilitar la delineación de estructuras anatómicas o regiones de interés de la imagen, extraer características y diferenciarlas del fondo. Muchos algoritmos han sido propuestos para segmentar imágenes biomédicas. En este proyecto se hará una breve descripción de los diferentes tipos de imágenes biomédicas y de las técnicas que se llevan a cabo para obtenerlas. Además, también se explicarán brevemente los métodos de segmentación de imágenes biomédicas utilizados hoy en día y se hará una comparación entre los resultados obtenidos a partir de cada uno de ellos. Además de ello, se llevará a cabo la creación de un algoritmo en lenguaje de programación MATLAB que intentará implementar los puntos fuertes de cada una de las técnicas descritas previamente para obtener un nuevo método que permita segmentar el mayor número de imágenes biomédicas posibles.

Palabras clave: *Visión por ordenador, Segmentación de imágenes biomédicas, Métodos de binarización por umbral, Métodos de agrupamiento, Modelos deformables.*

Abstract

In some applications, such as image recognition, the entire image cannot be processed directly as it is an inefficient process and it is not practical at all. Thus, one of the methods used to process the image consists in classifying it in different areas that share one or more characteristics. Separating the image into regions is known as image targeting. Image segmentation plays a very important role in many applications with medical images, allowing automation and / or facilitating the delineation of anatomical structures or regions of interest in the image, extracting characteristics and differentiating them from background. Many algorithms have been proposed in order to segment biomedical images. This project will give a brief description of the different types of biomedical images and of the techniques that are carried out in order to obtain them. In addition, the methods of segmentation of biomedical images used today will be briefly explained and a comparison will be made between the results obtained from each one of them. In addition to this, the creation of an algorithm in the programming language MATLAB will be carried out and it will try to implement the strengths of each of the previously described techniques in order to obtain a new method that allows segmenting the largest number of possible biomedical images.

Key Words: *Computer vision, Biomedical images segmentation, Threshold methods, Clustering methods, Deformable models.*

*Dedicat a la
meva família*

Glossari

- *Imatge RGB*: Tipus d'imatge que té tres canals d'intensitat que corresponen al RED, GREEN i BLUE.
- *Imatge en escala de grisos*: Tipus d'imatge amb un sol canal d'intensitat.
- *Imatge binaritzada*: Tipus d'imatge que només té dos possibles valors per a cada píxel.
- *TAC*: Les sigles TAC corresponen a Tomografia Axial Computeritzada.
- *RMN*: Les sigles RMN corresponen a Ressonància Magnètica Nuclear.
- *PET*: Les sigles PET corresponen a Positron-emission tomography (Tomografia per emissió de positrons).
- *SPECT*: Les sigles SPECT corresponen a Single-photon emission computed tomography (Tomografia computada per emissió de fotó simple).
- *TCO*: Les sigles TCO corresponen a Tomografia de Coherència Òptica.
- *TOD*: Les sigles TOD corresponen a Tomografia de Coherència Difusa.
- *Soroll en una imatge*: En una imatge, correpon a variacions aleatòries (que no es corresponen amb la realitat) de la instensitat o del color.
- *Filtre passa-baix*: Correspon a un filtre electrònic que permet el pas de les freqüències més baixes i atenua les freqüències més altes.
- *Filtre passa-alt*: Correspon a un filtre electrònic que, contràriament a un filtre passa-baix, permet el pas de les freqüències més altes i atenua les freqüències més baixes.
- *Mètode BHT*: Les sigles BHT corresponen a Balanced Histogram Thresholding (Binarització per equilibri de l'histograma).

- *Cluster*: Aquest terme, en aquest projecte, s'aplica a un conjunt de píxels que comparteixen alguna característica comuna.
- *Distància euclidiana*: És la distància ordinària entre dos punts que es mesura amb un regle, i ve donada pel teorema de pitàgores.
- *Snake*: És una corba deformable que pot adquirir la forma de l'objecte que es vol segmentar.
- *rgb2gray*: Instrucció de MATLAB que ens permet transformar una imatge RGB a una imatge en escala de grisos.
- *medfilt2*: Instrucció de MATLAB que ens permet portar a terme un filtratge de la imatge per tal d'eliminar soroll.
- *imadjust*: Instrucció de MATLAB que permet ajustar l'histograma (quedar-nos amb només un tros d'ell, expandir-lo, encongir-lo...)
- *imerode*: Instrucció de MATLAB que permet portar a terme una erosió de la imatge.
- *imdilate*: Instrucció de MATLAB que ens permet portar a terme una dilatació de la imatge.
- *strel*: Element estructural en 2D que s'utilitza per portar a terme la dilatació i erosió.
- *imbinarize*: Instrucció de MATLAB que permet transformar una imatge en escala de grisos en una imatge binaritzada.
- *bwareaopen*: Instrucció de MATLAB que elimina els conjunts de píxels que siguin més petits que el nombre designat.
- *regionprops*: Instrucció de MATLAB que ens permet mesurar les propietats de les diferents regions de la imatge.

Índex

Resum	i
Resumen	ii
Abstract	iii
Agraïments	iv
Glossari	v
1 Introducció	1
1.1 Objectius i abast del treball	1
2 Imatges Biomèdiques	3
2.1 Visió per ordinador	3
2.2 Tipus d'imatges	4
2.2.1 Imatges RGB	4
2.2.2 Imatges de intensitat (Escala de grisos)	5
2.2.3 Imatges Binàries	5
2.3 Modalitats d'imatges mèdiques	7
2.3.1 Raigs-X	7
2.3.1.1 Radiografia	7
2.3.1.2 Fluoroscòpia	9
2.3.1.3 TAC (Tomografia Axial Computeritzada)	10
2.3.2 RMN (Ressonància Magnètica Nuclear)	13
2.3.3 Medicina Nuclear	14
2.3.3.1 PET (Tomografia d'Emissió d'Electrons)	15
2.3.3.2 SPECT (Tomografia Computada d'Emissió d'Electrons)	17
2.3.4 Imatges Òptiques	18
2.3.4.1 Endoscòpia	19
2.3.4.2 TCO (Tomografia de Coherència Òptica)	19
2.3.4.3 Imatges fotoacústiques	19
2.3.4.4 TOD (Tomografia Òptica Difusa)	20

2.3.4.5	Espectroscopia Raman	20
2.3.4.6	Microscòpia de super-resolució	21
2.3.5	Ultrasons	21
2.3.6	Termografia	23
3	Segmentació	27
3.1	Què és la segmentació	27
3.2	Estat de l'art. Tècniques de segmentació	28
3.2.1	Mètodes de llindar. (<i>Thresholding Approaches</i>)	28
3.2.2	Tècniques de fronteres o contorns	32
3.2.2.1	Gradient + binarització	32
3.2.2.2	Mètodes en el domini freqüencial (<i>High-Emphasis Spatial Frequency Filtering</i>) + Binarització	38
3.2.3	Segmentació per àrees	40
3.2.3.1	Creixement de regions	40
3.2.3.2	Split and Merge	41
3.2.3.3	Agrupament. (<i>Clustering Approaches</i>)	43
3.2.4	Altres mètodes	44
3.2.4.1	Xarxes neuronals artificials. (<i>Artificial Neural Networks</i>)	44
3.2.4.2	Models deformables / Contorns actius. (<i>Deformable Models</i>)	45
3.2.4.3	Watershed	47
3.2.4.4	Atlas-Guided Approaches	48
4	Algorisme	49
4.1	Context	49
4.2	Algorisme	49
4.2.1	Primera part de l'algorisme	49
4.2.2	Segona part de l'algorisme	57
4.3	Resultats	62
4.3.1	Resultats de la primera part de l'algorisme	62
4.3.2	Resultats de la segona part de l'algorisme	66
5	Anàlisi de l'impacte mediambiental	69
	Conclusions	70

Pressupost i/o anàlisi econòmica	72
Costos directes	72
Costos indirectes	73
Bibliografia	76
Referències bibliogràfiques	76
Bibliografia complementària	78
ANNEX A	80
Codis de MATLAB	80

Índex de figures

2.1	(a) Imatge Original (imatge RGB), (b) Imatge original en escala de grisos, (c) Histograma de la imatge en escala de grisos amb representació del llinar per a la binarització, (d) Imatge original binaritzada.	6
2.2	Imatge radiològica del tòrax. (Font: commons.wikimedia.org)	8
2.3	Principi de funcionament dels fotomultiplicadors. (Font: Sense-Pro.org)	9
2.4	Fluoroscòpia abdomen i pelvis. (Font: SOCHRADI)	10
2.5	Tomografia Axial Computeritzada d'un crani. (Font: Centro Diagnostico Ipcrates)	11
2.6	Principi de funcionament de la Tomografia axial computeritzada (Font: © Encyclopædia Britannica, Inc.)	12
2.7	Estructura d'un escàner de ressonància magnètica.(Font: MRI SCAN) .	13
2.8	Equip obert de ressonància magnètica. (Font: Broadway Imaging Centre)	14
2.9	Principi d'anihilació positró-electró. (Font: Centre for Astrophysics and Supercomputing - Swinburne University)	16
2.10	Esquema d'adquisició del PET. (Font: Jens Maus)	16
2.11	Un pacient durant un SPECT on un parell de gammacàmeres giren al seu voltant. (Font: Wikipedia.org)	18
2.12	Il·lustració esquemàtica de la imatge fotoacústica. (Font: Wikipedia.org)	20
2.13	Estructures cel·lulars visualitzades amb un microscopi de super-resolució. (Font: ScienceMag.org)	21
2.14	(a) Tècnic realitzant la tècnica d'ultrasons a una pacient embarassada, (b) Imatge del fetus obtinguda amb la tècnica d'ultrasons (Font: (a) Dr. José F. De Leon, (b) UTSouthwestern Medicine)	22
2.15	Imatge en 3D d'un fetus obtinguda amb ultrasons. (Font: Baby Scan Clinic)	23
2.16	(a) Imatge tèrmica d'un individu, (b) Imatge d'una càmera tèrmica i d'un monitor col·locats a la terminal d'un aeroport de Grècia. (Font: (a) Digitalrev, (b) Wikipedia.org)	24

2.17	Observació de les extremitats inferiors d'un pacient mitjançant termografia. (Font: Science Direct)	26
3.1	Exemple d'un histograma òptim per a l'aplicació del mètode Otsu. (Font: MATLAB CORNER)	30
3.2	Obtenció del llindar al Balanced Histogram Method. (Font: Wikipedia)	31
3.3	Exemple d'una imatge obtinguda aplicant un filtre Sobel (Font: (a) EEBE, (b) MATLAB)	34
3.4	(a) Imatge Original, (b) Aplicació filtre Sobel, (c) Aplicació filtre Prewitt, (d) Aplicació filtre Roberts, (e) Aplicació filtre Canny, (f) Aplicació filtre Laplaciana (Font: Free stock photos, MATLAB)	37
3.5	Segmentació d'una determinada secció iniciada amb un punt llavor mitjançant el mètode de creixement de regions. (Font: Marshall97)	41
3.6	Estratègia del mètode de segmentació d'imatges Split and Merge. (Font: University of Auckland)	42
3.7	(a) Objecte simple segmentat mitjançant el mètode de Split and Merge, (b) Imatge segmentada amb el mètode Split and Merge (Font: (a) Xiang Yin, (b) Wolfram Demonstration Project)	42
3.8	Exemple de la distribució de píxels amb 3 clusters. (Font: MATHWORKS)	44
3.9	Detecció de dos objectes que la càmera reconeix com cotxe i persona. (Font: YouTube)	45
3.10	Exemple de l'aplicació del mètode "Snakes". (Font: Brunel University)	46
3.11	Exemple de representació topogràfica d'una imatge amb mètode Watershed. (Font: Research Gate)	47
3.12	(a) Imatge original, (b) Sobresegmentació de la imatge original com a resultat de l'aplicació de la transformada de Watershed sense un filtratge previ per reduir soroll. (Font: SciELO)	48
4.1	Imatge d'una estructura 3D corresponent a un cor que serà processada amb el codi.	50
4.2	(a) Histograma d'una de les imatges originals, (b) Nou histograma, distribuint tots els píxels entre els valors 0 i 1.	51
4.3	Imatge del cor després d'aplicar imadjust a MATLAB.	52
4.4	Imatge resultant després de l'aplicació del filtre morfològic.	53
4.5	Imatge resultant després de portar a terme la binarització.	54

4.6	Conjunts de píxels que romanen després d'eliminar els conjunts de píxels més petits que 1000.	55
4.7	Imatge final obtinguda mitjançant el codi de segmentació.	56
4.8	(a) Exemple de contorn per a la segona part de l'algorisme, (b) Exemple de màscara de la segona part de l'algorisme amb les mateixes dimensions que la imatge però amb tots els valors igual a 0.	58
4.9	Píxel d'inici, en color taronja, per a la segona part de l'algorisme de segmentació.	58
4.10	A la mateixa posició del píxel inicial, es canvia l'etiqueta 0 per la de 1.	59
4.11	Màscara amb l'etiqueta igual a 1 als nous píxels.	60
4.12	Màscara amb l'etiqueta igual a 1 als nous píxels.	61
4.13	(a) (c) (e) Imatges originals de l'estructura 3D del ronyó, (b) (d) (f) Imatges resultants obtingudes a partir del codi de MATLAB	63
4.14	(a) (c) (e) Imatges originals de l'estructura 3D del cor, (b) (d) (f) Imatges resultants obtingudes a partir del codi de MATLAB	64
4.15	(a) (c) (e) Imatges originals de l'estructura 3D de la vèrtebra, (b) (d) (f) Imatges resultants obtingudes a partir del codi de MATLAB	65
4.16	Punts finals del contorn, en vermell, de l'estructura del cor.	66
4.17	Punts finals del contorn, en vermell, de l'estructura del ronyó.	67
4.18	Punts finals del contorn, en vermell, de l'estructura de la vèrtebra.	67

1 Introducció

L'Enginyeria biomèdica és una disciplina que intenta connectar el forat que existeix entre l'enginyeria i la medicina. L'enginyeria biomèdica consisteix en l'aplicació dels principis i dels conceptes de disseny de l'enginyeria a la medicina per tal de solucionar els problemes que es puguin presentar i per millorar els mètodes de prevenció, diagnòstic, monitoratge, tractament i rehabilitació. L'Enginyeria biomèdica ha esdevingut, també, una activitat socioeconòmica estratègica amb un gran impacte a la medicina moderna i és una de les branques de l'enginyeria amb més ràpid creixement.

Dintre de l'enginyeria biomèdica, hi ha molts camps que es troben en constant expansió: control automàtic i adaptatiu, biomaterials, enginyeria clínica, biomecànica, entre d'altres. De tots els camps, un dels que destaquen és la imatge mèdica. Àrea en la qual es centra el present treball.

1.1 Objectius i abast del treball

Aquest treball es troba en el context del treball de tesi del codirector del mateix que es centra en el registre d'una seqüència d'imatges 2D d'un objecte amb un model 3D d'aquest en temps real. En aquest sentit el principal objectiu del projecte consistia en el disseny d'un codi en llenguatge de programació MATLAB que sigui capaç de portar a terme la segmentació d'una sèrie d'imatges biomèdiques donades. A més, donat que el context del projecte era obtenir un registre en temps real, un altre objectiu era l'optimització d'aquest codi de tal forma que duguí a terme aquesta segmentació en la menor quantitat de temps possible.

