



EPS

Escola Politècnica

UdG

Superior

Projecte/Treball Fi de Carrera

Estudi: Eng. Tècn. Informàtica de Sistemes. Pla 2001

Títol: Segmentació de teixit i lesions en imatges de MRI de malalts d'esclerosi múltiple

Document: Memòria

Alumne: Miguel Angel Doblado Pedrosa

Director/Tutor: Xavier Lladó, Jordi Freixenet

Departament: Arquitectura i Tecnologia de Computadors

Àrea: Arquitectura i Tecnologia de Computadors

Convocatòria (mes/any): 09/2009

Agraïments

Des d'aquí, manifesto el meu agraïment a tota la gent que ha col·laborat en aquest projecte. Començant pels meus dos directors, en Jordi, per la confiança dipositada a l'hora d'afrontar aquest projecte, i en Xavier, per tenir sempre una resposta a les meves constants consultes interrompent la seva feina. També vull expressar el meu agraïment a tots els membres del grup VICOROB, en especial a en Mariano, per la seva ajuda en el treball de camp, i l'Arnau, sempre donant els seus interessants punt de vista. Cal agrair també, a les persones que ens han proporcionat la informació del tema tractat al projecte, els neuròlegs i radiòlegs, de la Clínica Girona, l'Hospital Universitari de Girona Dr. Josep Trueta i l'Hospital Vall d'Hebron. També vull agrair a en Martí per tots els seus consells i ajuda amb \LaTeX . En definitiva, a tota la gent que m'ha donat suport d'algun tipus durant el desenvolupament d'aquest projecte.

Índex

1	Introducció	10
1.1	Antecedents	10
1.2	Objectius	11
1.3	Abast	14
1.4	Planificació	15
1.4.1	Organització	15
1.4.2	Calendari	17
1.5	Estructura del document	17
2	Coneixements i conceptes previs	20
2.1	Fonaments teòrics	20
2.1.1	El cervell humà	21
2.1.2	MRI. Magnetic Resonance Imaging	22
2.1.3	EM. Esclerosi Múltiple	23
2.1.4	La visió per computador i el processament d'imatges en el camp de les MRI	25
2.2	Estat actual	30
2.2.1	Estudi previ	30
2.2.2	Valoració	32

3	ADI del sistema de segmentació	34
3.1	Anàlisi del sistema de segmentació	34
3.2	Preprocessat	36
3.2.1	Reducció de soroll	36
3.2.2	Reducció del <i>bias</i>	38
3.2.3	Extracció de la regió d'interés. El cervell	39
3.3	Segmentació	40
3.3.1	Selecció de les llavors	41
3.3.2	Region Growing	42
3.3.3	Adaptació del Region Growing. Desenvolupament Uni- modalitat	60
3.3.4	Adaptació del Region Growing. Desenvolupament Mul- timodalitat	69
3.3.5	Segmentació de lesions amb Region Growing	70
4	Resultats	72
4.1	Tipus de dades	72
4.2	Metodologia d'avaluació	74
4.2.1	Ground truth	74
4.2.2	Avaluació a nivell de vòxel	74
4.2.3	Coefficients d'avaluació	75
4.3	Resultats Sintètics	76
4.3.1	Robustesa davant del soroll	77
4.3.2	Robustesa davant del <i>bias</i>	86
4.3.3	Cost computacional	95
4.4	Combinació de modalitats	95
4.5	Resultats cas real	97
4.6	Segmentació de lesions	98

5	Interfície gràfica	100
5.1	Anàlisi de requeriments	100
5.2	Disseny	101
5.2.1	Diagrames de cas d'ús	101
5.2.2	Diagrames d'activitat	101
5.3	Implementació	102
6	Conclusions i treballs futurs	109
6.1	Conclusions extretes a partir del projecte	109
6.2	Treballs futurs	111
A	Manual d'usuari de la toolbox de matlab	113
A.1	Funcions d'obtenció de les dades	113
A.1.1	llegirRAW	113
A.1.2	load_nii	114
A.2	Funcions de preprocessat	115
A.2.1	wavelet_denoise	115
A.2.2	eliminar_crani	115
A.3	Funcions de segmentació	116
A.3.1	regionGrowing_global	116
A.3.2	regionGrowing_global_min	117
A.3.3	regionGrowing_local_particions	117
A.3.4	regionGrowing_local_finestra	118
A.3.5	regionGrowing_multimodalitat	119
A.4	Funcions d'avaluació del resultat	119
A.4.1	comparar	119
B	Manual d'usuari de la interfície gràfica	121
B.1	Descripció de la interfície	121

B.2	Utilització de la interfície	123
B.2.1	Explorar volums	123
B.2.2	Segmentar volums	124

Índex de figures

1.1	MRI	10
1.2	Informació útil i informació poc rellevant	11
1.3	Segmentació de teixits. Imatge d'entrada i de sortida	12
1.4	Segmentació de lesions. Imatge d'entrada i de sortida	12
1.5	Planificació. Diagrama de Gantt	18
2.1	Detall dels teixits del cervell	21
2.2	Escàner de MRI	22
2.3	Diferents modalitats de MRI	23
2.4	Ubicació de les lesions. Imatge total i de les lesions	25
2.5	Resolució espacial en les MRI	26
2.6	Distorsió. Soroll i <i>bias</i>	27
2.7	Pipeline del procés de treball	32
3.1	Pipeline del sistema de segmentació	35
3.2	Detall dels teixits del cervell	37
3.3	Reducció de soroll	38
3.4	Reducció de <i>bias</i>	39
3.5	Extracció de la regió d'interés	40
3.6	Connectivitats possibles en 2D	43
3.7	Creixement del Region Growing en 2D	43

3.8	Connectivitats possibles en 3D	44
3.9	Creixement del Region Growing en 3D	44
3.10	Diagrama del Region Growing Bàsic	46
3.11	Segmentació amb Region Growing	47
3.12	Histogrames: Soroll 0% Bias 0%	48
3.13	Histogrames: Soroll 9% Bias 0%	49
3.14	Histogrames: Soroll 0% Bias 40%	50
3.15	Histogrames: Soroll 9% Bias 40%	51
3.16	Llegenda de la representació de solapaments	53
3.17	Solapaments: Soroll 0% Bias 0%	54
3.18	Solapaments: Soroll 9% Bias 0%	55
3.19	Solapaments: Soroll 0% Bias 40%	56
3.20	Solapaments: Soroll 9% Bias 40%	57
3.21	Distribució normal	62
3.22	Modificació de la llavor	63
3.23	Diagrama del Region Growing: llavor variable. Estadístic: Desviació (Global)	65
3.24	Subvolums	67
3.25	Estadístic pels subvolums	67
3.26	Finestra	68
3.27	Mètode multimodalitat	69
4.1	Avaluació dels vòxels	75
4.2	Avaluació de la matèria blanca amb estadístic global	78
4.3	Avaluació de la matèria gris amb estadístic global	80
4.4	Avaluació del CSF amb estadístic global	81
4.5	Avaluació de la matèria blanca amb estadístic local	83
4.6	Avaluació de la matèria gris amb estadístic local	84

4.7	Avaluació del CSF amb estadístic local	85
4.8	Avaluació de la matèria blanca amb estadístic global	87
4.9	Avaluació de la matèria gris amb estadístic global	89
4.10	Avaluació del CSF amb estadístic global	90
4.11	Avaluació de la matèria blanca amb estadístic local	91
4.12	Avaluació de la matèria gris amb estadístic local	93
4.13	Avaluació del CSF amb estadístic local	94
4.14	Avaluació de la combinació de modalitats	96
4.15	Segmentació en cas real	98
4.16	Segmentació d'una lesió	99
5.1	Diagrama de casos d'ús	101
5.3	Slice Viewer 3D per Marian Uhercik	104
5.2	Diagrama d'activitat	106
5.4	Interfície gràfica. Vista original	107
5.5	Interfície gràfica. Vista segmentat	108
B.1	Descripció de la interfície	122

Índex de taules

3.1	Valors de connectivitat dels diferents teixits	59
5.1	Especificació del cas d'us Segmentar Volums	102
5.2	Especificació del cas d'us Canviar Vista	103

Capítol 1

Introducció

1.1 Antecedents

Actualment, en l'àmbit mèdic, la ressonància magnètica, MRI Magnetic Resonance Imaging, és un dels sistemes més utilitzats per a la realització de diagnòstics i el seguiment de l'evolució de malalties com l'esclerosi múltiple (EM). No obstant, la gran quantitat d'informació que proporciona aquesta modalitat té com a conseqüència una tasca feixuga d'anàlisi i d'interpretació per part dels radiòlegs i neuròlegs.

Explicat amb un exemple, els metges es troben davant d'imatges com les de la figura 1.1.