En quant a l'abast del projecte, l'objectiu principal és que el codi proposat sigui capaç de segmentar més d'un 90% del conjunt d'imatges donades. En aquest cas, considerarem que s'ha segmentat bé la imatge quan s'obtingui un contorn continu

en la seva totalitat o discontinu en petites zones. El fet d'acceptar contorns que no són continus en la seva totalitat és degut a que durant la segona part de l'algorisme, aquests petits buits al contorn no afectaran al resultat final ja que es reduirà el nombre de punts ja existents que conformen el contorn i s'obtindrà com a resultat el mateix contorn però amb el nou nombre de punts que nosaltres haguem designat prèviament. Les imatges que quedaran totalment descartades seran aquelles en les quals no es distingeixi la forma original de l'objecte, és a dir, aquelles en les quals el contorn deixi de ser continu en zones molt extenses i aquelles en les que no apareixi cap mena de contorn.

El món de la segmentació d'imatges és una àrea en constant expansió i hi ha nombroses tècniques que tenen una finalitat comú: extreure les característiques d'interès de la imatge. Aquest concepte tant senzill d'entendre esdevé un dels grans reptes de la visió per ordinador. Les imatges biomèdiques de les quals es volen extreure característiques són imatges que presenten molts problemes a l'hora d'obtenir una part en concret de la imatge: hi ha moltes zones de la imatge que comparteixen característiques com el color, la intensitat i la forma, entre d'altres. Aquest fet suposa que sigui necessària l'aplicació de més d'una tècnica de segmentació i que sigui necessari la contemplació de molts paràmetres per tal de poder aproximar-se a la segmentació desitjada.

Per aquest mateix motiu, per a l'avaluació d'aquests mètodes, en aquest projecte s'ha treballat amb imatges on la regió d'interès a segmentar correspon a la d'una estructura en 3D (cor, vèrtebra i ronyó) sobre un fons força homogeni. A partir dels resultats obtinguts, una línia futura de treball seria la millora de les prestacions de l'algorisme per tal de poder operar amb imatges més complexes.

2 Imatges Biomèdiques

2.1 Visió per ordinador

Els humans utilitzen el sentit de la vista i el cervell per entendre l'entorn que els envolta. La visió per ordinador és una disciplina científica que tracta d'aconseguir que els ordinadors obtinguin un alt nivell d'enteniment a partir d'imatges o de vídeos, és a dir, proporcionar-los amb la capacitat que tenen els humans.

El procés de la visió humana consisteix en que una imatge travessa l'ull i es projecta a la retina, la qual porta a terme una anàlisi molt elemental i l'envia al cervell perquè el còrtex visual executi una anàlisi molt més exhaustiva. A continuació, aquesta informació és enviada a la resta del còrtex que la compara amb tot el que ja reconeix, classifica els objectes que reconeix i les seves dimensions i finalment, a partir d'aquesta interpretació, es poden prendre decisions per efectuar accions concretes. Un exemple seria el reconeixement d'una pilota de futbol que es troba a un prestatge amb altres pilotes d'altres esports. Es portaria a terme tot el procés descrit prèviament i, en aquest cas, la resposta seria agafar la pilota que correspon a l'esport que volem practicar. Aquest procés és molt ràpid (una petita fracció de segon), amb gairebé gens d'esforç i amb molt petites probabilitats d'error. Així que, vist l'exemple i explicat el procés, recrear la visió que posseeixen els humans no tan sols és un repte molt difícil, sinó que implica una gran quantitat de passos que depenen l'un en l'altre.

Les tasques de la visió per ordinador inclouen l'adquisició, el processament, l'anàlisi i la comprensió d'imatges digitals i l'extracció de dades per a produir informació numèrica. A la visió per ordinador, es busca que aquesta extracció de dades es produïxi de forma automàtica [2].

Hi ha nombroses aplicacions de la visió per ordinador:

- Agricultura
- Robòtica
- Reconeixement de caracters
- Reconeixement facial
- Restauració de imatges
- Anàlisi de imatges mèdiques
- Monitoratge de la contaminació
- Control de processos

2.2 Tipus d'imatges

Per tal de poder processar i analitzar una imatge cal que aquesta sigui interpretada com una funció matemàtica. Aquesta imatge tindrà una quantitat finita de punts (píxels) on a cadascun d'ells li correspondran unes coordenades i un valor d'intensitat. Aquest valor variarà segons el tipus d'imatge que s'estigui tractant:

2.2.1 Imatges RGB

Una imatge RGB és una imatge composta per tres plans que corresponen als tres canals d'intensitat dels colors primaris de la llum (RED, GREEN i BLUE) on el color de cada píxel és determinat per la combinació de les intensitats de la posició del píxel a cadascun dels plans. Es basa en la síntesi additiva, és a dir, en la representació d'un color a partir de la suma dels tres colors primaris. Aquest tipus d'imatges també són conegudes com "truecolor images" ja que són emmagatzemades com a imatges de 24 bits (els 3 canals són de 8 bits cadascun) i això provoca que hi hagi la possibilitat de representar més de 16 milions de colors; una representació prou aproximada a la realitat [3]. La superposició dels histogrames dels tres canals

2.2.2 Imatges de intensitat (Escala de grisos)

D'altra banda també existeixen les anomenades imatges d'intensitat. Aquestes imatges, a diferència de les imatges RGB, només consten d'un canal. En aquest canal es representen les intensitats de cadascun dels píxels i per tant, a cada píxel només li correspon un valor.

Els valors de les intensitats dels diferents píxels d'una imatge de 8 bits es distribueixen en un interval que va de 0 a 255.

2.2.3 Imatges Binàries

Les imatges binàries, al igual que amb les imatges d'intensitat, només consten d'un canal. La diferència entre aquests dos tipus resideix en el número de valors que pot prendre un píxel. En el cas d'una imatge d'intensitat, el píxel pot tenir qualsevol valor que es trobi dins de l'interval definit mentre que a les imatges binàries, el píxel només pot tenir dos valors possibles.

Un mètode genèric per binaritzar imatges es basa en, tal i com es pot observar a la Figura 2.1, definir un punt llindar a la imatge en escala de grisos on a partir del qual tots els píxels amb un valor superior al del llindar passaran a tenir un valor mentre que els que es trobin per sota d'aquest passaran a tenir-ne un altre.

Normalment, aquests dos valors es representen d'una manera abstracta com un valor 0 (com l'absència, negre) o bé 1 (com la presència, blanc), sense cap fracció entremig. Aquesta notació és utilitzada a molts articles acadèmics però no implica que es defineixin el "negre" i el "blanc" com a colors en si ja que, a vegades, l'escala és invertida.

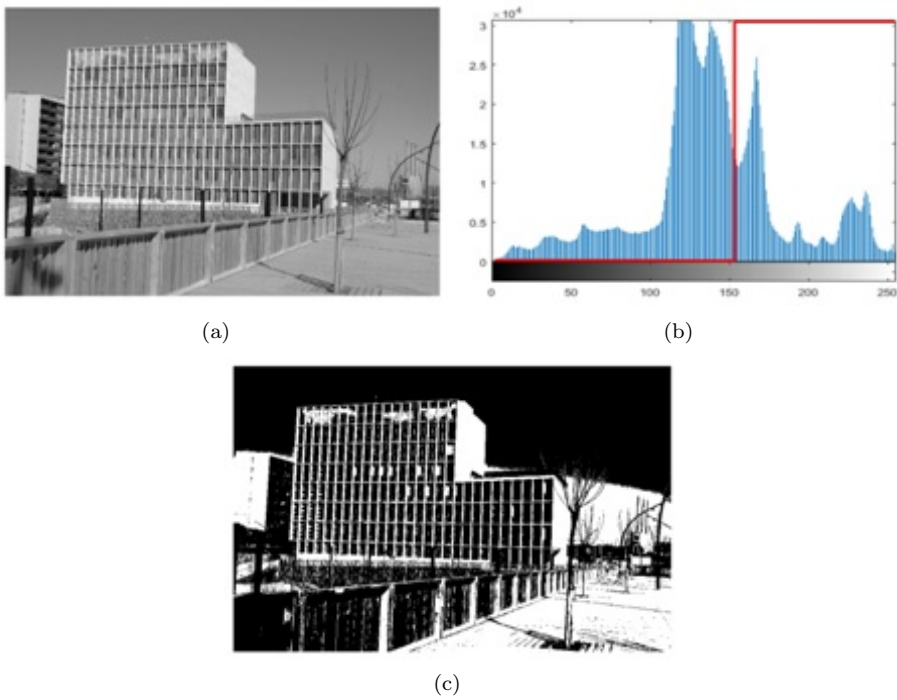


Figura 2.1: (a) Imatge Original (imatge RGB), (b) Imatge original en escala de grisos, (c) Histograma de la imatge en escala de grisos amb representació del llindar per a la binarització, (d) Imatge original binaritzada.

2.3 Modalitats d'imatges mèdiques

L'objectiu de les imatges mèdiques és crear representacions visuals de l'interior del cos humà per portar a terme anàlisi clíniques o bé, per a representar la funció de diferents òrgans o teixits, diagnosticar i tractar malalties.

Existeixen diferents tipus d'imatges mèdiques [4]: Raigs-X (Radiografia, Fluoroscòpia, TAC), Ultrasons, RMN (Ressonància magnètica nuclear), PET (tomografia d'emissió d'electrons per les sigles en anglès de positron emission tomography), SPECT (Tomografia computada d'emissió de fotons únics per les sigles en anglès Single-photon emission computed tomography), imatges d'ultrasons i termografia.

2.3.1 Raigs-X

Els raigs X són ones electromagnètiques amb una longitud d'ona entre els 0.01 i els 10 nanòmetres amb al capacitat de travessar cossos opacs i que al interactuar amb la matèria produeix la ionització dels seus àtoms. La tècnica més comú en la producció dels raigs-X és el bombardeig d'un ànode metàl·lic amb un flux d'electrons.

Tot i que els raigs-X siguin un molt bon mètode per a obtenir imatges definides, la radiació utilitzada pot danyar les cèl·lules, incloent les molècules d'ADN i això pot derivar en un càncer [5]. Tot i aquest fet, les radiacions que es reben amb les tècniques prèvies són variables. Per exemple, mitjançant una radiografia, la dosi de radiació a la que s'exposa el cos del pacient és la mínima si es compara amb qualsevol de les altres tècniques en les quals s'utilitzen raigs-X. A una TAC, l'objecte d'estudi pot rebre de 100 a 1000 vegades de radiació més que amb la radiografia [6].

2.3.1.1 Radiografia

Aquesta tècnica consisteix en radiar un cos amb radiació electromagnètica produïda per un generador de raigs-X. Aquests raigs-X interaccionen amb la matèria de diverses formes: efecte fotoelèctric, dispersió de Rayleigh, dispersió de Compton, interaccions amb el nuclis dels àtoms, etc [4].

Una quantitat d'aquests raigs serà absorbida per l'objecte, depenent de la seva densitat i composició i els raigs que passin a través de l'objecte poden ser capturats de manera directa o indirecta. L'absorció dels raigs-X dependrà del tipus de material o teixit ja que és indirectament proporcional a la densitat i aquest fet permet la visualització de l'interior del cos humà. En el cas del cos humà, les diferents absorcions per part dels teixits que ho componen permetran elaborar una imatge de la seva estructura interior. Un exemple de la imatge resultant obtinguda seria com la que es pot observar a la Figura 2.2. Capturar els raigs-X de forma directa implica que es formi la imatge directament amb la interacció dels raigs-X amb algun mitjà com per exemple una pel·lícula sensible a aquest tipus de radiació. A la detecció indirecta, s'utilitza un material intermedi amb el qual es produirà un nou tipus d'energia amb què posteriorment es formarà la imatge, com per exemple una pantalla de fòsfor que produirà llum visible a partir la l'absorció dels raigs-X i després la utilització d'algun tipus de fotodetector.



Figura 2.2: Imatge radiològica del tòrax. (Font: commons.wikimedia.org)

2.3.1.2 Fluoroscòpia

Aquesta és una tècnica utilitzada a medicina per a obtenir imatges a temps real de les estructures internes dels pacients. Durant aquesta tècnica s'utilitzen raigs-X de baixa intensitat, per aquest motiu s'utilitza, per exemple un fotomultiplicador per tal d'intensificar la imatge. El principi d'aquest fotomultiplicador es mostra a la Figura 2.3.




Figura 2.3: Principi de funcionament dels fotomultiplicadors. (Font: Sense-Pro.org)

Les imatges obtingudes a partir de la tècnica de la fluoroscòpia, com la que es pot observar a la Figura 2.4, s'utilitzen en estudis de:

- Tracte gastrointestinal (amb algun medi de contrast subministrat a l'objecte d'estudi prèviament)
- Cirurgia ortopèdica. Serveix com a guia per a la implementació de peces mecàniques
- Angiografia de la cama, cor i vasos sanguinis cerebrals
- Implantació de dispositius pel control dels ritme cardíac, marcapassos, desfibril·ladors implantables i dispositius de sincronització cardíaca




Figura 2.4: Fluoroscòpia abdomen i pelvis. (Font: SOCHRADI)

2.3.1.3 TAC (Tomografia Axial Computeritzada)

La tomografia axial computeritzada és un mètode de diagnòstic per imatge que s'utilitza per obtenir imatges detallades d'òrgans, ossos, teixits tous i vasos sanguinis. Amb aquest mètode s'obtenen imatges que corresponen a talls o seccions d'objectes anatòmics amb fins diagnòstics. Aquestes imatges que són generades poden dividir-se en múltiples plans i poden fins i tot ser reconstruïdes per tal de generar imatges tridimensionals que poden ser visualitzades a un monitor, impreses o bé, transferides a un altre medi electrònic.




Figura 2.5: Tomografia Axial Computeritzada d'un crani. (Font: Centro Diagnostico Ipocrates)

En lloc d'obtenir una imatge de projecció, com a la radiografia convencional, la TAC obté múltiples imatges, tal i com es pot observar a la Figura 2.5, al portar a terme moviments de rotació al voltant dels cos amb la font de raigs-X i amb els detectors de radiació.

El seu principi de funcionament consisteix en una emissió d'un feix de raigs X que incideix sobre l'objecte d'estudi, Figura 2.6. La radiació que no hagi estat absorbida serà recollida pels detectors. Posteriorment, es canvia la posició de l'emissor del feix de raigs-X. Aquest nou espectre obtingut també serà recollit pels detectors. L'ordinador, suma les imatges calculant una mitjana i així successivament: els detectors recullen aquest nou espectre, el sumen als anteriors i calculen una mitjana amb les dades. Aquest procés serà iteratiu fins que el tub emissor de raigs-X i els detector hagin donat una volta completa al voltant de l'objecte anatòmic d'estudi. El resultat que s'obtindrà serà una imatge tomogràfica definitiva i fiable.




Figura 2.6: Principi de funcionament de la Tomografia axial computeritzada (Font: © Encyclopædia Britannica, Inc.)

La Tomografia Axial Computeritzada és sovint el millor mètode per a detectar molts diversos tipus de càncers ja que les imatges permeten que els professionals mèdics confirmen la presència o no de tumors i determinar la seva localització i mida.