Figura 1.1: Imatge típica d'una MRI

Aquesta imatge, d'entrada, es pot dividir en 2 grans blocs d'informació: Informació útil, a la figura 1.2(a) i informació poc rellevant, a la figura 1.2(b).



(a) Part de la imatge que ens proporciona informació sobre la malaltia
(b) Part de la imatge que no ens proporciona cap informació sobre la malaltia


Figura 1.2: Tot i que en aquesta imatge la diferència es força clara, en altres de les MRI, on per exemple apareixen els ulls, la distinció no és tant evident

A més a més, unes zones del cervell tenen més probabilitats que d'altres de patir lesions d'escleròsi múltiple degut a la naturalesa d'aquesta malaltia i, per tant, també és d'agraïr disposar d'aquesta informació. El problema surgeix quan aquesta tasca s'ha de realitzar manualment. S'ha de tenir en compte que una resonància magnètica és un volum, és a dir, un conjunt d'imatges de llesques, en aquest cas del crani humà. Habitualment són algunes desenes de captures, motiu pel qual es necessita un temps considerable de dedicació exclusiva d'una persona molt qualificada per a cada volum. En els pròxims capítols s'entrarà en detall de les diferents zones i de la seva rellevància en la malaltia que s'està tractant.

1.2 Objectius

L'objectiu general d'aquest projecte és desenvolupar un sistema per ajudar als metges a segmentar les imatges de MRI del cervell. Es posarà especial


èmfasi en la segmentació dels diferents teixits, als quals s'ha fet referència abans amb el nom de zones, figura 1.3, però també es tractaran les lesions que apareixen com a conseqüència de l'esclerosi múltiple, figura 1.4. Els teixits són la matèria gris, la matèria blanca i el líquid cerebrospinal, mentre que les lesions són unes taques clares que apareixen, sovint, en la matèria blanca del cervell.



(a) Imatge d'entrada

(b) Imatge de sortida

Figura 1.3: En aquesta imatge s'il·lustra l'objectiu d'aquest projecte pel que fa al segmentat de teixits. Amb una imatge del tipus (a) es vol aconseguir una del tipus (b), el qual seria el resultat ideal.



(a) Imatge d'entrada

(b) Imatge de sortida

Figura 1.4: En aquesta imatge s'il·lustra l'objectiu d'aquest projecte pel que fa al segmentat de lesions. Amb una imatge del tipus (a) es vol aconseguir una del tipus (b), el qual seria el resultat ideal.

Segmentar una imatge, com s'observa a les figures 1.3(b) i 1.4(b), vol dir separar les regions que formen cada teixit. Per fer-ho, a cada teixit se

li assigna un valor, també conegut com etiqueta, i llavors, a cada vòxel del volum se l'atribueix una d'aquestes etiquetes, corresponent a la del teixit del qual es decideix que forma part. A les imatges referenciades anteriorment, cada etiqueta es representa amb un color diferent. La segmentació s'explica amb més detall a la secció 2.1.4.

Per assolir aquest objectiu general s'ha decidit dividir el projecte en objectius més concrets.

Estudi de l'estat actual dels sistemes de segmentació de MRI.

Per poder enfocar el projecte correctament, primer, cal fer un estudi dels mètodes que s'estan utilitzant en l'actualitat per intentar resoldre el problema que s'està tractant, amb la intenció de veure quins d'ells donen millors resultats. Això també aportarà un important estalvi de temps ja que evitarà intentar estratègies que s'ha demostrat, prèviament, que no funcionen.

Segmentar utilitzant diferents tipus de modalitats de MRI.

En l'actualitat existeixen diferents modalitats de MRI. Cadascuna d'elles destaca característiques diferents de la matèria. L'objectiu és ressaltar la informació rellevant que cada modalitat, per separat, aporta al diagnòstic de l'EM.

Segmentar combinant diferents tipus de modalitats de MRI.

Un cop assolida la fita anterior, es procedirà a combinar les diferents modalitats en un mateix mètode, amb l'esperança d'obtenir més informació pel fet d'aquesta combinació i també d'aconseguir més robustesa en els mètodes.

Comparar dos volums del mateix pacient obtinguts en diferents

dates. En tota malaltia és important, per als professionals mèdics,

poder fer un seguiment de la seva evolució. L'objectiu és, desenvolupar un mètode que ajudi a comparar, temporalment, l'evolució de dues MRI d'un mateix pacient.

Crear una interfície gràfica que integri tots els mètodes. Aquesta part es dissenyarà i s'implementarà per millorar l'experiència d'usuari dels metges i reduir el temps d'aprenentatge necessari per a poder utilitzar els diferents mètodes. D'aquesta manera podran fer servir les eines realitzades d'una forma més fàcil i intuïtiva.

1.3 Abast

Aquest projecte de final de carrera s'enmarca dins d'un projecte de recerca del grup de Visió per Computador i Robòtica de la Universitat de Girona. Aquest grup disposa d'experiència en la recerca de l'àmbit mèdic, i recentment, ha afegit una nova línia de recerca dedicada a l'esclerosi múltiple.

El resultat del PFC serà doncs, un programari instal·lat en un sol PC que estarà a disposició de l'equip de metges per aquesta fase de proves.

Per desenvolupar aquest projecte s'utilitzarà MATLAB, una eina molt utilitzada en el món de la recerca, la qual disposa de moltes llibreries que faciliten la feina d'implementació. Aquest software és de la companyia Mathworks i no és lliure.

Durant tot el procés s'utilitzaran dades sintètiques i reals.

Les dades sintètiques. BrainWeb. BrainWeb [1] és una base de dades simulada on es poden trobar diferents volums de MRI. Ofereix tant volums completament sans com volums amb lesions i diferents diferents

modalitats. A més a més, disposa d'un simulador en el qual es pot demanar un volum configurant els paràmetres de la ressonància segons la necessitat. S'hi pot accedir mitjançant web:

<http://www.bic.mni.mcgill.ca/brainweb>. Aquesta base de dades la proporciona el McConnell Brain Imaging Centre (BIC) of the Montreal Neurological Institute de la McGill University. Aquest tipus de dades són molt útils en la recerca perquè faciliten la validació dels mètodes implementats, ja que coneixem el resultat ideal amb anterioritat.

Les dades reals. Clínica Girona. Les dades reals seran proporcionades pel grup de metges col·laboradors amb el projecte del grup VICOROB que formen part de la Clínica Girona i l'Hospital Universitari de Girona Dr. Josep Trueta. Concretament el cas real exposat a la memòria ha estat proporcionat per la Clínica Girona. Prèviament, totes les dades han estat sotmeses a un procés per garantir-ne l'anonimat.

1.4 Planificació

1.4.1 Organització

1. **Familiarització amb els tipus de dades. Formats i eines disponibles.** Com en aquest camp els tipus de dades són molt diversos i força específics per a cada aplicació desenvolupada, caldrà un temps d'adaptació a la manipulació d'aquestes dades. Des d'extreure les dades fins a la conversió d'uns formats en uns altres.
2. **Adaptació de les eines de preprocessat.** En alguns casos les eines de preprocessat disponibles no s'acaben d'adequar a les necessitats i per això s'hauran de fer alguns canvis. Principalment, es necessitarà

modificar aquestes eines per a que treballin en tres dimensions, ja que la majoria ho fan amb dues.

3. **Estudi de les dades disponibles.** Un cop amb les dades apunt per treballar caldrà estudiar-les amb l'objectiu d'extreure característiques rellevants que ajudin a la segmentació.
4. **Estudi dels algorismes de segmentació.** Els algorismes de segmentació estan força desenvolupats, caldrà decidir segons les seves característiques, juntament amb l'estudi de les dades anteriors, quin d'ells es prendrà com a base per desenvolupar el sistema.
5. **Implementació de la 'pipeline' de segmentació.** En aquest punt s'haurà d'automatitzar tot el procés i desenvolupar diferents algorismes.
6. **Anàlisi de resultats.** Un cop desenvolupat el sistema serà necessari fer un joc de proves per observar els resultats i les diferències entre els diferents mètodes.
7. **Integració en una interfície gràfica.** Per facilitar la tasca als metges, es dedicarà un temps a integrar el sistema en una interfície gràfica que permeti explorar les imatges, executar la segmentació i veure'n els resultats.
8. **Documentació.** A mida que s'avanci en el desenvolupament del projecte es redactarà una documentació en la qual s'expliqui amb detall tot el que s'ha fet. Aquesta documentació s'ha realitzat amb el processador de textos \LaTeX .

1.4.2 Calendari

A la figura 1.5 és pot observar la durada de cada una de les tasques del projecte, mostrades amb un diagrama de Gantt.