2.3.2 RMN (Ressonància Magnètica Nuclear)

A la ressonància magnètica nuclear, a diferència dels raigs-X, s'utilitzen camps magnètics molt forts, ones de radio i gradients per a generar imatges del cos. Aquesta tècnica és molt semblant a la Tomografia Axial Computeritzada, però a diferència d'aquesta, no s'utilitzen raigs-X. El fet de no utilitzar els raigs-X suposa que no s'exposa el cos d'estudi a energia ionitzant i, per aquest motiu, que la tècnica de la RMN sigui preferible per casos més delicats com pot ser el primer trimestre de gestació durant l'embaràs.




Figura 2.7: Estructura d'un escàner de ressonància magnètica.(Font: MRI SCAN)

El principi de funcionament d'aquesta tècnica consisteix en l'aplicació temporal d'un camp magnètic constant d'alta intensitat creat per un imant, Figura 2.7. La intensitat i el moment magnètic dels diferents nuclis determinarà la seva freqüència de ressonància. Aquest camp magnètic alinea els moments magnètics dels nuclis atòmics en dues direccions: una paral·lela i una antiparal·lela. A la paral·lela els vectors apunten cap a un mateix sentit mentre que amb l'antiparal·lela els sentits són oposats. El següent pas consisteix en emetre radiació electromagnètica a una determinada freqüència de ressonància. Degut a l'estat dels nuclis, alguns passaran d'estat paral·lel a estat antiparal·lel (que és un estat amb una major energia) i finalment, acabaran en estat paral·lel perdent l'energia que havien guanyat (en forma de fotons) i aquests fotons seran detectats per tres bobines de gradient. Com el camp magnètic és constant, els nuclis que posseeixin el mateix moment magnètic tindran la mateixa freqüència

de ressonància. Amb només tres bobines es pot assignar a cada regió de l'espai una freqüència de ressonància diferent, fent possible la determinació de la regió de l'espai de la que prové [7].

Aquesta tècnica també comporta una sèrie de desavantatges en comparació amb la Tomografia Axial Computeritzada: els escanejos que es porten a terme a la Ressonància Magnètica Nuclear comporten una inversió major de temps, emeten un so molt fort i normalment, és necessari que el cos d'estudi entri a un tub molt estret, fins i tot exacerbant la sensació de claustrofòbia del subjecte . Aquests fets poden provocar que, tot i que aquesta tècnica no sigui ionitzant, s'utilitzi el TAC per tal d'obtenir la mateixa informació. A dia d'avui, existeixen escàners "oberts" de ressonància magnètica, com el que es pot observar a la Figura 2.8, per a aquells pacients que pateixin de claustrofòbia. Aquests, al ser oberts, posseeixen unes intensitats de camp menors.




Figura 2.8: Equip obert de ressonància magnètica. (Font: Broadway Imaging Centre)

2.3.3 Medicina Nuclear

La medicina nuclear utilitza petites quantitats de materials radioactius anomenats radiotraçadors que típicament, es subministren al pacient via sanguínia, oral o inhalatòria. Els radiotraçadors viatgen a través de l'àrea que es vol examinar i emeten energia en forma de rajos gamma que són detectats per una càmera especial, una gammacàmera [3].

La medicina nuclear és coneguda com a “endoradiologia” ja que, a diferència dels raigs-X, la radiació és emesa pel cos d'estudi i no és generada per fonts exteriors. Una altra diferència que resideix entre aquestes dues modalitats és que els escanejos portats a terme a la medicina nuclear no volen donar èmfasi a l'estructura de l'interior del cos sinó a la funció que aquestes parts porten a terme.

Cal esmentar que la medicina nuclear es tracta d'un tipus d'obtenció d'imatges no invasiu però sí que exposa a l'individu a radiació ionitzant. A la medicina nuclear, els dos mètodes més comuns són la tomografia d'emissió d'electrons (PET) i la tomografia computada d'emissió de fotons únics (SPECT).

2.3.3.1 PET (Tomografia d'Emissió d'Electrons)

Aquesta és una tècnica no invasiva que és utilitzada per a visualitzar processos metabòlics del cos.

A aquesta tècnica es mesura la producció de fotons gamma, que s'obtenen després de la destrucció d'un positró. El PET, es basa en detectar i analitzar la distribució tri-dimensional que adopta un radio fàrmac dins del cos d'estudi, administrat prèviament a través d'una injecció intravenosa.

Els fotons gamma són el producte de l'anihilació (és el procés que ocorre quan una partícula col·lideix amb la seva antipartícula i donen com a resultat energia que es manifesta com l'emissió de noves partícules o de radiació [8] entre un positró que és emès pel radiofàrmac i un electró del cos del pacient. Aquesta anihilació dóna lloc a dos fotons que seran radiats en una mateixa direcció però amb sentits oposats, Figura 2.9. Per tal de poder conformar la imatge, cal que els receptors detectin els dos fotons alhora, com es pot observar a la Figura 2.10, i que compleixin els següents criteris:

- Els fotons han de provenir d'una mateixa direcció però amb sentits oposats, formant un angle de 180° entre ambdues trajectòries.
- La seva energia ha de superar un llindar mínim que garanteixi que durant el seu trajecte, els fotons no han patit dispersions energètiques importants.




Figura 2.9: Principi d'anihilació positró-electró. (Font: Centre for Astrophysics and Supercomputing - Swinburne University)




Figura 2.10: Esquema d'adquisició del PET. (Font: Jens Maus)

2.3.3.2 SPECT (Tomografia Computada d'Emissió d'Electrons)

La tècnica computada d'emissió de fotons únics (SPECT) és molt similar a les tècniques prèvies que es porten a terme a la medicina nuclear però amb la diferència que aquesta tècnica és possible obtenir informació 3D.

Per poder efectuar una tomografia d'aquest tipus, cal injectar al pacient un producte radioactiu que emet radiacions gamma, constituïdes per fotons, que és el que es mesura.

Amb la gamma càmera s'obtenen moltes projeccions (imatges en 2D) des de múltiples angles. Després d'obtenir totes les projeccions, s'utilitza un algorisme que porta a terme una reconstrucció tomogràfica, obtenint informació 3D.

Per tal d'obtenir les projeccions, la gamma càmera rotarà al voltant del pacient, Figura 2.11. Per a obtenir una reconstrucció òptima es porta a terme una volta completa de 360° , registrant la radiació cada 3° - 6° . L'obtenció de cada projecció sol trigar entre 15 i 20 segons, el que implica que el temps necessari per a portar a terme una volta sencera serà de 15 a 20 min. Per tal d'optimitzar el temps d'adquisició, hi ha variants de la gamma càmera convencional que consten de més d'un receptor. Una gamma càmera amb dos receptors només necessitarà fer una rotació de 180° , permetent que s'adquireixin dos projeccions al mateix temps. Gamma càmeres de tres receptors també són comunes i impliquen que la rotació sigui només de 120° , fent que el temps necessari per a portar a terme l'adquisició de totes les projeccions sigui molt menor.



Figura 2.11: Un pacient durant un SPECT on un parell de gammacàmeres giren al seu voltant. (Font: Wikipedia.org)

El principi de funcionament d'ambdues tècniques és molt semblant, la principal diferència consisteix en que a la tècnica PET es detecten un parell de fotons mentre que a la tècnica SPECT es detecta només un fotó. Aquest fet provoca que les imatges obtingudes amb la segona tècnica siguin menys precises però, com a avantatge, cal dir que no necessita que el traçador emeti positrons.

2.3.4 Imatges Òptiques

Tal i com passa amb els raigs-X, les imatges òptiques també serveixen per veure l'interior de cos però amb la diferència de que les imatges òptiques no utilitzen radiació ionitzant. Les imatges òptiques utilitzen la llum visible que incideix als diferents teixits i que és reflexada per obtenir imatges detallades d'òrgans i teixits, així com per obtenir imatges d'estructures més petites com cèl·lules i molècules. En resum, les imatges òptiques es generen per la reflexió dels raigs de llum.

A dia d'avui, hi ha una gran varietat de tècniques que utilitzen la llum visible per obtenir imatges de dins del cos, teixits o cèl·lules [9]:

2.3.4.1 Endoscòpia

Una endoscòpia és utilitzada en medicina per observar l'interior del cos [10]. És el mètode més conegut i el més senzill de portar a terme. Un endoscopi consisteix en un tub flexible amb una petita càmera a l'extrem [11] que s'introdueix dins del cos del pacient mitjançant les entrades de les que ja es disposen o bé s'introdueixen per petits talls que es realitzen a la zona d'interès.

2.3.4.2 TCO (Tomografia de Coherència Òptica)

Aquesta tècnica és una tècnica no invasiva que utilitza ones de llum amb una penetració d' aproximadament 2-3 mm [12]), del teixit o del material que es tracti, amb una resolució axial i lateral de l'escala micromètrica. Ara, la TCO és una tècnica d'imatge àmpliament acceptada, especialment en oftalmologia i en altres aplicacions biomèdiques. L'aplicació més estesa, en oftalmologia, és la d'obtenció d'imatges de la retina amb un gran detall i amb una alta resolució. S'utilitza una combinació de llums que obtingudes a partir de diferents receptors per aconseguir una major resolució. Durant el procés, es poden identificar detalls anormals a nivell gairebé cel·lulars.

2.3.4.3 Imatges fotoacústiques

Durant el procés de l'obtenció d'aquestes imatges, s'envien impulsos no ionitzants de làser als teixits del pacient, Figura 2.12. Una part de la energia serà absorbida i convertida en calor, fet que provocarà que s'expandeixin els teixits i les ones que es generen com a resposta (emissió ultrasònica de banda ampla) són detectades per transductors ultrasònics permetent obtenir imatges de la seva estructura.




Figura 2.12: Il·lustració esquemàtica de la imatge fotoacústica. (Font: Wikipedia.org)

2.3.4.4 TOD (Tomografia Òptica Difusa)

És un procediment pel qual s'utilitzen ones de llum amb l'objectiu de crear imatges tridimensionals dels teixits de l'interior del cos humà. Un làser de llum infraroja es col·loca al cuir cabellut i aquesta passa a través del cervell sense danyar-lo. Aquesta tècnica es pot utilitzar per a observar el flux de sang que arriba als teixits i mesurar els canvis en la quantitat d'oxigen dels mateixos [13]. La TOD és especialment útil per examinar teixit tou, com el teixit de la mama i de l'encèfal.

2.3.4.5 Espectroscopia Raman

El llum làser interactua amb les vibracions moleculars del material que s'examina i els canvis en energia es mesuren per a revelar informació sobre les propietats del material. A medicina, s'utilitzen els analitzadors de gas Raman per a monitorar les barreges de gas anestèsic durant una cirurgia.

2.3.4.6 Microscòpia de super-resolució

La microscòpia de super-resolució es basa en tècniques que activen selectivament les molècules fluorescents per tal de mapejar la posició amb una precisió de fins a 10 vegades superior a la de la microscòpia fluorescent convencional [14]. Els microscopis de super-resolució i dels nanoscopis superen el límit de difracció de la llum i permeten als investigadors estudiar estructures subcel·lulars, com les que es poden observar a la Figura 2.13, amb major detall que amb el que es pot arribar a aconseguir amb un microscopi confocal estàndard. Amb aquesta tècnica és possible estudiar a nanoescala tant la morfologia com la dinàmica subcel·lular.




Figura 2.13: Estructures cel·lulars visualitzades amb un microscopi de super-resolució. (Font: ScienceMag.org)

2.3.5 Ultrasons

Aquesta tècnica de diagnosi per imatge consisteix en l'aplicació d'ones de so amb freqüències més altes que el límit de l'espectre audible de l'ésser humà (20,000 Hz). És una tècnica no invasiva i la tecnologia emprada és similar a la que fan servir el sonar i el radar [15], detectant objectes i mesurant distàncies. Les ones d'ultrasò són reflectides

a les superfícies dels teixits amb diferent densitat i aquesta reflexió és proporcional a la diferència d'impedància [16] (és la mesura de l'oposició que presenta un circuit a un corrent quan se li aplica una tensió).

A diferència d'altres tècniques de imatge, els ultrasons no utilitzen radiació, motiu pel qual és el mètode preferent per a veure el desenvolupament del fetus durant l'embaràs [15].

Un tècnic d'ultrasons, aplica un lubricant especial a la pell de la zona que es vol examinar, Figura 2.14 (a). Això, a més de disminuir notablement la fricció entre el transductor i la pell del pacient perquè el tècnic pugui moure el transductor amb total llibertat té un altre objectiu que és evitar que hi pugui haver aire entre la sonda i el cos, ja que l'aire esmorteiria la senyal i no es podria visualitzar res. El feix d'ultrasò procedeix d'oscil·lacions mecàniques de nombrosos cristalls en un transductor, que està excitat per polsos elèctrics. Les ones de so s'envien des del transductor i es propaguen a través dels diferents teixits. Després de fer el recorregut d'anada, tornen al transductor com a ecos reflectits. Els ecos retornats es converteixen de nou en impulsos elèctrics pels cristalls transductors i es presenten posteriorment per formar la imatge d'ultrasò presentada a la pantalla. Una imatge resultant obtinguda amb el mètode d'ultrasons seria com la que es pot observar a la Figura 2.14 (b).



Figura 2.14: (a) Tècnic realitzant la tècnica d'ultrasons a una pacient embarassada, (b) Imatge del fetus obtinguda amb la tècnica d'ultrasons (Font: (a) Dr. José F. De Leon, (b) UTSouthwestern Medicine)

Amb aquesta tècnica, no només és possible l'obtenció d'imatges en dues dimensi-

ons sinó que també són possibles les imatges en tres i quatre dimensions. Amb tres dimensions s'obté una imatge en tres dimensions de l'òrgan o teixit d'interès, o bé del fetus en el cas d'una ecografia a una dona embarassada; mentre que, en quatre dimensions, s'obté un vídeo a temps real.

L'obtenció d'imatges 3D, Figura 2.15, i 4D són considerades tan segures com la de les imatges en 2D perquè estan compostes per seccions d'imatges en dues dimensions. Tot i això, en el cas de dones embarassades, els professionals no recomanen fer escàners de tres i quatre dimensions com un simple recordatori ja que s'està exposant al fetus a més ultrasons dels que són estrictament necessaris.



Figura 2.15: Imatge en 3D d'un fetus obtinguda amb ultrasons. (Font: Baby Scan Clinic)

2.3.6 Termografia

Les imatges obtingudes mitjançant aquesta tècnica són imatges que mostren la radiació emesa pels diferents objectes que apareixen a la imatge. Segons la llei de la radiació del

cos negre, tots els objectes que estiguin per sobre del zero absolut (-273°K) emetran una radiació electromagnètica; així doncs, la termografia permet veure l'entorn sense la necessitat de llum visible.

La càmera tèrmica permet diferenciar variacions en la temperatura, així que és molt útil per a diferents aplicacions. Un exemple seria l'ús que porten a terme els bombers i consisteix en poder veure a través del fum, localitzar a persones i a localitzar el punt d'inici del foc. La termografia permet detectar molt fàcilment, a qualsevol hora del dia, a éssers vius de sang calenta ja que a major temperatura, major és la radiació que el cos desprèn, Figura 2.16.