1.5 Estructura del document

El document s'estructurarà de la manera següent:

Capítol 1. Introducció. S'introdueix el projecte i s'explica el motiu pel qual s'ha decidit dur a terme. Després es fa un resum dels objectius. També es situa el projecte en el seu marc de treball, és a dir, on es desenvolupa, a qui va dirigit, eines i dades utilitzades.

Capítol 2. Fonaments teòrics i estat actual. S'explica la teoria necessària per a poder desenvolupar el projecte. Això inclou aspectes com la representació de les dades, el concepte de segmentació i diferents estratègies per aconseguir segmentar una imatge, entre d'altres. Tot això s'explica sobre imatges del tema tractat, i fent balanç de les avantatges i els inconvenients de cadascun. Un cop introduïts aquests conceptes es fa un breu repàs de l'estat actual dels sistemes de segmentació de MRI, que s'acompanya d'una discussió que condueix al desenvolupament del projecte.

Capítol 3. Anàlisi, disseny i implementació. Un cop descrita la situació actual, se'n fa una anàlisi per decidir com s'aconseguiran els objectius del projecte. Tot això implica posar a sobre de la taula el problema, recopilar els requeriments, fer un disseny i implementar-lo. Es segueix un desenvolupament iteratiu i incremental. És a dir, un cop resolta la part de la implementació, si el resultat no és prou bo, es torna




Figura 1.5: Planificació. Diagrama de Gantt

a la fase d'anàlisi, es redissenya el sistema i es torna a implementar fins a aconseguir un resultat acceptable.

Capítol 4. Resultats. Es mostren tots els resultats obtinguts en els diferents mètodes implementats. De tot això s'en fa una discussió mostrant els encerts i desencerts de cadascun.

Capítol 5. Interfície. S'explica com es construeix una interfície gràfica que integra els mètodes desenvolupats, des del punt de vista de l'enginyeria del software.

Capítol 6. Conclusions i treballs futurs. S'extreuen conclusions i es suggereixen una sèrie de treballs futurs per continuar la línia d'aquest projecte.

Capítol 2

Coneixements i conceptes previs

2.1 Fonaments teòrics

Per a poder dur a terme aquest projecte cal tenir en compte un seguit de coneixements i conceptes previs que fan referència a l'objecte tractat, a l'obtenció de les dades, a la interpretació d'aquestes, a com es reflecten les patologies en elles i també a molts altres conceptes del camp del processat d'imatge mitjançant computadors. Al principi d'aquest capítol s'explica breument l'estructura fisiològica del cervell. Després, es fa una repassada de la tècnica amb la que s'obtenen les MRI. A continuació es donen a conèixer alguns aspectes que cal conèixer sobre l'esclerosi múltiple i el seu diagnòstic. Més endavant, es mostren alguns conceptes de la visió per computador i el processament en el camp de les MRI i, finalment, es comenta l'estat actual dels sistemes que persegueixen el mateix objectiu que aquest projecte.

2.1.1 El cervell humà

Pel que afecta a aquest projecte l'aspecte de la composició del cervell que cal conèixer és que està format per 3 teixits principals, la matèria blanca, la matèria gris i el líquid cerebrospinal. S'il·lustra a la figura 2.1.




Figura 2.1: A les imatges (b), (c) i (d) es remarca en blanc la part corresponent.

Matèria Blanca. S'extén uniformement entre el còrtex cerebral y els nuclis centrals. Es compona, principalment, de fibres nervioses amielíniques que conecten entre ells diversos punts del còrtex i els nuclis del neuroeix. Es distribueix en làmines, aproximadament verticals.

Matèria Gris. També coneguda com a còrtex cerebral, és la part exterior del cervell té una espesor de 2 o 3 mm, està format per unes capes de cèl·lules amielíniques, sense baina que les cobreixi. Degut als nombrosos plects que presenta, la superfície cerebral és unes 30 vegades més gran

que la superfície del crani. Aquests plecs formen les circumvolucions cerebrals, solcs i fisures i delimiten àries amb funcions determinades.

Líquid cerebrospinal. Circula per l'interior dels ventrícles, situats a la part més interna del cervell, i també envolta tot el sistema nerviós central per protegir-lo de canvis bruscs de pressió i per transportar substàncies químiques.

2.1.2 MRI. Magnetic Resonance Imaging


Magnetic Resonance Imaging, MRI, també coneguda com a ressonància magnètica és una tècnica d'imatge mèdica molt utilitzada en radiologia per visualitzar l'estructura interna del cos humà. Aquesta tècnica ofereix molt més contrast entre els diferents teixits que d'altres i, a més a més, no emet radiació. Les imatges s'obtenen enregistrant la resposta dels àtoms d'hidrogen després de ser alineats mitjançant diferents camps magnètics. L'aparell utilitzat es mostra a la figura 2.2.



Figura 2.2: Scanner MRI modern de 3 tesles. [12]


Depenent de com es magnetitza i de la característica que s'obté, les MRI es divideixen en diferents modalitats. Els contrastos s'aconsegueixen gràcies a la diferència d'àtoms d'hidrògen que hi ha entre els diferents tipus de teixits,

que fa variar la resposta. Les utilitzades en aquest projecte són T1, T2 i PD (proton density). Tot seguit, a la figura 2.3 s'en mostren exemples.



(a) Modalitat T1

(b) Modalitat T2



(c) Modalitat PD

Figura 2.3: A les imatges (a), (b) i (c) s'observen els diferents contrastos obtinguts segons la modalitat utilitzada.

S'observa que unes modalitats ofereixen més contrast que d'altres i també que les mateixes regions estan representades amb nivells alts d'intensitat o baixos, és a dir, en el que una modalitat apareix de color fosc en una altra apareix de color clar, de forma aproximadament complementària.

2.1.3 EM. Esclerosi Múltiple


La malaltia

L'esclerosi múltiple, EM, és una malaltia on el sistema immunitari ataca el sistema nerviós central, produint la desmielinització. Aquesta malaltia succeeix en adults joves i és més freqüent entre les dones. Segons les estadístiques

afecta entre un 2 i un 150 per 100.000 de la població [7]. L'EM disminueix la capacitat de les neurones del cervell i de la medul·la espinal per comunicar-se. Les neurones es comuniquen enviant senyals elèctrics, anomenats potencials d'acció, per unes fibres, els axons, que estan envoltades d'una substància anomenada mielina. En la EM, el propi sistema immunitari del cos ataca i fa mal bé la mielina. Quan aquesta es perd, els axons no poden transmetre els senyals correctament. Tot i que hi ha molts aspectes coneguts sobre els mecanismes involucrats en el procés de la malaltia, la causa encara és desconeguda. Hi ha teories que inclouen la genètica o infeccions. També s'han trobat diferents factors relacionats amb riscos mediambientals.

El diagnostic mitjançant MRI

L'EM pot ser molt difícil de diagnosticar perquè els signes i els símptomes poden ser similars a altres problemes mèdics. El nom d'esclerosi múltiple es refereix a "scars", cicatrius, més conegudes en aquest camp com a plaques o lesions. Aquestes plaques es produeixen en la matèria blanca del cervell i en la medul·la espinal, que està majoritàriament composta de mielina. Les lesions apareixen en les MRI degut a la manca d'aquesta, perquè fa que hi hagi un canvi en la composició de la matèria, la qual respon diferent a la incidència dels camps magnètics. Això es pot observar a la figura 2.4.




(a) Imatge amb lesions (b) Situació de les lesions

Figura 2.4: En la imatge (a) es pot veure una imatge típica amb lesions i en la (b) a on es troben.

2.1.4 La visió per computador i el processament d'imatges en el camp de les MRI

En l'actualitat tota la informació de les imatges es digitalitza. El fet de digitalitzar la informació permet fer un tractament mitjançant un computador, però a la vegada produeix unes limitacions.

Les imatges es representen mitjançant matrius de píxels. Cada unitat de superfície està representada per un nombre de píxels. A major nombre de píxels per la mateixa unitat de superfície major serà la resolució espacial. En el cas de les MRI es treballa en tres dimensions, i enlloc de píxels es parla de vòxels. La tridimensionalitat s'aconsegueix posant, en l'ordre correcte, un conjunt d'imatges de dues dimensions unes a sobre de les altres. Les imatges que s'obtenen són plans com els que s'han vist anteriorment. A aquestes imatges se'ls farà referència amb el nom de llesques. En les imatges sintètiques la distància entre aquestes llesques és d'1 mm però en les reals normalment és de 3 mm, fet que provoca una mena de pèrdua de resolució espacial. Es pot observar a la figura 2.5.




(a) Imatge amb resolució 1 mm (b) Imatge amb resolució 3 mm

Figura 2.5: En aquest pla del cervell es veu la distància que existeix entre les llesques en una imatge real, figura (b) tot i que, s'ha modificat una imatge sintètica, figura (a), perquè la comparació sigui més clara.