Una altra aplicació seria la utilització de la termografia com a mètode de protecció i control ja que a l'any 2009 hi va haver una pandèmia del virus H1N1 i un dels símptomes del virus era un increment en la temperatura corporal. Amb aquesta premissa, els diferents governs van col·locar càmeres tèrmiques a aeroports per tal de controlar als passatgers, Figura 2.16, i descartar que estiguessin infectats [17]. Cal esmentar que aquesta tècnica és molt emprada en medicina veterinària i en la detecció d'al·lèrgies [18].




Figura 2.16: (a) Imatge tèrmica d'un individu, (b) Imatge d'una càmera tèrmica i d'un monitor col·locats a la terminal d'un aeroport de Grècia. (Font: (a) Digitalrev, (b) Wikipedia.org)

Algunes de les aplicacions més comunes de la termografia a la medicina són:

- Patologies de mama

Possiblement aquesta sigui l'àrea de més aplicació de la Termografia mèdica. Les patologies més examinades són: el càncer de mama, els tumors benignes, la mastitis i la malaltia fibroquística de les mames.

En el cas de la detecció del càncer, aquest mètode es basa en un concepte molt senzill: un tumor no és més que un conjunt de cèl·lules que posseeixen una “immortalitat replicativa”, un terme utilitzat pel fet que es poden dividir moltes vegades més que una cèl·lula somàtica normal. En general, les cèl·lules humanes poden experimentar de 40 a 60 rondes de divisió abans de perdre la capacitat de dividir-se, “envellir” i finalment morir [19]. Per tal de poder subministrar oxigen a les cèl·lules tumorals, aquestes són capaces de portar a terme una angiogènesis tumoral que consisteix en la formació de nous vasos sanguinis a partir dels vasos preexistents. Aquest fet provocarà que hi hagi una major circulació de sang a través d'aquesta nova massa de cèl·lules ja que les cèl·lules cancerígenes tenen un metabolisme més elevat que les altres cèl·lules autosòmiques i necessiten aquests nous vasos per obtenir més glucosa i oxigen.

Normalment, es comparen les temperatures de les dues mames. Una temperatura anormal en alguna d'elles pot ser detectada fàcilment.

- Malalties vasculars extracranials

Els vasos sanguinis a la cara i al crani són molt molt fàcils de visualitzar amb la termografia ja que es troben ocupant un espai molt reduït entre la pell que recobreix el crani i els ossos que conformen el crani. Que siguin tan fàcils de visualitzar permet que, mitjançant la termografia, es puguin diferenciar diferents tipus de mals de cap (migranya, cefalea, dolors relacionats amb l'espina cervical), i de les lesions dels nervis facials que puguin derivar d'un accident de cotxe, per exemple.

- Malalties vasculars de les extremitats inferiors

La termografia permet, en aquests casos, detectar la presència de trombosis venoses profundes o d'altres malalties relacionades amb els vasos sanguinis de

les extremitats inferiors, Figura 2.17. Aquest fet permet detectar, de manera indolora i segura, possibles futures malalties que podrien ésser mortals si no fossin detectades amb suficientment temps d'antelació.




Figura 2.17: Observació de les extremitats inferiors d'un pacient mitjançant termografia. (Font: Science Direct)

A més d'aquestes aplicacions de la termografia en medicina també es troben altres àrees on la tomografia s'aplica obtenint bons resultats. Algunes d'aquestes àrees serien les disfuncions respiratòries, desordres digestius, desordres urinaris, desordres cardiovasculars i circulatoris, disfuncions limfàtiques, desordres de l'aparell reproductor, entre d'altres.

3 Segmentació

3.1 Què és la segmentació

La segmentació d'imatges és el procés que consisteix en dividir una imatge en diferents parts o objectes. L'objectiu d'aquesta divisió és el de simplificar la imatge per tal de fer més fàcil la seva anàlisi mitjançant la localització d'objectes o bé dels contorn dels mateixos dins de la imatge. La segmentació es porta a terme fins a un nivell de subdivisió en el qual s'aconsegueixi aïllar regions o objectes d'interès. Durant aquest procés s'assigna una etiqueta a diferents píxels que comparteixen determinades característiques (color, intensitat, textura...) per tal de que la seva visualització a la imatge resultant sigui semblant.

Existeix un gran nombre d'aplicacions pràctiques de la segmentació d'imatges [1]:

- Localització d'objectes en imatges satèl·lit
- Sistemes de control de tràfic
- Detector d'empremtes digitals
- Proves mèdiques (cirurgia guiada per ordinador, localitzacions de tumors i altres patologies, entre d'altres)
- Visió per ordinador (reconeixement facial, robòtica, detecció d'objectes, detecció de vianants...)

Un cop finalitzada la segmentació, la imatge obtinguda necessita complir els següents cinc requisits [22] per tal que aquesta sigui bona:

- **Integritat:** La segmentació ha de ser completa, és a dir, cada píxel ha de pertànyer a una regió.

- **Connectivitat:** Els píxels que pertanyin a una mateixa regió han d'estar connectats d'alguna manera.
- **Disjunció:** Les diferents regions no poden compartir cap píxel.
- **Semblança:** Els diferents píxels que conformen una mateixa regió han de compartir una o més propietats comunes.
- **Segmentació:** Els píxels de regions diferents han de satisfer diferents propietats, ja que tal i com s'esmenta al requisit de "Disjunció", les regions no poden tenir píxels compartits.

3.2 Estat de l'art. Tècniques de segmentació

Les tècniques de segmentació es solen basar en dos tipus diferents d'aproximacions. Primer de tot, estan els mètodes que intenen determinar la frontera entre les diferents regions per tal de dur a terme la segmentació. Normalment, aquests punts corresponen amb els punts de la imatge on hi ha un canvi abrupte en una determinada característica. I segon, els mètodes que intenten agrupar els píxels per àrees o regions que compleixen una o varies característiques semblants.

Així mateix, generalment per tal de dur a terme una correcte segmentació s'aplicaran diferents tècniques de les descrites a continuació per tal d'aprofitar els avantatges de cadascuna d'elles.

Els mètodes de segmentació més habituals són els següents:

3.2.1 Mètodes de llindar. (Thresholding Approaches)

És el mètode més simple per a segmentar imatges. Aquest mètode consisteix en el reemplaçament del valor de cadascun dels píxels d'una imatge segons la seva intensitat. Si aquesta intensitat és menor que un determinat llindar, el píxel passarà a tenir un determinat valor mentre que els píxels que tinguin una intensitat major a la determinada pel llindar passaran a tenir-ne un altre, és a dir, amb un simple llindar la imatge en escala de grisos passa a ser una imatge binaritzada:

$$B = \begin{cases} 0 & \text{si } A(i, j) < \text{Llindar} \\ 1 & \text{si } A(i, j) \geq \text{Llindar} \end{cases} \quad (3.2.1)$$

on A és la imatge original en escala de grisos a la qual se li aplica el mètode, B és la imatge binaritzada obtinguda i on i, j són les coordenades del píxel.

La determinació d'aquest llindar pot ésser manual, l'usuari defineix el valor que tindrà, o bé pot obtenir-se de forma automàtica amb diferents algorismes. S'han proposat diverses tècniques per trobar el llindar adequat. Bàsicament, es poden classificar en llindar global, llindar local i llindar dinàmic.

A la tècnica de llindar global, el mateix llindar s'aplica a tota la imatge. Un exemple d'aquesta aplicació seria el mètode Otsu. Aquest assumeix que la imatge té dues classes de píxels. A partir de l'histograma de la imatge, calcula el llindar òptim que separarà les dues classes a l'histograma per aconseguir que la distància entre les seves variàncies sigui màxima.




Figura 3.1: Exemple d'un histograma òptim per a l'aplicació del mètode Otsu. (Font: MATLAB CORNER)

Aquest mètode consta de diferents limitacions entre les quals es troben la mida de l'objecte a segmentar, l'existència d'una molt petita variació entre les mitjanes dels dos conjunts de píxels, la similitud de les intensitats de l'objecte i del fons, entre d'altres. Una de les limitacions esmentades d'aquest mètode és la mateixa distribució de la imatge. Per a un rendiment òptim de l'algoritme, cal que l'histograma de la imatge que volem segmentar tingui una distribució bimodal i una vall molt pronunciada entre dos pic tal i com es pot observar a la Figura (3.1). Aquesta, per aquest mateix motiu, és la principal limitació que podem trobar a l'aplicar aquest mètode ja que hi ha molts casos en els quals no obtindríem aquesta distribució a l'histograma. Un exemple seria si l'objecte a segmentar té una àrea molt més petita que la que correspondria al fons o si, per exemple, l'objecte a segmentar i el fons tinguessin una intensitat similar ja que no es podria establir una diferència notable entre les seves dues variàncies.

Un altre mètode que també es basa en l'aplicació d'un llindar és l'anomenat Balanced Histogram Thresholding Method (BHT). Aquest mètode comparteix una gran similitud amb el mètode previ ja que la determinació del llindar també es basa en l'histograma de la imatge.

El mètode BHT s'inicia calculant l'histograma de la imatge. Un cop distribuïts els píxels en diferents rangs, es calcula el punt mig de l'histograma que s'utilitza com a punt de fulcre i s'observa quina de les dues bandes de l'histograma té un major pes

(correspondrà a la que tingui un nombre major de píxels). A la banda que sigui més pesada, s'eliminarà el rang de píxels més allunyats del fulcre. A partir d'ara el procés és iteratiu: es torna a moure el fulcre a la posició central de l'histograma, es calculen els pesos d'ambdues bandes i s'elimina el conjunt de píxels més allunyats del fulcre de la més pesada. Un cop finalitzat aquest procés s'obtindrà un valor que serà utilitzat com a llindar. A la Figura 3.2 es pot veure l'obtenció d'un llindar utilitzant aquest mètode.




Figura 3.2: Obtenció del llindar al Balanced Histogram Method. (Font: Wikipedia)

També es poden trobar tècniques on es troba el llindar local i que són especialment recomanables per a tractar imatges amb text on el fons és molt uniforme. En aquests algorismes, en lloc d'utilitzar un mateix valor de llindar per a tota la imatge, es calculen múltiples llindars per a cada píxel amb unes fórmules que tenen en compte la mitjana i la desviació estàndard de cada conjunt de píxels definits per una finestra que tindrà al píxel que volem calcular com a element central.

I finalment, hi ha una variable del mètode local anomenada mètode de llindar dinàmic, en el qual es defineix per a una zona d'un número N de píxels veïns, un valor de llindar adequat. En aquest cas, el valor del píxel que s'està tractant dependrà de si és major o menor que el llindar definit per a aquell conjunt de N píxels.

3.2.2 Tècniques de fronteres o contorns

Aquest tipus de mètodes es centren en detectar les fronteres o els contorns dels objectes de la imatge ja que en aquests punts hi ha un fort canvi en el valor de la intensitat. Per tal de determinar els contorns, es solen utilitzar mètodes del càlcul del gradient de la imatge i aleshores es defineixen com a contorns els punts que sobrepassen un cert valor llindar dins del gradient. Per tant, la segmentació s'obté al aplicar una tècnica de llindar sobre el gradient de la imatge.

El principal problema d'aquest tipus de tècniques és que en ocasions s'obtenen contorns que presenten discontinuïtats i aleshores és necessària la utilització d'altres mètodes per tal de completar aquests contorns.

3.2.2.1 Gradient + binarització

Calcular el gradient de la intensitat de la imatge és el més simple per a obtenir els contorns. El gradient d'una imatge correspon a un canvi direccional en la intensitat o en el color de la imatge. Les imatges obtingudes són creades a partir de la convolució de la imatge original amb una màscara en la direcció x (horitzontal) i en la direcció y (vertical) per tal de cobrir totes les direccions.

Matemàticament, el gradient d'una funció de dues variables és un vector bidimensional ens components del qual són les seves derivades parcials en les direccions horitzontal i vertical:

$$\nabla f = [g_x \quad g_y] = \left[\frac{\partial f}{\partial x} \quad \frac{\partial f}{\partial y} \right] \quad (3.2.2)$$

on

$\frac{\partial f}{\partial x}$ és la derivada de la funció respecte a x (gradient en la direcció x)

$\frac{\partial f}{\partial y}$ és la derivada de la funció respecte a y (gradient en la direcció y)

Un cop han estat calculades les imatges de gradient, els píxels amb valors de gradient que excedeixin un determinat llindar correspondran a píxels de contorn. Els contorns seran traçats en la direcció perpendicular a la direcció del gradient.

Hi ha una gran quantitat d'operadors de gradient: Sobel, Prewitt, Canny, Roberts, Intermediate, Central... però d'entre tots, l'operador de gradient més utilitzat és l'operador Sobel. A la Figura 3.3 (b) es pot veure el càlcul del gradient de la imatge (a). En el cas d'aquest operador, les màscares utilitzades per a la convolució amb la imatge original són de dimensions de 3x3 píxels. Si es defineix A com la imatge original i G_x i G_y com les imatges resultants que representen les aproximacions de les derivades parcials en les direccions horitzontal i vertical, aquestes es calculen com:

$$G_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} * A \quad \text{i} \quad G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ +1 & +2 & +1 \end{bmatrix} * A$$




Figura 3.3: Exemple d'una imatge obtinguda aplicant un filtre Sobel (Font: (a) EEBE, (b) MATLAB)

D'altra banda, l'operador Prewitt és considerat com un detector de contorns molt semblant al Sobel i és àmpliament utilitzat per a detectar els contorns tant verticals com horitzontals d'una imatge [20]. L'operador de Prewitt consisteix en un parell de màscares amb dimensions de 3x3 píxels:

$$G_x = \begin{bmatrix} -1 & 0 & +1 \\ -1 & 0 & +1 \\ -1 & 0 & +1 \end{bmatrix} \quad \text{i} \quad G_y = \begin{bmatrix} +1 & +1 & +1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}$$

En el cas de l'operador Roberts, aquesta va ser la primera tècnica de detecció de contorns i, a diferència dels operadors Sobel i Prewitt, les màscares no tenen una mida de 3x3 píxels, sinó que consisteixen en dues màscares de 2x2 píxels. Es tracta d'un operador que porta a terme operacions que són molt simples i que gairebé no requereix cap cost computacional. Un dels desavantatges de la mida de les màscares a l'operador Roberts és que aquest és molt més sensible al soroll que els dos previs.

$$G_x = \begin{bmatrix} -1 & 0 \\ 0 & -1 \end{bmatrix} \quad \text{i} \quad G_y = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}$$

Dos operadors també molt utilitzats són l'operador Canny i l'operador Laplacà.

L'algoritme Canny s'executa en 5 passos separats [21]:

- **Suavitzat:** Es desenfoca la imatge per eliminar el soroll. Les imatges obtingudes amb una càmera normalment contenen una quantitat de soroll que pot provocar que a l'aplicar un algoritme de detecció de contorns, aquest soroll sigui detectat com a contorn donant lloc a una detecció errònia. Normalment, s'aplica un filtre Gaussià.
- **Trobar gradients:** Els contorns corresponen als píxels on els gradients de la imatge tenen una major magnitud. Els gradient a cada píxel és trobat mitjançant l'operador Sobel.
- **Supressió dels no-màxims:** Aquest pas consisteix en convertir els contorns més difuminats en contorns més "marcats". Això s'aconsegueix preservant el màxim local dels gradients de la imatge i eliminant tota la resta.
- **Llindar doble:** Els contorns potencials seran determinats mitjançant el mètode de llindar (es trobarà un valor llindar i els píxels que tinguin un valor inferior passaran a tenir un valor mentre que els que tinguin un valor superior al del llindar passaran a tenir-ne un altre). En aquest cas, es determinaran dos llindars, amb la qual cosa, es trobaran tres diferents intensitats de píxel a la imatge resultant.
- **Seguiment de contorns per histèresi:** Els contorns més "forts" de la imatge es consideren com a contorns definitius i els contorns més dèbils, podran pertànyer a la imatge final si estan connectats amb un d'aquests contorns més "forts".