D'altra banda, en el cas de les MRI, la representació es fa en nivell de grisos. La gamma de grisos diferents de que es disposa depèn de la quantitat de bits que es fan servir per representar cada vòxel. Si es fa servir un bit, el 0 representarà el negre i l'1 el blanc. Si es fan servir 2 bits, el 0 serà el negre, l'1 un gris fosc, el 2 un gris clar i el 3 el blanc. D'aquesta manera, en les imatges MRI s'aconsegueix una gamma de 4096 nivells de gris diferent (12 bits). Aquest nombre és molt major al que és capaç de distingir l'ull humà, i per tant és una avantatge que ofereix la visió per computador. Això s'anomena la resolució en amplitud o profunditat.

En els processos d'adquisició de les imatges apareixen alguns fenòmens que distorsionen la informació. En el cas de les MRI els més importants són el soroll i el *bias*. En les imatges de la figura 2.6 es mostra gràficament la distorsió creada per aquests fenòmens.



(a) Imatge ideal

(b) Imatge amb soroll

(c) Imatge amb *bias*

Figura 2.6: A la imatge (b) es poden veure uns vòxels que apareixen aleatòriament per tota la imatge, mentre que a la imatge (c) s'observa que es va enfosquint de dreta a esquerra.

LA SEGMENTACIÓ

La segmentació d'una imatge és la divisió de la imatge en un conjunt de regions no solapades les quals formen la imatge sencera. L'objectiu es descomposar la imatge en parts que tinguin un significat per a una aplicació particular. Per exemple, una regió pot correspondre a un objecte de la realitat.

És molt complex decidir amb una computador què té significat i què no. Enlloc d'això els procediments de segmentació tendeixen a obeir les següents regles [17].

1. Les regions han de ser uniformes i homogènies respecte alguns característics, com el nivell de gris o la textura.
2. Les regions interiors haurien de ser simples i sense gaires forats.
3. Les regions adjacents d'una segmentació haurien de tenir diferents valors respecte del característic pel qual elles son uniformes.
4. Les fronteres de cada part segmentada haurien de ser simples i precises.

ESTRATEGIES DE SEGMENTACIÓ

Per aconseguir segmentar una imatge es poden fer servir diferents estratègies.

Mètodes basats en regions. En aquests mètodes es decideix si un píxel forma part d'una regió principalment fent ús de dos criteris. El primer d'ells és la connectivitat, és a dir, perquè un píxel/vòxel pertanyi a una regió ha de tenir un d'adjacent que també ho faci. A més a més, el píxel ha de complir un criteri, de similitud, per un estadístic obtingut a partir dels píxels que ja formen part de la regió. Dos dels mètodes més coneguts són el Region Growing i l'Split and Merge [17].

Mètodes basats en clustering. Una altra manera de segmentar una imatge és fent servir el seu espai de mesures. Mitjançant aquesta opció es dona més importància al valor de cada píxel/voxel que a la seva situació espacial. Per exemple, en el cas de les MRI, l'espai de mesures seria el rang de nivells de grisos que prenen per valor els voxels. Una opció seria, ja que volem obtenir 4 regions diferents, matèria blanca, matèria gris, líquid cerebrospinal i exterior, dividir aquest rang en 4 classes i assignar els vòxels a un teixit en funció del seu valor. És evident que això no donarà un resultat òptim. Per això existeixen molts mètodes que treuen més partit d'aquesta informació. A vegades s'han de combinar per a poder tenir en compte la informació espacial que, per definició, no utilitzen. L'algorisme més conegut rep el nom de K-means [17].

Mètodes basats en l'extracció de contorns. En aquest cas s'intenta simplificar la imatge utilitzant un filtratge que en destaquï els contorns. Per fer això es comprova si hi ha una diferència important entre un píxel/vòxel i l'adjacent. Per tant, es realitza un escombrat en una

direcció concreta. Per obtenir contorns en diferents direccions cal fer més d'un escombrat canviant la direcció. Aquesta direcció es defineix en el filtre. Els filtres més coneguts són el Sobel, Prewitt i Roberts [9].

Mètodes basats en models matemàtics. A vegades, la naturalesa de la imatge fa que s'assembli a un model determinat. Llavors s'intenta adaptar al màxim la imatge a aquest model per aconseguir la segmentació [21].

Mètodes basats en històrics (atlas). Són mètodes que necessiten del coneixement d'imatges similars. Llavors assignen els píxels/voxels per la probabilitat que té de pertanyer a una regió o una altra a partir de diferents estadístics, ja sigui referent a la posició o al valor [4].

Mètodes combinats Si les imatges són complexes, sovint, és necessari combinar varies de les tècniques anteriors per aconseguir un bon resultat [11].

AVALUACIÓ DEL RESULTAT

En termes generals hi ha principalment dues formes de resumir el resultat d'una imatge segmentada. Quan en el resultat de la segmentació s'obtenen més regions de les que existeixen realment es parla de sobresegmentació. En cas contrari, és a dir, si s'obtenen menys regions de les que hi ha en realitat, és una situació de sotasegmentació. En l'àmbit mèdic, però, els píxels/voxels sovint es classifiquen els píxels/voxels en vertaders positius, vertaders negatius, falsos positius i falsos negatius.

- **Vertader positiu** (True positive). Classificat correctament com a pertanyent a la regió d'interès.

- **Vertader negatiu** (True negative). Classificat correctament com a no pertanyent a la regió d'interès.
- **Fals positiu** (False positive). Classificat incorrectament com a pertanyent a la regió d'interès.
- **Fals negatiu** (False negative). Classificat incorrectament com a no pertanyent a la regió d'interès.

Els dos primers corresponen a píxels/vòxels que s'han adjudicat a una regió a la qual no correspon en realitat. D'altra banda, els segons són els píxels/vòxels que corresponen a una regió en la realitat i no se li han adjudicat. Si el píxel/voxel s'adjudica a la regió corresponent llavors es coneix com a correctament segmentat. S'explica amb més detalls al capítol 4.

2.2 Estat actual

2.2.1 Estudi previ

Des del grup VICOROB s'ha dut a terme un extens estudi referent als mètodes que s'estan utilitzant o que ha desenvolupat altra gent en projectes de recerca [18]. Aquests mètodes es podrien classificar mitjançant dos criteris, segons l'estrategia que segueixen, o segons l'objectiu.

Segons l'estrategia. Se'n poden fer 5 grups.

Regions La majoria d'aquests mètodes són supervisats. Exemples: Udapa *et al* [14], Boudraa *et al* [3] i Datta *et al* [5].

Clustering Són els mètodes més utilitzats. La majoria tenen com a base un algorisme anomenat K-means sobre el que se'n fan adaptacions. Exemples: Nie *et al* [19] i Pham [20].

Models matemàtics La majoria d'aquests mètodes intenten ajustar les dades a un model gaussià o trobarne les diferències en el cas de la segmentació de les lesions. Exemples: Johnston *et al* [13], Ruan *et al* [21] i Shattuck *et al* [22].

Atlas Intenten deduir les zones del volum a partir d'un històric de volums dels quals es coneix el resultat. Exemples: Bach Cuadra *et al* [4], Shie *et al* [23] i Ashburner *et al* [2].

Segons l'objectiu. Se'n poden fer 3 grups.

Segmentar teixits La majoria d'aquests algorismes tenen l'objectiu de segmentar els tres teixits principals, matèria blanca, matèria gris i el líquid cerebrospinal. No obstant, alguns altres diferencien més regions i després són supervisats per obtenir el resultat final. Exemples: Ruan *et al* [21], Ashburner *et al* [2], Liew *et al* [16] i Bach Cuadra *et al* [4].

Segmentar lesions directament En aquest algorismes s'ataca directament el problema de les lesions. De la mateixa manera que els anteriors, n'hi han d'automàtics i de supervisats. Exemples: Ghazel *et al* [8] i Boudraa *et al* [3].

Segmentar lesions després de segmentar els teixits Aquests algorismes intenten aprofitar l'alta probabilitat que tenen les lesions de trobarse situades a la matèria blanca, del 95. Així un cop trobat aquest teixit resulta més senzill detectar i segmentar les lesions. Exemples: Johnston *et al* [13], Udapa *et al* [14] i Datta *et al* [5].