Per la seva banda, l'operador Laplacià calcula la segona derivada de la imatge. Aquest operador ressalta les regions on es produeix un canvi ràpid d'intensitat. Per tal d'aplicar-ho és necessari que la imatge hagi estat difuminada mitjançant un filtre Gaussià. El Laplacià $L(x,y)$ d'una imatge amb els valor d'intensitat de píxel $I(x,y)$, ve donat per l'expressió:

$$L(x,y) = [g_x \quad g_y] = \begin{bmatrix} \frac{\partial^2 I}{\partial x^2} & \frac{\partial^2 I}{\partial y^2} \end{bmatrix} \quad (3.2.3)$$

El Laplacià de la imatge pot ésser calculat utilitzant un filtre de convolució. Normalment, les dues màscares utilitzades per a la convolució són:

0	-1	0
-1	4	-1
0	-1	0

-1	-1	-1
-1	8	-1
-1	-1	-1

Aquestes màscares corresponen a la aproximació de la segona derivada i, com a tal, són molt sensibles al soroll. És per aquest motiu que es difumina la imatge mitjançant el filtre de Gauss abans d'aplicar el filtre Laplacià. Aquest petit processament de la imatge previ redueix el soroll a les freqüències més altes.

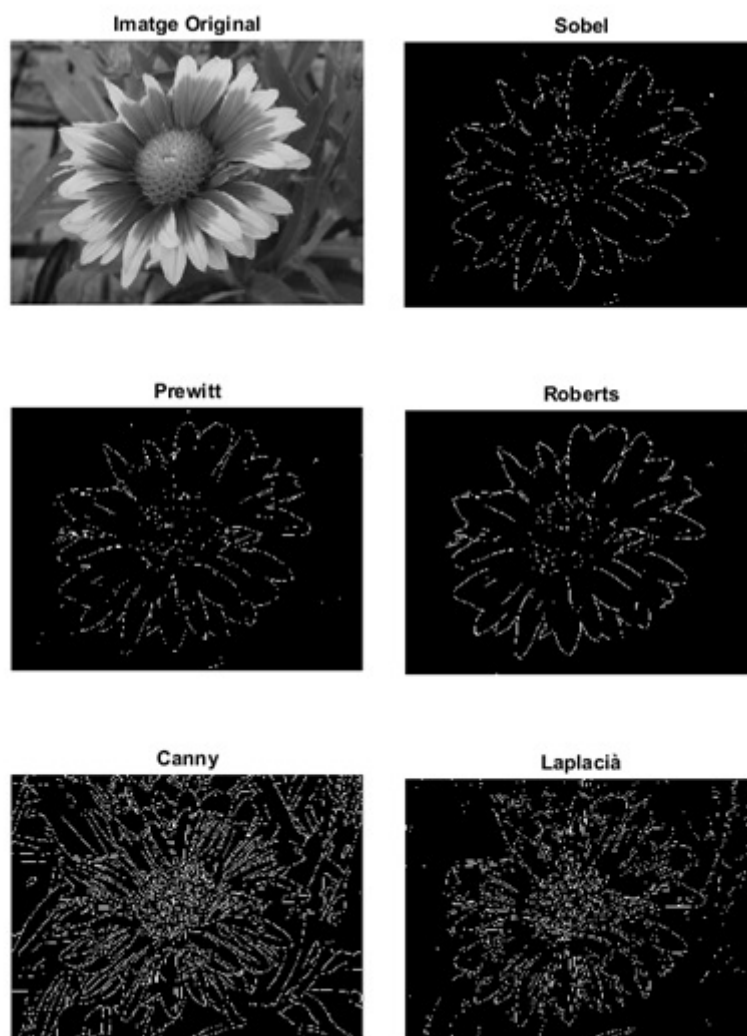


Figura 3.4: (a) Imatge Original, (b) Aplicació filtre Sobel, (c) Aplicació filtre Prewitt, (d) Aplicació filtre Roberts, (e) Aplicació filtre Canny, (f) Aplicació filtre Laplaciana (Font: Free stock photos, MATLAB)

Tal i com es pot comprovar a la figura (3.4), es pot observar com les imatges obtingudes a les quals se les ha aplicat els filtres Sobel i Prewitt, són bastant similars, ja que les màscares utilitzades són molt semblants entre elles (màscares de dimensions de

3x3 píxels). D'altra banda, els contorns de la imatge resultant un cop aplicat el filtre Roberts es troben millor definits degut a que aquest filtre, com que utilitza màscares de mida 2x2 píxels és més sensible que no pas els dos filtres previs comentats. Seguidament, el filtre Canny és un filtre, que com ja es pot visualitzar a la imatge, molt utilitzat per definir els contorns d'una imatge. Aquest filtre defineix la majoria d'ells presents a la imatge a processar. Aquest fet pot ésser de gran ajuda si el que es busca és la definició de la majoria de contorns possibles però esdevé un gran inconvenient si el que realment es busca és la segmentació una petita part de la imatge en qüestió. I finalment, es troba la imatge processada amb un filtre Laplaciana. Les màscares emprades aproximen el resultat al que s'obténdria si es portés a terme la segona derivada, i és per aquest motiu que de tots els filtres emprats en aquest projecte, és el que és més sensible al soroll.

Un dels avantatges de calcular els gradients de la imatge és que una diferent il·luminació o que una càmera tingui diferents propietats que una altra poden provocar que els píxels d'una imatge canviïn dràsticament de valor. Això pot provocar que diferents algorismes que depenguin d'un llindar fallin al intentar trobar les mateixes característiques. Calcular els gradients de la imatge original pot ser una solució ja que els gradients són menys susceptibles als canvis de llum o de característiques de la càmera, i es poden reduir els errors. Aquest mètode no requereix d'un gran cost computacional però és necessari que, per a un òptim resultat, la imatge no tingui una gran quantitat de textura ni de soroll.

3.2.2.2 Mètodes en el domini freqüencial (High-Emphasis Spatial Frequency Filtering) + Binarització

Altres mètodes utilitzen el domini freqüencial per a tal de determinar els píxels que conformen el contorn de les diferents regions de la imatge. Aquests mètodes es valen del fet que les altes freqüències corresponen a punts amb un canvi bruscat en el valor de la intensitat. Per tant, utilitzant un filtre passa-alts seguit d'una binarització es pot obtenir una segmentació dels contorns de la imatge.

Per tal de poder comprendre els algorismes que s'apliquen en el domini de la freqüència cal entendre en què consisteix el concepte de domini de la freqüència. En

dos dimensions, una funció sinusoidal té tres valors que la caracteritzen: la fase, la freqüència d'oscil·lació i la seva direcció d'oscil·lació. Una funció sinusoidal en dues dimensions té la següent forma:

$$f(m, n) = \sin(2\pi(\omega m + \theta n)) \quad (3.2.4)$$

on m, n són les coordenades dels píxels a l'espai de la imatge, ω i θ són les dues freqüències amb unitats cicles/píxel.

Un senyal es pot descompondre en un sumatori de diferents funcions de sinus amb diferents freqüències. Per a saber amb quina proporció contribueixen cadascuna d'elles a la funció principal, cal calcular la transformada de Fourier.

En dues dimensions, la transformada de Fourier per a una imatge finita de mida $M \times N$ vindrà donada per:

$$F(\omega, \theta) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} f(m, n) e^{-j2\pi(\omega m + \theta n)} \quad (3.2.5)$$

Observant l'espectre de freqüències de la imatge es poden veure diferents característiques: l'energia concentrada a baixes freqüències es troba associada a les zones homogènies mentre que, a altes freqüències, es trobaran les zones amb canvis bruscos que poden correspondre a soroll o a contorns. Donat aquest fet, es pot modificar la Transformada, multiplicant-la per una altre funció o així mitigar les freqüències que interressi per a aquella imatge en concret. La modificació de la Transformada de Fourier es pot expressar com:

$$G(\omega, \theta) = H(\omega, \theta) * F(\omega, \theta) \quad (3.2.6)$$

Per tal de disminuir les freqüències que no són d'interès, es necessari multiplicar la transformada per un filtre que deixi passar les freqüències d'interès. Els filtres passa-baix atenuen les components d'alta freqüència i s'utilitzen per eliminar el soroll

provinent d'altres freqüències i eliminar tots els canvis bruscs. D'altra banda, si l'objecte d'interès és l'obtenció dels contorns dels objectes que configuren la imatge cal plantejar-se la possibilitat d'aplicar filtres passa-alt, que mitigaran els components de baixa freqüència per així obtenir només amb aquelles zones on els nivells de gris varien bruscament corresponents als contorns.

3.2.3 Segmentació per àrees

Aquests tipus de tècniques de segmentació intenta agrupar els diferents píxels que comparteixen una o diverses característiques en una mateixa àrea.

3.2.3.1 Creixement de regions

El mètode de creixement de regions consisteix a seleccionar uns punts inicials (punts llavors) i mitjançant iteracions decidir si els píxels veïns corresponen o no a la mateixa regió a la qual pertany la llavor per tal de classificar la imatge en regions. El primer pas en aquest mètode consisteix en seleccionar les llavors. La selecció de llavors pot dur-se a terme en alguns casos automàticament, però generalment es fa manualment, la qual cosa és un dels grans desavantatges d'aquest tipus de mètode. En el cas de trobar les llavors automàticament, es designen uns píxels com a llavors basant-se o bé en la posició d'aquests o bé en una determinada característica com pot ser el valor del píxel. Un cop determinades les llavors, les diferents regions que aniran augmentant de mida a mesura que els píxels del voltant compleixin amb els requisits necessaris per a formar part d'aquella regió en concret tal i com es pot veure a la Figura 3.5. Uns criteris totalment vàlids podrien ser la intensitat del píxel, la seva textura o bé el color.

El mètode de creixement de regions té com a avantatge que és molt ràpid i contextualment simple. D'altra banda, al igual que amb tots els mètodes de segmentació, aquest també té certes limitacions que s'han de tenir en compte. Cal esmentar que es tracta d'un mètode local que no té en consideració una visió global del problema. Un altre punt negatiu a tenir en compte és que és un mètode molt sensible al soroll i que si en comptes d'uns determinats píxels s'escullen uns altres píxels com a llavors el resultat diferirà de l'obtingut amb les llavors prèvies.




Figura 3.5: Segmentació d'una determinada secció iniciada amb un punt llavor mitjançant el mètode de creixement de regions. (Font: Marshall97)

3.2.3.2 Split and Merge

Un altre mètode que també pertany a aquesta classificació és un mètode anomenat Split and Merge. A diferència del primer aquest no necessita llavors. Aquests mètode intenta dividir la imatge en regions uniformes. Normalment, l'algoritme comença amb la suposició inicial de que tota la imatge forma una sola regió, aleshores es computa el criteri d'homogeneïtat (H) que mesura la homogeneïtat de les regions d'estudi [23]. Si la regió no és homogènia, es divideix la imatge en regions iguals. Es torna a aplicar el criteri i si la regió continua sense ser homogènia es torna a dividir (Figura 3.6). És un procés iteratiu i només parerà quan no sigui necessària una nova divisió. Aleshores, l'algoritme intentarà unir les regions contínues que verifiquin una certa condició de semblança.

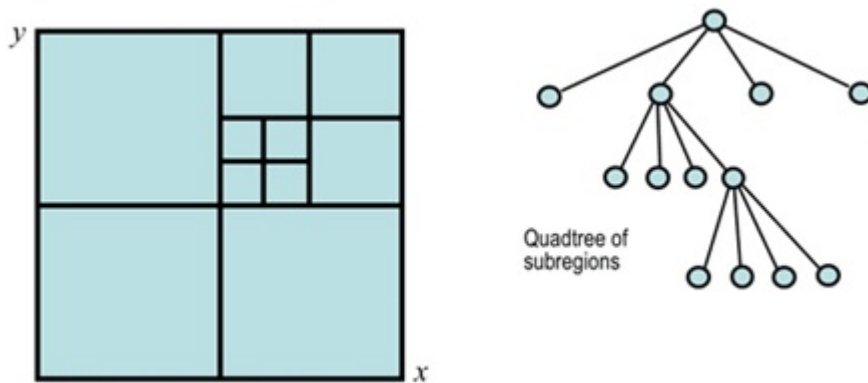


Figura 3.6: Estratègia del mètode de segmentació d'imatges Split and Merge. (Font: University of Auckland)

Tot i els avantatges que aquest mètode presenta, es pot presentar el cas que les zones d'interès variïn en brillantor o en color depenent de les condicions de llum amb les quals es va obtenir la imatge. Un altre desavantatge és la composició de la imatge, ja que és molt poc probable que una imatge estigui composta per regions uniformes de similar intensitat, color o textura, el que implicarà que píxels que pertanyin a la mateixa regió poden acabar en regions diferents tal i com passa a la Figura 3.7.

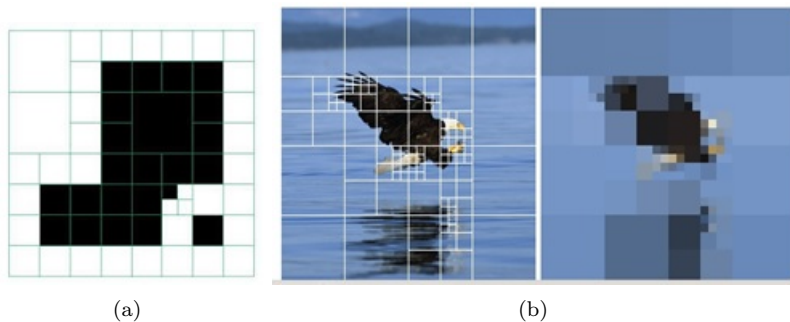


Figura 3.7: (a) Objecte simple segmentat mitjançant el mètode de Split and Merge, (b) Imatge segmentada amb el mètode Split and Merge (Font: (a) Xiang Yin, (b) Wolfram Demonstration Project)

3.2.3.3 Agrupament. (Clustering Approaches)

De totes les diferents tècniques de segmentació, una de les més eficients és el mètode d'agrupament o clustering. El clustering es tracta d'un procés d'agrupació d'una sèrie de píxels d'acord amb un o diversos criteris. Generalment, els clusters comparteixen propietats comunes.

Hi ha diferents mètodes d'agrupament: *K-means clustering*, *Fuzzy C-means clustering*, *mountain clustering* i el *subtractive clustering* [1].

L'algoritme *K-means* és un dels mètodes més utilitzats degut a la seva senzillesa i degut a que, computacionalment, és més ràpid que el mètode Split and Merge que es basa en un agrupament jeràrquic. Un petit desavantatge que presenta aquest mètode és que s'obté un diferent resultat segons el nombre de clusters, i és per aquest motiu que és necessari definir el nombre de clusters que es volen obtenir. L'algoritme consta de dues fases separades: a la primera fase, es calcula el centroide de cadascun dels agrupaments i durant la segona fase, s'assignen els diferents píxels al centroide que tinguin més a prop. Normalment, per tal de definir quin és el centroide més proper al píxel que es vol classificar s'utilitza el mètode de la distància euclidiana, que correspon a la mida del segment de línia entre els dos punts:

$$d = \| p(x, y) - C_k \| \quad (3.2.7)$$

On d és la distància entre el píxel i el centre, $p(x, y)$ és la posició del píxel dins la imatge i on C_k és el centroide.

Una vegada s'han agrupat els píxels, es torna a calcular el nou centroide de cada cluster :

$$C_k = \frac{1}{k} \sum_{y \in C_k} \sum_{x \in C_k} p(x, y) \quad (3.2.8)$$

Basant-se en aquest nou centroide, una nova distància euclidiana és calculada entre

cada centroide i cada píxel del conjunt i s'assignen els píxels al cluster amb el qual tinguin una distància mínima. A la Figura 3.8 es pot veure la distribució d'una sèrie de punts en 3 clusters.

És per aquest motiu, que els centroides dels diferents agrupaments seran els punts on la suma de totes les distàncies que conformin el cluster sigui mínima.




Figura 3.8: Exemple de la distribució de píxels amb 3 clusters. (Font: MATHWORKS)

3.2.4 Altres mètodes

A continuació es llisten una sèrie de tècniques que no pertanyen a cap dels tipus anteriors.

3.2.4.1 Xarxes neuronals artificials. (Artificial Neural Networks)

Per tal d'entendre el funcionament bàsic d'aquest mètode cal veure l'exemple que es pot trobar a la natura; els animals reben informació sobre el seu entorn i sobre ells mateixos gràcies a una xarxa neuronal de cèl·lules especialitzades anomenada sistema

nerviós, aquest també processa la informació i ocasiona respostes. Portat al camp de la segmentació d'imatges, les xarxes neuronals artificials són un sistema d'interconnexió de neurones (nodes) en una xarxa que col·labora per produir un estímul de sortida. El mètode és molt semblant al mètode de Classificadors però amb una major complexitat. Per tal de produir una resposta adequada cal que “s'entreni” al sistema primer amb una gran quantitat d'imatges ja segmentades per tal que el sistema aprengui que aquella és la resposta que es desitja.

Un exemple pràctic d'aquest mètode seria els automòbils que detecten a un vianant mentre circulen i s'aturen (Exemple a la Figura 3.9). Per tal de poder fer-ho, cal que “s'entreni” a la xarxa amb una gran quantitat d'imatges en les quals apareguin tots els objectes amb que es pot trobar algú que condueixi el vehicle i identificar quins d'ells són vianants.



Figura 3.9: Detecció de dos objectes que la càmera reconeix com cotxe i persona.
(Font: YouTube)

3.2.4.2 Models deformables / Contorns actius. (Deformable Models)

A la natura és molt difícil trobar formes geomètriques completament regulars que no hagin estat fabricades per l'ésser humà [24].

Un contorn actiu (comunament conegut com a Snake) és una corba elàstica deformable que, col·locada sobre una imatge, comença a deformar-se a partir de la seva forma inicial amb la finalitat de delimitar les zones d'interès de la imatge. La deformació de la Snake es produeix mitjançant l'aplicació de forces internes que controlen la suavitat de la corba i mitjançant forces externes que empenyen al contorn actiu cap a les característiques sortints de la zona que es vol delimitar.

Aquest mètode és molt utilitzat per a la segmentació d'imatges mèdiques i és molt popular a aplicacions com el seguiment d'un objecte, reconeixement de forma, detecció de contorn, entre d'altres. Per tal de delinear el contorn d'un objecte en una imatge cal col·locar una corba tancada a prop del contorn que es vol obtenir. La posició de la Snake varia amb el temps amb l'objectiu de minimitzar l'energia total. A la Figura 3.10 es veu la segmentació per "Snakes" d'una mà.

La tècnica, comparada amb les tècniques clàssiques, té múltiples avantatges entre els quals cal destacar que autònomament i adaptativament busquen la posició de mínima energia, les forces externes de la imatge actuen sobre la Snake de forma intuïtiva i també poden ser utilitzades per a fer un seguiment d'objectes dinàmics. Tot i tenir una gran quantitat d'avantatges també existeixen diferents dificultats a l'hora d'executar-lo; aquest mètode és sensible a mínims locals i petites característiques de l'objecte a segmentar poden ser omeses durant la minimització de l'energia sobre tot el contorn.




Figura 3.10: Exemple de l'aplicació del mètode "Snakes". (Font: Brunel University)

3.2.4.3 Watershed

A la tècnica *Watershed* la imatge es pot considerar com una imatge topogràfica d'un relleu terrestre on cada píxel és associat amb un valor d'altura dins d'aquest relleu que correspon amb el seu nivell de gris. Si la imatge és un relleu, els pics amb major valor de gris es poden considerar com les muntanyes mentre que els píxels que tinguin un valor més baix correspondran a valls i rius. Això es mostra a la Figura 3.11. El pas següent que porta a terme aquest mètode és la "d'omplir" aquestes valls i rius. Aquestes zones, que corresponen als píxels de baixa intensitat, poden formar diferents valls. Totes aquestes valls es començaran a inundar fins que l'aigua de les diferents valls s'uneixin. Aquestes unions representaran les fronteres de les regions de la imatge i constituïran el resultat del procés de segmentació.




Figura 3.11: Exemple de representació topogràfica d'una imatge amb mètode Watershed. (Font: Research Gate)

Una de les limitacions d'aquest mètode és que és òptim per a imatges homogènies, ja que en imatges no homogènies hi ha un gran nombre de mínims locals que es traduiran en moltes valls a la imatge topogràfica provocant que hi hagi moltes regions generades a la imatge segmentada tal i com es veu a la Figura 3.12. Per tal d'evitar que això passi, s'ha de portar a terme un preprocesament de la imatge per suavitzar aquests mínims locals, com per exemple un filtre Gaussià, o bé un postprocesament que consisteixi en la unió de regions que comparteixin algun criteri.




Figura 3.12: (a) Imatge original, (b) Sobresegmentació de la imatge original com a resultat de l'aplicació de la transformada de Watershed sense un filtratge previ per reduir soroll. (Font: SciELO)

3.2.4.4 Atlas-Guided Approaches

Aquest mètode és una eina molt emprada en segmentacions mèdiques quan una plantilla o model estan disponibles. En comptes de centrar-se en les característiques de la imatge, els *Atlas-Guided Approaches* es centren en el domini espacial de la imatge. Els atlas es generen compilant informació de les parts de la imatge que es volen segmentar i posteriorment, aquest atlas s'utilitzarà com a plantilla de referència per a segmentar noves imatges de manera automàtica.

Ha estat emprat, sobretot, a les imatges de ressonància magnètica obtingudes del cervell per a segmentar diverses estructures, i també per a extreure el volum del cervell. En casos clínics, s'utilitza per detectar diferències morfològiques entre diferents grups de pacients.

Comparat amb altres mètodes de segmentació d'imatges, els mètodes basats en atlas tenen l'habilitat de segmentar la imatge sense que hi hagi una relació molt definida entre les regions i les intensitats dels píxels. És per aquest motiu que s'utilitza principalment quan la informació de les intensitats dels diferents píxels no és suficient.

4 Algorisme

4.1 Context

Aquest codi ha estat dissenyat per a optimitzar la part de l'algorisme encarregada de portar a terme la segmentació, utilitzada a la tesi del codirector del treball. Es necessitava obtenir els contorns ben definits de l'estructura que es volia segmentar i fer-ho en la menor quantitat de temps possible. En el cas que amb dos codis s'obtinguessin els contorns dels objectes que es volguessin segmentar, escolliríem aquell codi que necessités menys temps per a portar a terme la segmentació, és a dir, en aquest projecte es prioritza la rapidesa del codi envers la qualitat de la imatge resultant.

4.2 Algorisme

La principal finalitat d'aquest algorisme és la de segmentar les estructures d'interès que es troben a la imatge. Aquest algorisme constarà de dues parts; primer de tot, es portarà a terme la segmentació de les estructures d'interès de la imatge i, en segon lloc, es reduirà el nombre de punts que conformen el contorn.

4.2.1 Primera part de l'algorisme

Aquesta part de l'algorisme retorna la imatge binaritzada amb la zona d'interès segmentada.

Inicialment, les imatges que seran preprocessades per tal de reduir el soroll. Si les imatges no fossin en escala de grisos hauria de portar-se a terme una instrucció anomenada, a MATLAB, *rgb2gray* que ens permetria obtenir-les en escala de grisos per a poder portar a terme la segmentació.

Per tal de visualitzar els diferents passos portats a terme es defineix una de les imatges tractades com a exemple, Figura 4.1.




Figura 4.1: Imatge d'una estructura 3D corresponent a un cor que serà processada amb el codi.

Prèviament a la segmentació, es portarà a terme un preprocessat de la imatge. Els píxels de la nova imatge es generaran calculant la mediana del conjunt de píxels de l'entorn del píxel corresponent a la imatge d'origen. D'aquesta manera, s'homogeneïtzen els píxels amb intensitats molt diferents amb respecte a la dels veïns. Aquest tipus de filtre es molt indicat quan es té soroll aleatori.

A MATLAB, la instrucció que portarà a terme aquest filtratge de mediana correspon a *medfilt2*. Per defecte, MATLAB defineix una matriu de píxels amb dimensions 3x3 píxels, fent que el píxel que s'està tractant estigui envoltat per vuit píxels. Cada píxel de la imatge de sortida contindrà la mediana del valor dels vuit píxels del voltant al corresponent píxel de la imatge d'entrada:

```
Img2 = medfilt2(Img);
```


A continuació, com a segona part del preprocessat de la imatge, s'expandirà la zona d'interès de l'histograma de la imatge per tal de que aquests píxels es distribueixin entre els valors 0 i 1, Figura 4.2. On el resultat d'aquesta expansió pot observar-se a la Figura 4.3.

```
Img2 = imadjust (Img2, [0.1 0.5], [0.0 1.0]);
```




Figura 4.2: (a) Histograma d'una de les imatges originals, (b) Nou histograma, distribuint tots els píxels entre els valors 0 i 1.




Figura 4.3: Imatge del cor després d'aplicar imadjust a MATLAB.

A partir d'aquest punt, el preprocessat de la imatge finalitza i s'inicia la part de segmentació de la imatge pròpiament dita.

Per iniciar el procés de segmentació, primer de tot es portarà a terme un gradient morfològic que consisteix en fer una dilatació de la imatge original, una erosió de la imatge original i posteriorment la resta les dues imatges resultants, Figura 4.4. El motiu pel qual s'ha triat aquest filtre envers d'altres ja comentats prèviament (com el filtre Canny o el Sobel) és perquè, tot i que la qualitat dels contorns obtinguts no és tan elevada, és un mètode molt més ràpid.

Tant a la dilatació com a l'erosió, l'element estructural de l'operació morfològica serà un quadrat amb dimensions 3x3 píxels.

```
SE = strel('square', 3);  
dImg2 = imdilate(Img2, SE);  
se = strel('square', 3);  
eImg2 = imerode(Img2, se);  
Img2 = dImg2 - eImg2;
```




Figura 4.4: Imatge resultant després de l'aplicació del filtre morfològic.

La imatge resultant seguirà sent una imatge en escala de grisos, pel que el següent pas del codi serà binaritzar la imatge mitjançant la instrucció *imbinarize* de MATLAB, Figura 4.5. Aquesta instrucció binaritzarà la imatge utilitzant el llindar obtingut mitjançant el mètode d'*Otsu*. Aquest algorisme assumeix que hi ha dues classes de píxels. Tot seguit, calcula el llindar òptim per tal de separar les dues classes i que la variació dels píxels dintre d'una mateixa classe sigui mínima mentre que la diferència amb la variància de l'altre classe sigui màxima.

```
Img2 = imbinarize(Img2);
```



Figura 4.5: Imatge resultant després de portar a terme la binarització.

A continuació, s'emprarà una eina de MATLAB anomenada `bwareopen` que té com a funció eliminar tots els conjunts de píxels que siguin més petits que un determinat valor i produeix, com a resultat, una imatge binaritzada que conté aquells conjunts que no han estat eliminats.

Les imatges processades són de tipus *uint8* i tenen unes dimensions de 480x752 píxels, és a dir, la resolució de la càmera amb la qual s'han obtingut les imatges és de 360960 píxels. Per tal de poder determinar el valor que definirà els conjunts de píxels que seran eliminats es farà una aproximació per a determinar el nombre òptim de píxels per a la eliminació de la major part dels conjunts de píxels que no corresponen a la zona a segmentar.

Fem la suposició de que la zona a segmentar serà circular i, tenint en compte que la imatge té unes dimensions de 480x752 píxels, suposarem un diàmetre de l'objecte igual a 400 píxels. Tenint en compte aquesta dada, s'obté un valor de perímetre d'aproximadament 1257 píxels. El contorn que s'obtindrà no tindrà només un píxel de gruixudesa, així doncs, és una dada que caldrà tenir en compte. Si considerem una amplada de contorn de dos o tres píxels, el nombre de píxels que passaràn a formar el

contorn anirà des dels 2514 als 3771 píxels.

Un cop obtingudes aquestes dades, es podrà utilitzar qualsevol nombre de píxels que sigui inferior al nombre de píxels que conformen el contorn de l'objecte que es vol segmentar. S'escollirà un valor de 1000 píxels, Figura 4.6.



Figura 4.6: Conjunts de píxels que romanen després d'eliminar els conjunts de píxels més petits que 1000.

Per tal d'eliminar possibles discontinuïtats que es puguin trobar al contorn obtingut al pas previ es portarà a terme una obertura. Una obertura consisteix en l'aplicació d'una dilatació sobre la imatge original i posteriorment aplicar una erosió.

```
SE1 = strel('rectangle', [3 4]);  
Img2 = imdilate(Img2, SE1);  
SE2 = strel('diamond', 1);  
Img2 = imerode(Img2, SE2);
```

A diferència de la dilatació i de l'erosió portades a terme prèviament, els elements estructurals són diferents. L'utilitzat durant la dilatació correspon a un rectangle de

dimensions 3x4 píxels, mentre l'utilitzat durant l'erosió té dimensions 3x3 píxels on el segon, el quart, el cinquè, el sisè i el vuitè element tenen valor 1 mentre que la resta tenen un valor igual a 0.

Un cop portada a terme l'obertura s'etiquetaran els conjunts de píxels i la zona segmentada final correspondrà al conjunt de píxels el centre del qual es més proper al centre de la imatge. Aquest pas es farà gràcies a les propietats obtingudes mitjançant l'eina *regionprops* de MATLAB. Amb aquesta eina és possible obtenir els centres de tots els conjunts de píxels que es trobin a la imatge i mitjançant el càlcul senzill d'una distància euclidiana es determinarà quin dels centres és més proper al centre de la imatge, obtenint com a resultat la imatge segmentada, Figura 4.7.

```
labeledImage = bwlabel (Img2);  
  
measurements = regionprops (labeledImage, 'Centroid');
```




Figura 4.7: Imatge final obtinguda mitjançant el codi de segmentació.