2.2.2 Valoració

Un cop finalitzat l'estudi, s'ha conclòs que gaire bé totes els mètodes segueixen un procediment general semblant, variant en la part concreta del segmentat. Per aconseguir un millor resultat s'aplica una pipeline amb diferents processos. Es mostra l'esquema a la figura 2.7

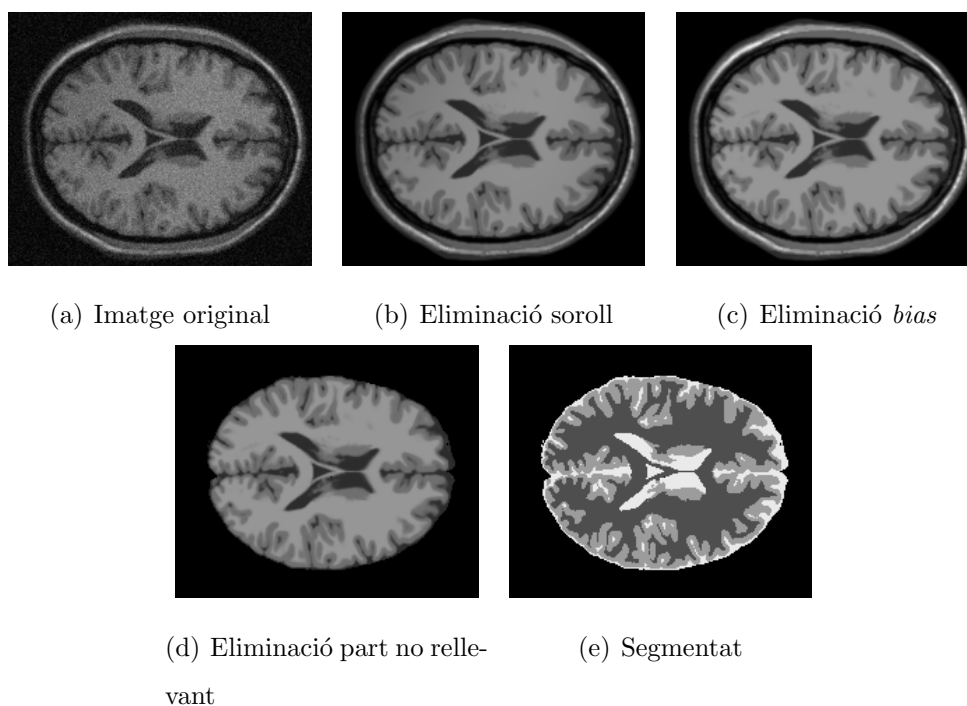


Figura 2.7: S'observen els diferents processos als que es sotmeten les imatges abans d'arribar al resultat, per ordre, des de la figura (a) fins a la figura (e).

Referent als mètodes específics sembla que la tendència és fer servir algorismes de clustering, fet pel qual ja s'estava investigant en aquesta línia dins del grup de recerca, en el moment de començar aquest projecte. Per això es va decidir seguir una altra línia. Els mètodes basats en regions no semblen gaire explorats i per això se'n vol treure algun profit d'aquesta estratègia. A més a més, el projecte es centrarà en el mètode de segmentació, deixant de banda els preprocessats que permeten treballar amb una imatge més nítida.

Per fer això, es farà servir una toolbox de preprocessament desenvolupada pel grup, juntament amb d'altres d'externes.

Capítol 3

Anàlisi, disseny i implementació del sistema de segmentació

3.1 Anàlisi del sistema de segmentació

A la secció 2.2.2 s'ha explicat que la majoria dels sistemes de segmentació actuals fan servir una estratègia en pipeline. Una pipeline és un procés compost per diferents fases que s'executen seqüencialment. Així doncs, el resultat d'una fase anterior afecta a l'entrada d'una fase posterior i, per tant, al resultat d'aquesta. Aquest plantejament és necessari a conseqüència dels fenòmens que apareixen, els quals s'han explicat a la secció 2.1.4, que són el soroll i el *bias*. En concret, en aquesta pipeline entraran volums en 3D, compostos per vòxels de 16 bits de profunditat, als quals se'ls sotmetrà a un preprocessat. Llavors s'aplicaran els algorismes de segmentació. Per a fer el preprocessat s'ha aprofitat una toolbox anteriorment desenvolupada pel grup VICOROB. Per poder-la utilitzar ha estat necessària una tasca d'aprenentatge del seu funcionament. No obstant l'objectiu d'aquest projecte es centra en el desenvolupament dels algorismes de segmentació. A la figura 3.1

podem observar aquesta seqüencialitat. A les seccions posteriors es donaran més detalls de les diferents fases de la pipeline.

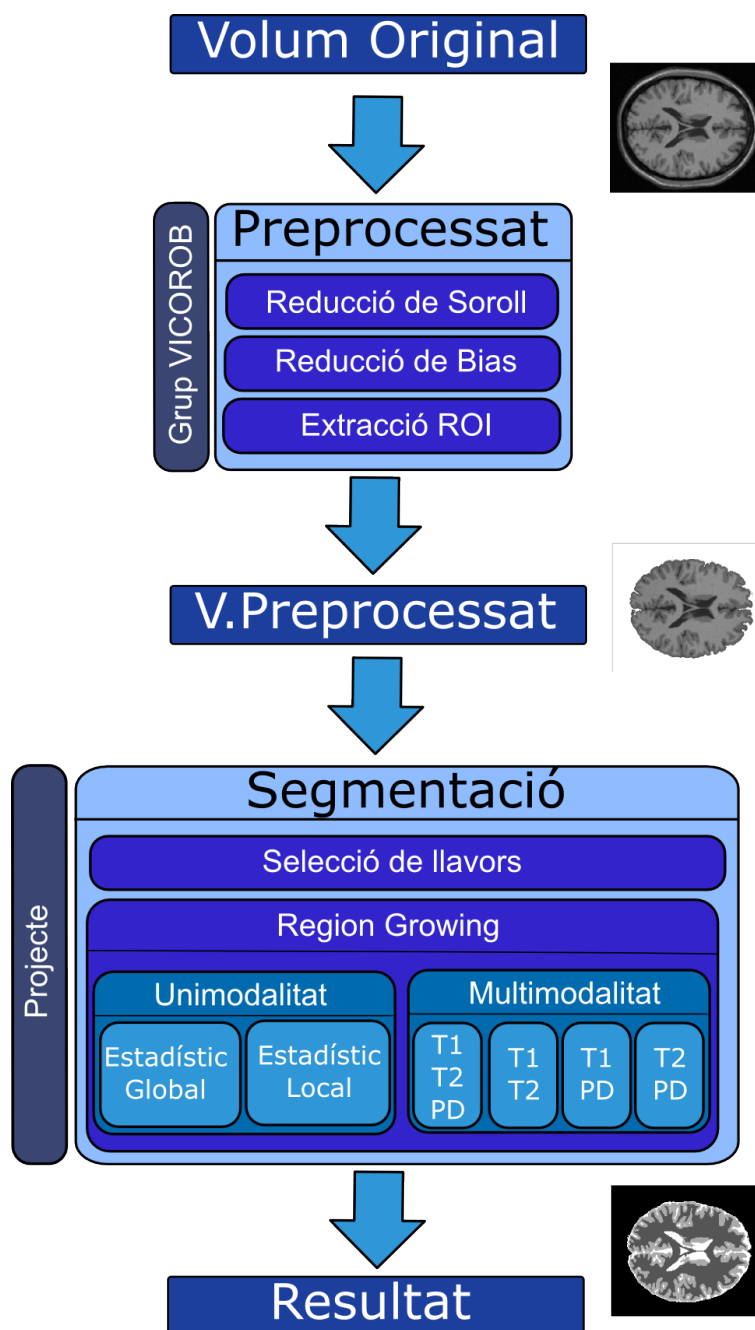



Figura 3.1: Pipeline del sistema de segmentació.

3.2 Preprocessat




Com s'ha explicat anteriorment els dos grans fenòmens externs que distorsionen els valors dels nivell d'intensitat del volum són el soroll i el *bias*. Això és pot expressar matemàticament amb la fórmula 3.1.

$$Y = \alpha X + \beta \quad (3.1)$$


on X representa la imatge ideal, α el *bias*, β el soroll i Y la imatge original.

En el preprocessat s'aplica un procés per reduir el soroll, un altre per reduir el *bias* i finalment s'extreu el cervell que és la regió d'interès.


3.2.1 Reducció de soroll



El soroll que contenen les imatges és additiu Gaussià. L'algorisme desenvolupat pel grup VICOROB fa servir *wavelets* per eliminar el soroll dels volums entrants. Aquest mètode consisteix, a grans trets, en aplicar filtres passa-baixes i passa-altes a les imatges, per files i per columnes, amb l'objectiu de localitzar el soroll. Es pot observar a la imatge 3.2.




(a) Files passa-altes, columnes passa-altes. (b) Files passa-altes, columnes passa-baixes.



(c) Files passa-baixes, columnes passa-altes. (d) Files passa-baixes, columnes passa-baixes.

Figura 3.2: Descomposició segons el filtre aplicat. És important destacar que la imatge (d) es pot tornar a descomposar.

D'aquest filtratge s'obtenen 4 imatges. A la imatge resultant d'aplicar dos filtres passa-baixes es pot tornar a repetir el mateix procés, per detectar el soroll degut a canvis d'intensitat menys brusc. En aquest projecte s'ha utilitzat el procediment amb 5 nivells, com recomana la major part de la literatura. En aquestes descomposicions es realitzen una sèrie de càlculs, que no s'explicaran amb detall, i s'aconsegueix reduir el soroll. Tamé cal remarcar que aquest procediment és 2D i, per tant, cal aplicar-lo a cada una de les llesques del volum. A la figura 3.3 es pot veure un exemple d'una d'aquestes llesques.




(a) Imatge original

(b) Imatge un cop aplicada la reducció de soroll

Figura 3.3: Es pot observar la millora que es produeix entre la imatge (a) i la imatge (b).

3.2.2 Reducció del *bias*




En aquest moments la imatge real, sense soroll, es pot expressar per la fórmula 3.2. Ara és més facil trobar la component multiplicativa del *bias*.

$$Y = \alpha X \quad (3.2)$$

on X representa la imatge ideal, α el *bias* i Y la imatge resultant després d'aplicar la reducció de soroll.

Per aconseguir reduir el *bias* s'utilitzarà la versió 8 d'una toolbox de Matlab anomenada SPM, *Statistical Parametric Mapping*, que implementa un mètode molt conegut. El mètode s'explica amb detall a l'article de Zhang et al [25]. Aquesta tècnica fa servir atles estadístics que s'han esmentat a

la secció 2.1.4. A la figura 3.4 es mostra com afecta aquest procés amb un exemple d'una imatge.




(a) Imatge original

(b) Imatge un cop aplicada la reduccio de *bias*

Figura 3.4: Es pot observar la millora que es produeix entre la imatge (a) i la imatge (b). L'enfosquiment que pateix la imatge, de dreta a esquerra, desapareix.


3.2.3 Extracció de la regió d'interés. El cervell



Pel que fa a l'extracció del crani s'han aplicat dos mètodes diferents segons si els volums eren sintètics o reals. Això s'ha fet perquè fins ara no es disposa d'un mètode per extreure correctament tot el cervell sinó que funciona només en les llesques superiors. Aquest projecte vol abarcar tot el volum, ja que s'intenta aprofitar la informació tridimensional.

En imatges sintètiques es disposa d'una segmentació correcta de tots els diferents teixits que apareixen. S'ha fet servir aquesta segmentació, per poder separar la regió d'interés. En imatges reals s'ha omès aquest pas i s'ha

segmentat directament amb la part no rellevant inclosa. A la figura 3.5 es pot observar com afecta aquesta part del preprocessat.




(a) Imatge amb totes les regions
gions

(b) Imatge amb la regió
d'interés

Figura 3.5: Es pot observar com es delimita la zona a segmentar que realment té interès mèdic.

Tot i que no s'abastarà en aquest projecte, l'estratègia de l'atlas, esmentada a la secció 2.1.4 podria ser molt útil per realitzar aquest pas, ja que es podria relacionar la part que no corresponen al cervell amb la de la resta d'imatges de l'històric del qual es disposa.

3.3 Segmentació



Un cop dut a terme el preprocessat que s'ha explicat a les seccions anteriors d'aquest capítol ja es disposa d'un volum d'entrada millor per aplicar-hi els mètodes de segmentació. En aquest projecte, dins dels diferents algorismes basats en regions, s'ha decidit dissenyar i implementar mètodes basats en el

creixement de regions, tècnica coneguda en anglès com a Region Growing. Aquesta tècnica és molt utilitzada en imatges en 2 dimensions, i és fàcil d'escalar a imatges en 3 dimensions. A la secció 2.1.4 també s'ha fet referència a la tècnica Split and Merge per les estratègies basades en regions. S'ha optat pel Region Growing perquè aquest altre mètode provoca un aspecte pixelat en els resultats, fet que no interessa.

El primer pas, per a poder fer créixer una regió és decidir un punt d'inici, el qual també es coneix com a llavor. Després s'aplica el creixement de regions, fent servir uns criteris que poden variar segons les necessitats. Concretament s'ha comprovat com responen aquestes tècniques davant de les diferents modalitats de MRI, com també enfront de la combinació d'aquestes. D'altra banda s'han estudiat les diferències entre tenir en compte informació local, és a dir, entre vòxels més propers, o informació global, on es fan servir els mateixos estadístics per a tot el volum.


3.3.1 Selecció de les llavors



La selecció de llavors, és farà mitjançant una interfície que permetrà veure el volum des dels tres plans. D'aquesta manera el sistema serà semiautomàtic, permetent als metges interactuar per aconseguir una major fiabilitat en la classificació dels teixits. La funció del metge serà, després d'inspeccionar el volum, fer un simple clic, amb el ratolí, en un voxel de cadascuna de les regions que desitgi segmentar. A la figura 5.4, es pot veure la forma d'aquesta

aplicació.

3.3.2 Region Growing



El Region Growing és un mètode basat en un concepte senzill, i per tant, es difícil atribuir-lo a un autor. No obstant, és molt comú a la literatura de la visió per computador, sobretot en llibres de fonaments bàsics com poden ser *Digital Image Processing* [9] o *Machine Vision* [6] de Gonzalez & Woods i D.Vernon respectivament.

Abans d'aplicar el mètode ha calgut fer un anàlisi del mètode per veure què podia aportar, i quins eren els inconvenients, pel que fa a la naturalesa de la tècnica. Llavors, durant el desenvolupament del projecte han estat necessaris un seguit d'estudis i comprovacions de com es reflectia tota aquesta teoria en els volums MRI.

Anàlisi

Per començar es farà una explicació del funcionament del Region Growing bàsic. Per fer-ho més fàcil s'enfocarà, en un principi, en 2 dimensions i després, es detallaran les diferències que comporta el seu disseny en 3 dimensions. En el Region Growing els dos aspectes més importants són el criteri d'agregació i el tipus de connectivitat. Com s'ha comentat abans, per fer créixer una regió, es necessita un píxel inicial, anomenat llavor. A partir d'aquesta llavor es pot iniciar el creixement de la regió. Per fer-la créixer es

consulten els píxels veïns, que venen determinats pel tipus de connectivitat que es fa servir. Si els píxels veïns compleixen el criteri d'agregació s'afegeixen a la regió creixent i es repeteix el mateix procés amb cadascun d'ells. En cas contrari, la regió deixa de créixer en aquella direcció. Quan s'afegeix un píxel a la regió cal actualitzar l'estadístic. En 2 dimensions els tipus de connectivitats possibles són dos: C4 o C8, s'observa a la figura 3.6.




Figura 3.6: Connectivitats possibles en 2D. [17]

L'ordre de creixement de la regió ve definit per l'ordre en el que s'afegeixen els píxels a una cua que fa possible el disseny seqüencial de l'algorisme. Aquesta cua a més, permet que el creixement sigui circular al voltant de la llavor i, per tant, l'estadístic que forma part del criteri d'agregació s'obté a partir de píxels més propers a aquesta. La figura 3.7 mostra com seria el creixement, en un cas hipotètic, on tots els píxels compleixen el criteri d'agregació.




Figura 3.7: Creixement del Region Growing en 2D.[17]

La part més flexible del mètode és el criteri d'agregació. En aquest criteri intervé, com a mínim, un estadístic. Habitualment, es combina un estadístic dels valors, els quals formen part de la regió, amb alguna altra dada per establir un llindar.

Un cop entès el concepte, cal modificar aquest algorisme per aplicar-ho directament a un volum, és a dir, en 3 dimensions. És necessari canviar la connectivitat, que ara serà C6, C18 o C26. Es mostra a la figura 3.8.




Figura 3.8: Connectivitats possibles en 3D.

Ara a la cua s'hauran de guardar punts amb 3 coordenades. El creixement serà més complexe, describint una forma esfèrica, en el cas que tots els punts complissin el criteri d'agregació. Fent un símil amb la figura 3.7, ara el creixement seria com indica la figura 3.9. També es pot apreciar, que el problema es complica, o si més no, el procés serà més costós.




Figura 3.9: Creixement del Region Growing en 3D.

Un cop introduïda la tècnica s'arriba a la conclusió de que té una sèrie d'avantatges però d'altra banda també té alguns inconvenients.

- Avantatges

- La propietat que es defineix per segmentar és molt respectada pel mètode.
- Si la imatge té els contorns definits la segmentació és fàcil.
- El concepte és senzill.
- Es pot fer servir més d'un criteri a la vegada.
- Es força robust al soroll.

- Inconvenients

- Té un alt cost de computació.
- Tot i ser robust al soroll, aquest es pot reflectir en forma de forats dins de la regió.
- Les ombres sovint són intepretades com a part de la regió.
- Les regions no connectades espacialment queden diferenciades, tot i ser, conceptualment la mateixa.