Com es pot observar, gràcies a la propietat *regionprops* de MATLAB ha estat possible

eliminar el conjunt de píxels que es trobava a la part superior dreta de la imatge i quedar-se, així, amb el contorn d'interès.

4.2.2 Segona part de l'algorisme

L'objectiu d'aquesta part de l'algorisme és reduir el nombre de punts que conformen el contorn de l'estructura segmentada.

Per tal de fer-ho, primer caldrà obtenir les coordenades de tots els píxels que conformen el contorn. Durant aquest pas seran necessàries una màscara amb les mateixes dimensions que la imatge original però amb el valor de tots els píxels iguals a zero, Figura 4.8 (a), i la imatge ja segmentada, Figura 4.8 (b).

A continuació, es necessitarà un píxel de la imatge segmentada que formi part del contorn, és a dir, que el seu valor sigui 1. Per tal d'optimitzar el temps, en comptes de buscar per tota la imatge un píxel que compleixi amb aquesta característica es suposarà que el contorn de l'estructura segmentada passarà pel centre de la imatge així que només centrarem la nostra cerca a la fila del mig. Un cop es troba el píxel que forma part del contorn es portarà a terme un creixement de regions.

A la funció *creixerRegio*, les dades d'entrada seran la imatge segmentada, les coordenades del punt trobat que forma part del contorn. D'altra banda, les dades de sortida seran una nova màscara i una llista de punts que seran aquells punts que conformin el contorn.




Figura 4.8: (a) Exemple de contorn per a la segona part de l'algorisme, (b) Exemple de màscara de la segona part de l'algorisme amb les mateixes dimensions que la imatge però amb tots els valors igual a 0.

Com s'ha esmentat abans, el píxel d'origen, Figura 4.9, és un píxel que pertany al contorn i que pertany a la fila que divideix la imatge en dues parts iguals ja que es suposa que el contorn de la figura d'interès passa pel centre de la imatge.




Figura 4.9: Píxel d'inici, en color taronja, per a la segona part de l'algorisme de segmentació.

El primer pas consistirà en guardar les coordenades del primer píxel que forma part del contorn a la llista (llista de punts per a visitar) i canviar l'etiqueta amb valor 0 de la nova màscara per una etiqueta amb valor 1 al píxel amb les mateixes coordenades que aquell que s'ha guardat a la llista, Figura 4.10.

Llista de punts per a visitar: {punt 8}

0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	1	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0

Figura 4.10: A la mateixa posició del píxel inicial, es canvia l'etiqueta 0 per la de 1.

Mentre la llista no sigui buida, la llista perdrà el seu últim element i aquest passarà a una altra llista (llista de punts finals) on es guardaran tots els píxels visitats. Per a poder continuar es comprovarà si algun punt veí de element que s'elimina compleix les següents condicions:

- $\text{Img}(\text{punt}) == 1$
(ens indicarà que el punt forma part del contorn)
- $\text{mascaranova}(\text{punt}) == 0$
(aquesta característica indicarà que el punt no ha estat avaluat prèviament)

Si el punt avaluat compleix les característiques passarà a formar part de la llista i es canvia el valor de la màscara dels píxels veïns que compleixin les dues condicions anteriors.

En aquest exemple, de tots els píxels veïns del píxel número 8 (píxel inicial) són del contorn el 6 i 10. Un cop aquests punts siguin afegits a la llista de punts per a visitar, el valor de la màscara d'aquests píxels passarà a tenir valor 1, Figura 4.11.

Llista de punts per a visitar: {punt 6, punt 10}

llista de punts finals: {punt 8}

0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	1	0	0	0	0	0	0	0
0	0	1	0	0	0	0	0	0	0
0	0	1	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0

Figura 4.11: Màscara amb l'etiqueta igual a 1 als nous píxels.

Es tracta d'un procés iteratiu, és a dir, fins que la llista de punts per a visitar no sigui buida, el programa anirà repetint els mateixos passos:

- S'elimina el punt 10 ja que és l'últim element de la llista de punts per a visitar i passa a la llista de punts finals. Els píxels veïns que compleixen les condicions anteriors són, en aquest cas, el píxel 12 i el 13. Per tant, s'afegeixen a la llista de punts per a visitar i es canvia el valor de la seva màscara a 1, Figura 4.12

0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	1	0	0	0	0	0	0	0
0	0	1	0	0	0	0	0	0	0
0	0	1	0	0	0	0	0	0	0
0	0	1	1	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0

Figura 4.12: Màscara amb l'etiqueta igual a 1 als nous píxels.

Llista de punts per a visitar: {punt 6, punt 12, punt 13}

Llista de punts finals: {punt 8, punt 10}

Aquest procés s'anirà repetint successivament fins que no hi hagi cap punt a la llista de punts per a visitar. El fet de que no hi hagi cap punt a la llista de punts per a visitar implica que tots els punts que conformen el contorn de la figura d'interès han passat a formar part de la llista de punts finals.

Un cop es té la llista de punts de pertanyen al contorn, es torna al codi principal amb l'objectiu d'obtenir finalment un nombre més reduït de punts del contorn.

Per a poder portar-ho a terme, el següent pas del codi és calcular el baricentre de tots els punts de la llista i transformar a coordenades polars tots els punts respecte d'aquest baricentre. Aleshores, dividirem totes les direccions respecte del baricentre en un nombre de seccions circulars igual al nombre de punts desitjats. El següent pas consisteix en determinar a quina secció pertany cada punt i quedar-nos només amb el punt més allunyat del baricentre de cada secció.

4.3 Resultats

En aquesta secció es mostraran els resultats de les segmentacions de les tres estructures (cor, ronyó i vèrtebra) obtinguts un cop portada a terme la primera i la segona part de l'algorisme.

4.3.1 Resultats de la primera part de l'algorisme

En aquesta primera part de l'algorisme, l'objectiu principal era el de trobar els contorns de l'estructura en el menor temps possible. A les imatges obtingudes un cop processades, es pot veure el contorn de l'estructura d'interès que es volia segmentar i també s'observa que els contorns són completament continus.

Tal i com es pot observar a les imatges (a) i (c) de la Figura (4.13), ambdues imatges de l'estructura del ronyó corresponen a la mateixa instantània però la imatge situada a la part inferior ha estat preprocessada augmentant el contrast entre l'objecte i el fons. A la imatge superior es pot observar com hi ha una zona discontinua degut a la semblança entre la intensitat dels píxels que conformen aquella determinada zona i la intensitat dels píxels que corresponen a l'estructura del fons. Com ja hem esmentat abans, al ser una discontinuïtat de pocs píxels no suposa cap problema ja que a la segona part de l'algorisme es portarà a terme una reducció del nombre de punts que conformen el contorn i, per tant, no és necessari tenir un contorn completament tancat. El fet d'augmentar la diferència d'intensitat dels píxels que conformen la figura amb els píxels del fons ha permès portar a terme una millor segmentació de l'objecte, fent possible l'obtenció d'un contorn continu en la seva totalitat.


També es pot observar com a la imatge (b) de la Figura (4.13) hi ha conjunts de píxels a l'interior del contorn trobat. Aquest fet no suposa cap inconvenient ja que, durant la segona part de l'algorisme, només ens quedarem amb els punts més llunyans, és a dir, amb el contorn més extern de la figura.

A continuació es mostren tres imatges originals de cadascuna de les estructures que han estat segmentades mitjançant el codi corresponent a la primera part de l'algorisme:

- Contorns obtinguts de l'estructura del ronyó, Figura 4.13:




(a)




(b)




(c)



(d)




(e)



(f)

Figura 4.13: (a) (c) (e) Imatges originals de l'estructura 3D del ronyó, (b) (d) (f) Imatges resultants obtingudes a partir del codi de MATLAB


- Contorns obtinguts de l'estructura del cor, Figura 4.14:




(a)




(b)




(c)



(d)



(e)




(f)

Figura 4.14: (a) (c) (e) Imatges originals de l'estructura 3D del cor, (b) (d) (f) Imatges resultants obtingudes a partir del codi de MATLAB

- Contorns obtinguts de l'estructura de la vèrtebra, Figura 4.15:




(a)



(b)




(c)



(d)



(e)



(f)

Figura 4.15: (a) (c) (e) Imatges originals de l'estructura 3D de la vèrtebra, (b) (d) (f) Imatges resultants obtingudes a partir del codi de MATLAB

4.3.2 Resultats de la segona part de l'algorisme

La finalitat d'aquesta segona part del codi és la de portar a terme una reducció del nombre de punts que configuren el contorn. A les Figures 4.16, 4.17 i 4.18 es mostren els contorns obtinguts a la primera part de l'algorisme amb el nombre de punts finals en vermell




Figura 4.16: Punts finals del contorn, en vermell, de l'estructura del cor.




Figura 4.17: Punts finals del contorn, en vermell, de l'estructura del ronyó.




Figura 4.18: Punts finals del contorn, en vermell, de l'estructura de la vèrtebra.

L'objectiu prioritari d'aquest projecte era el de portar a terme la segmentació en el menor temps possible. El codi es va implementar en dos llenguatges de programació diferents: MATLAB i C++. Un cop implementat es va calcular el temps que trigava el codi en ambdós llenguatges donant com a resultat 0,025 segons en MATLAB i 0,004 segons en C++ per a la primera part i 0,020 segons en MATLAB i 0,001 segons en

C++ per a la segona part de l'algorisme. El temps total necessari per poder portar a terme la segmentació és de 0,045 segons en MATLAB i 0,005 segons en C++. Aquests resultats indiquen que el codi permet processar 22 imatges per segon i 200 imatges per segon respectivament. Tenint en compte els resultats obtinguts, es pot assegurar que el codi és suficientment ràpid, complint així amb l'objectiu principal del projecte.

5 Anàlisi de l'impacte mediambiental

Aquest projecte no té cap conseqüència directa sobre la salut del medi ambient ni sobre la integritat dels ecosistemes.

Conclusions

La segmentació d'imatges biomèdiques, tal i com s'ha pogut observar al llarg del treball, és un procés molt complex i ésser capaç d'obtenir una segmentació perfecta requereix una bona implementació de les diferents tècniques i una correcta aplicació de les mateixes.

Un cop analitzades totes les imatges, hi ha algunes d'elles on el codi de segmentació no serveix per tal d'obtenir la zona desitjada. Tot i això, el tant per cent d'imatges segmentades és superior al 90% del total de les imatges, i és per aquest motiu que es considera que el codi utilitzat en aquest projecte és una aproximació bastant bona a l'objectiu inicial que es volia aconseguir.

Inicialment, el codi contenia la tècnica de Watershed com a pas final. Com a primera característica de la implementació d'aquesta tècnica es pot dir que la qualitat de la segmentació era molt més elevada: s'obtenien uns contorns molt fins (d'un o d'un parell de píxels com a màxim) i el contorn de la figura era molt més semblant a la forma original de l'objecte. En contraposició, cal esmentar que el rati final d'imatges segmentades era inferior a si no s'utilitzava la tècnica del Watershed i el temps també era molt major. El principal problema de la tècnica de Watershed és que si el contorn tenia alguna discontinuïtat, per molt petita que fos, es considerava que l'àrea de dins del contorn pertanyia a l'àrea corresponent al fons; per tant, a la imatge resultant no s'observava cap contorn.

Les imatges, tal i com s'ha esmentat en apartats anteriors d'aquest projecte, es consideren gairebé òptimes ja que l'objecte que es vol segmentar destaca clarament del fons en el qual es troba. Això pot provocar que el codi implementat en aquest treball no sigui tan eficaç en altres ambients amb diferents característiques; com per exemple, una imatge on l'objecte a segmentar i el fons siguin molt semblants. En aquest cas, s'hauria de canviar l'estratègia per tal d'obtenir els contorns. Un possible canvi seria utilitzar operadors de gradient Sobel o Canny per tal d'obtenir uns primers contorns

en comptes d'utilitzar un gradient morfològic.

Per últim, degut als resultats obtinguts, a les limitacions de les tècniques emprades i del llenguatge de programació, es considera que queda molt per avançar en aquesta línia de treball i es proposen un seguit de línies futures per tal d'aconseguir una millor segmentació i una millora de les tècniques ja existents:

- En aquest treball ja s'ha portat a terme un preprocessat de les imatges però, un cop analitzats els resultats i les imatges on no s'ha portat a terme una bona segmentació, es veu clarament que es necessita un preprocessat molt més intens per tal de corregir errors com els provocats per soroll i il·luminació.
- Seguir treballant en l'algorisme per tal de millorar les seves prestacions i així poder operar amb imatges biomèdiques més complexes.
- Un major coneixement de les tècniques disponibles avui en dia per a la segmentació d'imatges. En aquest projecte s'han utilitzat diverses tècniques de segmentació i les imatges resultants compleixen amb l'objectiu que es buscava però, tenint en compte l'elevat nombre de tècniques disponibles, es podrien haver obtingut uns resultats molt més òptims a partir de les mateixes. Es podria plantejar dissenyar una tècnica híbrida de moltes de les existents per tal de combinar tots els avantatges de cadascuna d'elles.

Pressupost i/o anàlisi econòmica

Durant aquest projecte no serà necessària una gran quantitat de material, ja que la part més important del projecte recau a les mans de l'enginyer biomèdic que programarà l'algoritme que portarà a terme la segmentació. Per tant, una gran part del pressupost anirà destinada a pagar el cost de les hores de treball que el professional necessiti per a enllestir el treball i, l'altra part, correspondrà al cost indirecte del projecte. El pressupost o costos totals, seran la suma dels costos directes i indirectes.

Per tal de portar a terme una anàlisi econòmica més aproximada a la realitat, considerarem que l'enginyer biomèdic al que se li demana encarregar-se d'aquest projecte és autònom i només haurà d'encarregar-se del processament un cop adquirides les imatges.

Costos directes

Els costos directes són aquells que poden identificar-se directament amb un objecte de costos. Els costos directes deriven de l'existència del producte, servei, activitat del què s'ha de determinar el seu cost. Com per exemple, si es tracta d'un producte, els costos directes corresponen als costos dels materials directes i de la mà d'obra directa destinada a la fabricació del mateix o als costos de publicitat efectuats directament per promocionar els productes en un territori particular de vendes.

En aquest cas en particular, el cost directe recau, principalment, en el sou (costos de personal) de l'enginyer encarregat de portar a terme la feina:

COSTOS DIRECTES					
Perfil del treballador	Número de treballadors	Tasques a realitzar	Sou (€/hora)	Número d'hores del projecte	Costos directes TOTALS
Enginyer Biomèdic	1	Implementació d'un algoritme de segmentació d'imatges biomèdiques	35€/hora	320 hores	11200€

Taula 5.1: Taula de costos directes

Costos indirectes

Els costos indirectes del projecte poden desglossar-se en dos tipus: els costos indirectes generals de l'empresa i els costos generals del projecte. Tal i com ja s'ha especificat abans, s'ha considerat al professional com a autònom que treballi de manera individual, cosa que fa que els costos indirectes de la empresa no existeixin.

Els costos indirectes del projecte correspondran tant al software com al hardware necessaris per a la realització del projecte.