Per finalitzar, a la figura 3.10 es mostra el diagrama de flux del Region Growing bàsic.

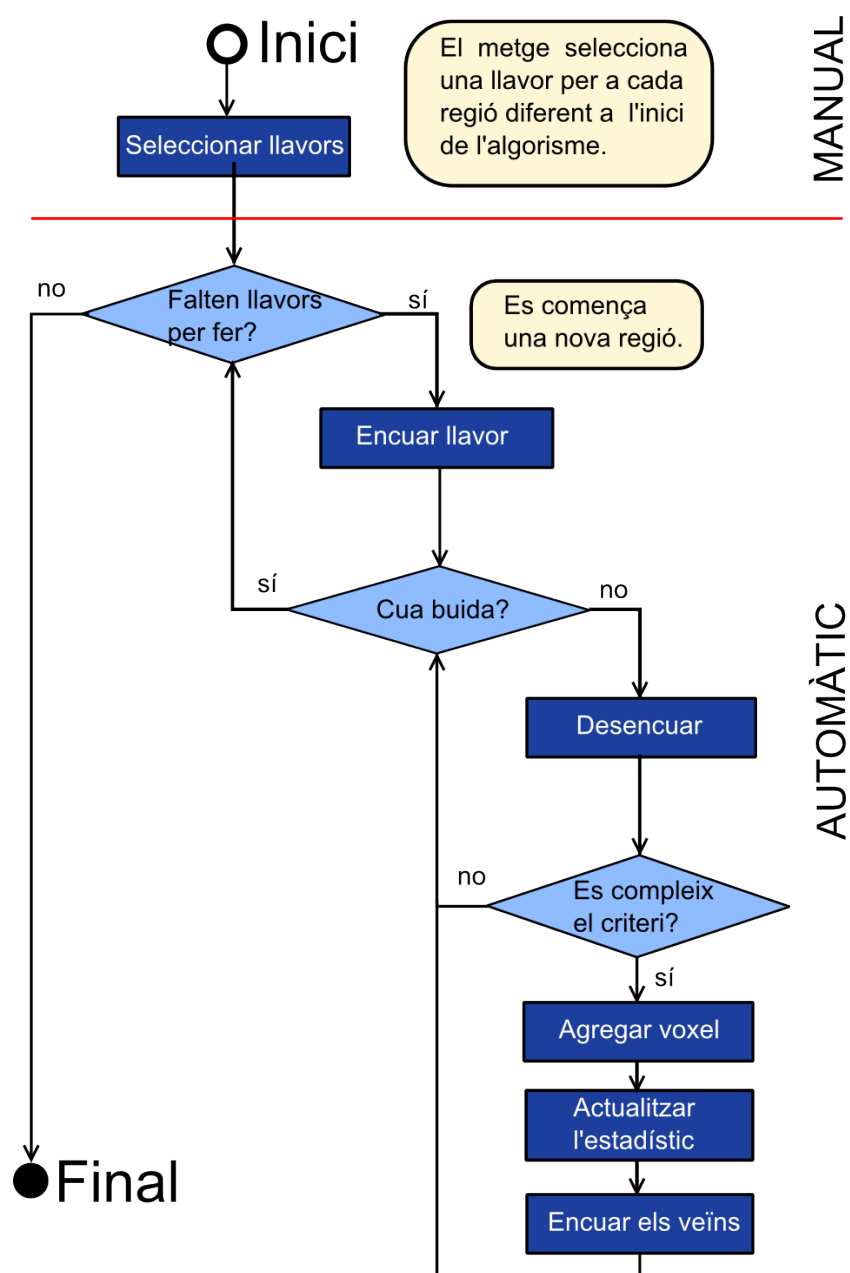


Figura 3.10: Diagrama del Region Growing Bàsic.

Un exemple d'una segmentació que es pot aconseguir amb el Region Growing es pot observar a la figura 3.11.


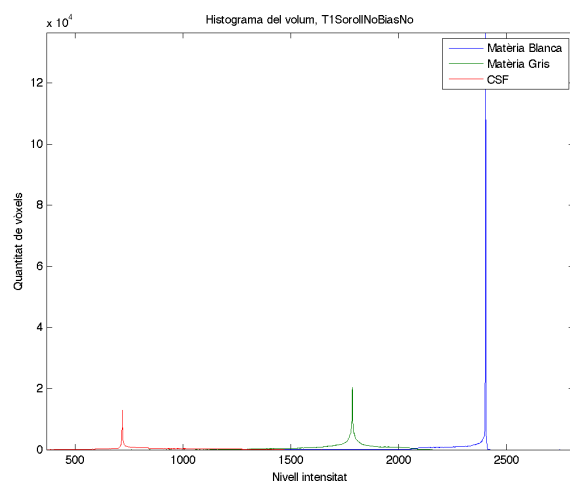


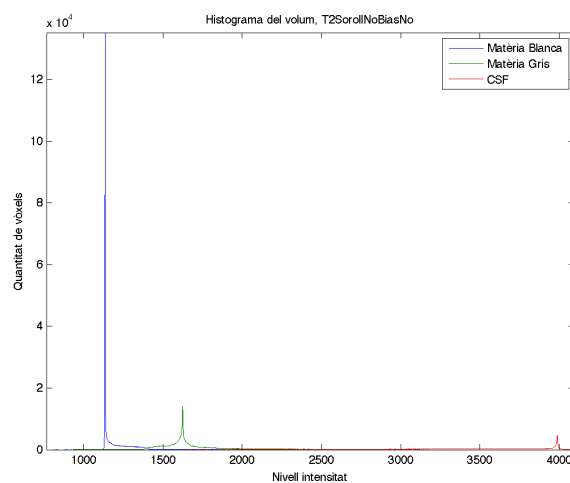
Figura 3.11: A l'esquerra es veu la imatge original que ha quedat segmentada com es mostra a la dreta. En aquest exemple es poden apreciar els aspectes que s'han comentat en aquesta secció.[17]

Aplicació en MRI del cervell


Un cop analitzat el Region Growing independentment, s'exposaran diferents estudis que s'han dut a terme, sobre del terreny, a mesura que s'anaven implementant els diferents mètodes. Aquests estudis s'han realitzat sobre les MRI del Brainweb, de les quals es coneix la segmentació correcta, i per tant, se'n poden extreure més dades interessants. Una bona part d'aquest estudi ha estat sobre histogrames. Un histograma representa la quantitat de vòxels que tenen un nivell d'intensitat concret. Amb aquesta representació es pot observar quins nivells d'intensitat tenen els vòxels de cada teixit, i per tant, si els vòxels dels diferents teixits coincideixen en l'espai de mesures. A més a més, es pot veure reflectit com afecten els fenòmens externs, soroll i *bias*, a aquests valors. També les diferències entre les diferents modalitats. A la figura 3.12 es poden observar els histogrames ideals, a la figura 3.13 els mateixos però amb soroll, a la figura 3.14 sense soroll però amb *bias*, i finalment a la figura 3.15 amb soroll i *bias*.



(a) Modalitat T1




(b) Modalitat T2




(c) Modalitat PD


Figura 3.12: Histogrames: Soroll 0% Bias 0%



(a) Modalitat T1




(b) Modalitat T2

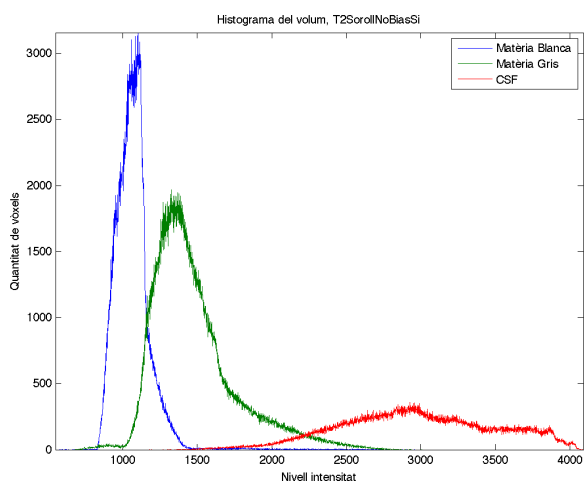


(c) Modalitat PD


Figura 3.13: Histogrames: Soroll 9% Bias 0%



(a) Modalitat T1




(b) Modalitat T2




(c) Modalitat PD


Figura 3.14: Histogrames: Soroll 0% Bias 40%



(a) Modalitat T1



(b) Modalitat T2



(c) Modalitat PD

Figura 3.15: Histogrames: Soroll 9% Bias 40%

Observant la figura 3.12 s'arriba a la conclusió de que, en un cas ideal, si la MRI no està afectada per el soroll ni el *bias*, els diferents teixits tenen un rang de valors força exclusiu per a cadascun, i per tant, hauria de ser fàcil segmentar les regions. També es reflecteix, com es pot veure a cop d'ull, que en les imatges PD el contrast és menor. D'altra banda, com es veu a la figura 3.13, un cop els volums es veuen afectats pel soroll, un gran nombre de vòxels tenen el mateixos nivell d'intensitat, tot i pertanyer a diferents teixits. Aquest fet, deixarà la responsabilitat d'una bona segmentació a la connectivitat, i a un estadístic robust. En el cas del *bias*, figura 3.14, s'observa un eixamplament de les corbes a conseqüència de l'enfosquiment d'una gran quantitat de vòxels, el qual té conseqüències semblants al soroll. En aquest últim cas, l'estadístic no haurà de soportar canvis de nivell d'intensitat entre vòxels propers sinó diferències de valors de l'estadístic a nivell més global. Per finalitzar, a la 3.15, s'observen els histogrames de les MRI afectades pels dos fenòmens. Comparant-los amb la figura 3.12 és pot apreciar la dificultat que aporten al problema.