COSTOS INDIRECTES					
Costos de Software					
Programa	Número de llicències requerides	Preu llicència (€/any)	Període d'ús (temps emprat al projecte)	Costos indirectes totals software	
Matlab R2017b	1	2000€/any	4 mesos	667€	
Microsoft Office Professional	1	69€/any		23€	
Microsoft 10 PRO	1	48,99€/any		16,33€	
Costos de Hardware					
Tipus de dispositiu	Cost total de l'equip	Número d'equips	Període d'amortització de l'equip	Període d'ús (temps emprat al projecte)	Costos indirectes totals de hardware
Workstation Portàtil HP Zbook Studio G3 Full HD Core i7, 8GB 256GB TurboZ NVIDIA® Quadro® 4GB	2562,78€	1	5 anys	4 mesos	170,80€
				COSTOS INDIRECTES TOTALS	877,13€

Taula 5.2: Taula de costos indirectes

COSTOS DIRECTES	COSTOS INDIRECTES	COSTOS TOTALS
11200€	877,13€	12077,13€

Taula 5.3: Taula de costos totals

Així doncs, el pressupost necessari per a portar a terme aquest projecte és d'aproximadament 12100€. La major part del pressupost anirà destinada al sou de l'enginyer biomèdic encarregat del projecte.

Bibliografia

Referències bibliogràfiques

- [1] Dhanachandra, Nameirakpam, Khumanthem Manglem, and Yambem Jina Chanu. 2015 “ Image Segmentation using K-means Clustering Algorithm and Subtractive Clustering Algorithm ”. *Procedia - Procedia Computer Science* 54. Elsevier Masson SAS: 764-71. DOI:10.1016/j.procs.2015.06.090.
- [2] The British Machine Vision Association and Society for Pattern Recognition. “ What is computer vision? ” BMVA.org. <http://www.bmva.org/visionoverview>. (accessed October 20, 2017)
- [3] “ Medicina nuclear general ” RadiologyInfo.org Para pacientes, <http://www.radiologyinfo.org/sp/info.cfm?pg=gennuclear>. (accessed October 20, 2017)
- [4] Beutel, Jacob, Harold L. Kundel, Richard L. Van Metter, “ Medical imaging handbook ”, *SPIE press*, 2000.
- [5] Brenner, David J, and Eric J Hall. 2007. “ Computed Tomography – An Increasing Source of Radiation Exposure”, pp. 2277-84.
- [6] Smith-Bindman, Rebecca. “ Opinion — We Are Giving Ourselves Cancer ” NYTIMES.com. <http://www.nytimes.com/2014/01/31/opinion/we-are-giving-ourselves-cancer.html>. (accessed October 22, 2017)
- [7] Howseman, Alistair M, and Richard W Bowtell. 1999. “ Functional Magnetic Resonance Imaging: Imaging Techniques and Contrast Mechanisms ”.
- [8] “ Anihilació ” Wikipedia.org. <http://ca.wikipedia.org/wiki/Anihilacio>. (accessed October 20, 2017)

- [9] “ Imágenes Ópticas ” National Institute of Biomedical Imaging and Bioengineering, <http://www.nibib.nih.gov/espanol/temas-cientificos/imagenes-opticas>. (accessed October 22, 2017)
- [10] “ Endoscopy: MedlinePlus ” Medlineplus.gov. <http://medlineplus.gov/endoscopy.html>. (accessed October 24, 2017)
- [11] “ Endoscopia ” Wikipedia.org. <http://es.wikipedia.org/wiki/Endoscopia>. (accessed October 22, 2017)
- [12] Rovere, G, Nadal-Nicolás FM, Agudo-Barriuso, Sobrado- Calvo, Nieto-López L, Nucci C, Villegas-Pérez MP and Vidal.Sanz M. “ Comparison of Retinal Nerve Fiber Layer Thinning and Retinal Ganglion Cell Loss After Optic Nerve Transection in Adult Albino Rats.- PubMed - NCBI ”, *Ncbi.nlm.nih.gov*, 2017.
- [13] “ Diccionario de cáncer ” Instituto Nacional del Cáncer. <http://www.cancer.gov/espanol/publicaciones/diccionario?cdrid=785629>. (accessed October 24, 2017)
- [14] “ Microscopía de Super-Resolución: Capacidades de I+D - Portal Web de ITEMAS - Plataforma de Innovación en Tecnologías Médicas y Sanitarias ” Itemas.org. <http://www.itemas.org/cartera-de-servicios/capacidades-de-i-d/itc/microscopia-de-super-resolucion/c/show/>. (accessed October 25, 2017)
- [15] “ Ultrasound: Purpose, Procedure, and Preparation ” Healthline.com. <http://www.healthline.com/health/ultrasound>. (accessed October 25, 2017)
- [16] Nadrljanski, Mirjan M. “ Physical principles of ultrasound — Radiology Reference Article — Radiopaedia.org ” Radiopaedia.org. <http://www.radiopaedia.org/articles/physical-principles-of-ultrasound-1>. (accessed October 24, 2017)
- [17] “2009 flu pandemic ” Wikipedia.org, http://en.wikipedia.org/wiki/2009_flu_pandemic. (accessed October 24, 2017)
- [18] “ Thermography ” Wikipedia.org. <http://en.wikipedia.org/wiki/Thermography>. (accessed October 24, 2017)
- [19] “ The Hayflick Limit — The Embryo Project Encyclopedia ” Embryo.asu.edu. <http://embryo.asu.edu/pages/hayflick-limit>. (accessed November 3, 2017)

-
- [20] Sujatha, P, and K K Sudha. 2015. “ Performance Analysis of Different Edge Detection Techniques for image Segmentation ”8 (July). DOI: 10.17485/ijst/2015/v8i14/72946.
- [21] Image, Test. 2009. “ Canny Edge Detection, ” 1-7.
- [22] “ Computação Visual e Multimédia ” <http://www.di.ubi.pt/agomes/cvm/teoricas/07-regionsegmentation.pdf>. (accessed November 3, 2017)
- [23] Warhols, Andy, and Lars Aurdal. 2006. “ Image segmentation beyond thresholding (or how to understand). ”
- [24] Vision, Computer. 2012. “ Segmentation and Clustering. ”

Bibliografia complementària

Pravin, B. Pokle, and G. Bawane Narendra. 2013. “Comparative Study of Various Image Segmentation Techniques.” *IJSER- International Journal of Scientific & Engineering Research* 4 (5): 77-79.

Khan, a.M. 2013. “Image Segmentation Methods: A Comparative Study.” *International Journal of Soft Computing and Engineering (IJSCE)* 3 (4): 84-92. DOI: 10.1117/1.2762250.

Mcinerney, Tim, and Demetri Terzopoulos. 1996. “ Deformable Models in Medical Image Analysis: A Survey” 1 (2): 91-108.

Albregtsen, Fritz. 2010. “INF 4300 - Digital Image Analysis. Region & Edge Based Segmentation” 7.

Chuang, Keh-shih, Hong-ong Tzeng, Sharon Chen, Jay Wu, and Tzong-ger Chen. 2006. “Fuzzy c-Means Clustering with Spatial Information for Image Segmentation” 30:9-15. DOI: 10.1016/j.compmedimag.2005010.001.

Iglesias, Juan Eugenio, Mert R Sabuncu, Massachusetts General Hospital, and Harvard Medical. 2016. “HHS Public Access” 24 (1): 205-19. DOI: 10.1016/j.media.2015.06.012.Multi-Atlas.

Wesley, Addison. 1996. "Filtrado de Imágenes", 25-48.

Muñoz, José. n.d. "Segmentación de Imágenes 6.1 Introducción." *Universidad de Málaga*.

Rueda, Andrea. n.d. "Segmentación de Imágenes Parte 1 Visión Artificial Introducción."

Sharma, Neeraj, AmitK Ray, KK Shukla, Shiru Sharma, Satyajit Pradhan, Arvind Srivastva, and LalitM Aggarwal. 2010. "Automated Medical Image Segmentation Techniques." *Journal of Medical Physics* 35 (1): 3. DOI: 10.4103/971-6203.58777.

ANNEX A

Codis de Matlab

- Codi per a llegir les imatges d'un determinat directori:

```
%Llegim les imatges del directori que nosaltres designem

ImgCarpeta = dir('C:\Users\UPC-ESAI\Dropbox (Personal)\
TFG\TFG\fotos\IMGDESEMBRE17\imgCor\*.png');

% Creem un vector cell amb la mateixa mida que la carpeta
on tenim les imatges

filename = cell(length(ImgCarpeta),1);

% Anem llegint les imatges que es troben al directori i les
guardem al vector filename

for i = 1 : 500

    filename{i} = imread(['C:\Users\UPC-ESAI\Dropbox (Personal)\
TFG\TFG\fotos\IMGDESEMBRE17,ImgCarpeta(i).name]);

end

% Creem un vector per a les imatges de sortida

ImgSortida = cell (499,1);

% Processem totes les imatges de la carpeta amb la funció
SegmentacioImg

for i = 1:499
```

```
[ImgSortida{i}] = SegmentacioImg (filename{i});  
end
```

- Codi de la funció que processa les imatges:

```
function [ImgFinal] = SegmentacioImg (Img)
```

Les imatges que processem són en escala de grisos. És per aquest motiu que no utilitzem la funció **rgb2gray** de MATLAB que passaria les imatges RGB a imatges en escala de grisos. Si fossin imatges RGB s'hauria de fer aquesta conversió per tal de poder portar a terme aquesta part del codi.

```
% Es porta a terme un filtrat de la imatge. El valor de cada  
píxel serà el de la mitjana dels 8 píxels del seu voltant
```

```
Img2 = medfilt2(Img);
```

```
% S'ajusta l'histograma de la imatge. Es trien els píxels amb  
intensitat de 0.1 a 0.5 i es porta a terme una rehistogramació on,  
per defecte, els valors de sortida són 0 i 1.
```

```
Img2 = imadjust(Img2,[0.1 0.5]);
```

```
% Es porta a terme un gradient morfològic. És la diferència entre  
la dil·latació i l'erosió de la imatge
```

```
SE = strel('square', 3);  
dImg2 = imdilate(Img2,SE);  
se = strel('square', 3);  
eImg2 = imerode(Img2,se);  
Img2 = dImg2 - eImg2;
```

```
% Es binaritza la imatge en escala de grisos
```

```
Img2 = imbinarize(Img2)
```

% Amb la funció `bwareaopen` de MATLAB s'eliminen els conjunts de píxels més petits que el valor designat, en aquest cas, 1000 píxels.

```
Img2 = bwareaopen(Img2,1000);
```

% Per tal d'eliminar els petits forats que es puguin trobar al contorn, es porta a terme l'operació de tancament morfològic que consisteix en portar a terme una dilatació i una posterior erosió.

```
SE1 = strel('rectangle',[3 4]);
```

```
Img2 = imdilate(Img2,SE1);
```

```
SE2 = strel('diamond', 1);
```

```
Img2 = imerode(Img2,SE2);
```

% S'etiqueten tots els conjunts de píxels trobats.

```
labeledImage = bwlabel(Img2);
```

% Amb l'eina `regionprops` de MATLAB es troben els centroides (coordenades X i Y de tots els conjunts de píxels obtinguts anteriorment).

```
measurements = regionprops(labeledImage, 'Centroid');
```

% Es guarden els centroides dels conjunts en un vector.

```
centroids = [measurements.Centroid]
```

```
xCentroids = centroids(1:2:end);
```

```
yCentroids = centroids(2:2:end);
```

% Es calculen les distàncies entre cada centroide i el centre de la imatge. Quedaran guardades en el vector "distances".

```
distances = sqrt(((size(labeledImage,2))\2-xCentroids).^ 2 +  
((size(labeledImage,1))\2-yCentroids).^ 2));
```

% El conjunt de píxels final serà aquell que tingui la distància al centre més petita. A `minDistance` es trobarà el valor de la distància menor i a `indexOfMin` es trobarà el valor de l'etiqueta del conjunt

de píxels.

```
[minDistance, indexOfMin] = min(distances);
```

```
% El centralBlob serà com s'anomenarà al conjunt de píxels que  
s'ha determinat com a més pròxim al centre de la imatge.
```

```
centralBlob = labeledImage == indexOfMin;
```

```
% Finalment, obtenim la imatge de sortida.
```

```
ImgFinal = centralBlob
```

- Codi de la funció que redueix el nombre de punts del contorn:

```
% Es crea una matriu de zeros amb les mateixes dimensions en x  
i en y de la imatge inicial.
```

```
J=zeros(size(BW,1),size(BW,2));
```

```
% Es crea una altra matriu amb les mateixes dimensions que la  
imatge inicial. Aquesta és la matriu on quedaran reflexats els  
diferents contorns amb les etiquetes.
```

```
A=zeros(size(BW,1),size(BW,2));
```

```
% Ara es declaren les variables:
```

```
row = ceil(size(BW,1)/2);
```

```
lbl=0; % La primera etiqueta és 0.
```

```
MMax = []; % Matriu que mostra quins píxels estan pintats.
```

```
nMax = 0; % Nombre de píxels pintats.
```

```
tmin=30;
```

```
% El pas següent consisteix en cercar algun punt amb valor 1 dins  
de la imatge binària per després fer créixer per continuïtat la  
regió
```

```
for i = 1:1:size(BW,2)
```

```
    if (BW(row,i)>0)&&(A(row,i)==0)
```

```
lbl=lbl+1; % Passem el valor de la màscara de 0 a 1.
```

Ara cridem a la funció **creixerRegio**

```
[M,n,A,flcorrecte]=creixerRegio(BW,A,row,i,lbl);
if (flcorrecte==1) && (n>nMax)
    nMax=n;
    MMax=M;
end
end
end
```

- Codi de la funció **creixerRegio** que permetrà obtenir el contorn total a partir d'un punt trobat a la imatge que pertanyi al contorn.

```
[M,n,Aout, fcorrecte]=creixerRegio(J,Ain,x,y,lbl)
% A partir del primer píxel donat, retorna una llista de les coordenades
de tots els píxels. Aquesta funció utilitza Ain com a màscara per
tal de saber si un píxel ha estat avaluat anteriorment.
```

```
M=[x;y];
MM=[x;y];
Aout=Ain;
Aout(x,y)=lbl;
n=1;
DD=[-1 -1 -1 0 0 1 1 1;-1 0 1 -1 1 -1 0 1];
fcorrecte = 1;
while(size(MM,2)>0)
    for i=1:size(DD,2)
        if ((MM(1,1)+DD(1,i)>5) && (MM(2,1)+DD(2,i)>5) && (MM(1,1)+DD(1,i)
<=size(J,1)-5) && (MM(2,1)+DD(2,i)<=size(J,2)-5) && (J(MM(1,1)+DD(1,i),MM(2,1)
+DD(2,i),1)>0) && (Aout(MM(1,1)+DD(1,i),MM(2,1)+DD(2,i))==0))
            MM=[MM [MM(1,1)+DD(1,i);MM(2,1)+DD(2,i)]];
        end
    end
```

```
Aout (MM(1,1)+DD(1,i),MM(2,1)+DD(2,i))=1b1;  
M=[M [MM(1,1)+DD(1,i);MM(2,1)+DD(2,i)]];  
n=n+1;  
    elseif ((MM(1,1)+DD(1,i)<5) || (MM(2,1)+DD(2,i)<5) || (MM(1,1)  
+DD(1,i)>size(J,1)-5) &&  
(MM(2,1)+DD(2,i)>size(J,2)-5))  
        fcorrecte = 0;  
        break;  
    end  
end  
if fcorrecte==0  
    break;  
    MM=MM(:,2:size(MM,2));  
end  
end
```