Fins ara, s'ha analitzat el problema en l'espai de mesures, però això no permet fer-se una idea de com estan situats aquests vòxels. Per aixó, a mesura que ha avançat el projecte, amb els problemes trobats, ha estat necessari fer el mateix estudi pero situant els vòxels problemàtics, en l'espai. Per il·lustrar-ho es mostraran algunes llesques, figures 3.17, 3.18, 3.19 i 3.20, dels casos dels quals s'ha vist l'histograma anteriorment. D'aquesta manera es comprova si els vòxels pertanyents a diferents regions coincidents en l'espai de mesures podran ser fàcilment distingits gràcies a la connectivitat o, si en cas contrari, dificultaran molt la feina. Per entendre la representació, s'ha de relacionar cada color amb la llegenda de la figura 3.16. Aquest especial interès en la connectivitat dels vòxels que coincideixen en l'espai de mesures,

però que pertanyen a diferents teixits, respon a l'estrategia que es fa servir en aquest projecte. Com que s'utilitza una tècnica de creixement de regions, si aquests vòxels no estan connectats, la regió no creixerà en aquella direcció i no suposarà cap problema.

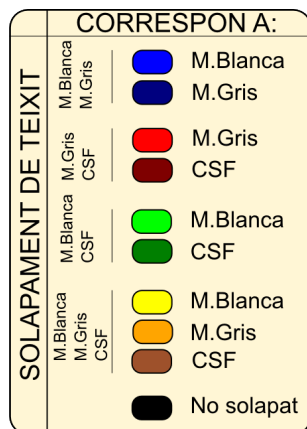





Figura 3.16: Llegendra de la representacio de solapaments.



(a) Modalitat T1




(b) Modalitat T2




(c) Modalitat PD


Figura 3.17: Solapaments: Soroll 0% Bias 0%



(a) Modalitat T1




(b) Modalitat T2




(c) Modalitat PD


Figura 3.18: Solapaments: Soroll 9% Bias 0%



(a) Modalitat T1




(b) Modalitat T2




(c) Modalitat PD


Figura 3.19: Solapaments: Soroll 0% Bias 40%



(a) Modalitat T1



(b) Modalitat T2



(c) Modalitat PD

Figura 3.20: Solapaments: Soroll 9% Bias 40%

En aquestes representacions hi ha diferents aspectes a tenir en compte:

Diferències entre modalitats. D'entrada es pot observar que generalment en la modalitat T1 hi ha menys solapament en l'espai de mesures, perquè la zona representada és més petita. Es veu clarament, quan el volum no té soroll, ni *bias*.

Solapament espacial. Tot i tenir un alt solapament entre els teixits en l'espai de mesures, això no representa un problema important si espacialment els teixits estan clarament separats. No obstant, es pot observar que als límits de cada teixit els vòxels tenen una situació espacial aleatòria, fet molt negatiu per a la segmentació amb creixement de regions.

Efecte del soroll. Aquest fenomen té diferents efectes sobre les imatges. El més important és que augmenta la zona de solapament espectral. A més a més, accentua el que hem comentat en el punt anterior, la regió de conflicte als límits augmenta.

Efecte del *bias*. En les imatges afectades pel *bias*, es pot apreciar que si aquestes es miren d'esquerra a dreta, els vòxels de més cap a l'esquerra es veuen afectats per solapaments diferents que els de més cap a la dreta. Això és conseqüència de que el *bias* afecta linealment en funció de l'eix X del volum. No obstant, no provoca que les zones de conflicte a la frontera entre un teixit i l'altre, siguin més amples.

Una vegada fet aquest estudi, i ja que es volia assignar només una llavor a cada regió, ha calgut realitzar un anàlisi per comprovar que això podia funcionar. Per fer-ho s'ha aplicat a una màscara, de cada teixit per separat la funció `bwlabeln(volum,connectivitat)`; que proporciona MATLAB, la

	Nombre de regions	Volum total (vòxels)	Volum regió més gran (voxels)	% regió més gran
Blanca	215	680764	679794	99.86
Gris	142	902912	901767	99.87
CSF	397	371945	369471	99.33

Taula 3.1: Valors de connectivitat dels diferents teixits.


qual etiqueta cada regió independent amb valors diferents, i sobre això s'ha calculat l'àrea de cadascuna amb la funció `regionprops(volum, 'Area')`. Els resultats es mostren a la taula 3.1.

D'aquestes dades es pot concloure que no és necessari pensar en una inicialització més sofisticada. A més a més, el petit tamany de les zones no conectedes fa que siguin difícils de detectar visualment, i fins i tot, augmenta el risc d'error.

D'altra banda, es tracta en aquest projecte el tema de les lesions produïdes per l'esclerosi múltiple. En aquest cas s'ha analitzat el volum de les diferents lesions que apareixen en el volum que ofereix BrainWeb. Conté 63 lesions. D'aquestes lesions, 36 estan formades per menys de 10 vòxels, 18 tenen una mida entre 10 i 100 vòxels, mentre que les 9 restants tenen un volum considerable de més de 100 vòxels. Això fa pensar que en les lesions petites no només representaran un problema de segmentació sinó també de localització, ja que fent l'histograma es pot veure que no tenen un nivell de gris exclusiu amb la resta de teixits i es confondran fàcilment.

Finalment, per acabar d'analitzar tot el que abasta el projecte, cal fer una repasada als histogrames mostrats a les figures 3.12, 3.13, 3.14 i 3.15 per intentar trobar com pot ajudar el fet de disposar de 3 modalitats diferents. Dels histogrames no se'n pot extreure una gran conclusió. Per tant, es combinaran les tres modalitats amb l'objectiu de formar un criteri d'agregació més robust.

3.3.3 Adaptació del Region Growing. Desenvolupament Unimodalitat



Per començar, s'ha enfocat el desenvolupament de la tècnica del creixement de regions per fer servir una sola modalitat. En el mètode implementat es podrà escollir la connectivitat en el moment de l'execució. Finalment, només faltaria decidir quin criteri d'agregació s'utilitzarà. Quan es parla d'un criteri d'agregació, aquest va fortament lligat al concepte d'estadístic. Un estadístic és una mesura quantitativa, derivada d'un conjunt de dades, amb l'objectiu d'extreure característiques. Un dels estadístics que sempre formarà part del criteri d'agregació és la mitjana, fórmula 3.3.

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.3)$$

on x_i és el nivell d'intensitat del vòxel i .

A partir d'aquest es pot formar el criteri d'agregació que s'indica a la fórmula 3.4.

$$|f(V_i) - \mu(R_i)| \leq \Delta \quad (3.4)$$

on V_i és el vòxel que s'està comprovant si pertany a la regió, R_i és la regió actual i Δ és el llindar amb el qual es decideix en funció d'un escalar o d'un altre estadístic.

És en aquest punt on cal decidir quin estadístic i quina mostra fer servir. En un principi, s'ha implementat un mètode que tingui en compte la informació de tot el volum per calcular els estadístics, amb diferents variants. I després, s'ha passat a prendre mostres més pròximes al vòxel protagonista per veure com reaccionava el mètode davant del *bias* i del soroll.

Estadístic Global

En aquesta línia s'han implementat dos mètodes. Un d'ells fa servir un escalar extern a les dades per establir el llindar, mentre que l'altre utilitza les mateixes dades del volum que s'està segmentant.

El primer, que s'ha desenvolupat en la fase inicial del projecte, té en compte el valor absolut de la diferència entre el vòxel inspeccionat i la mitjana de la regió actual. Per tant, el llindar queda establert com es mostra a la fórmula 3.5.

$$\Delta = K \quad (3.5)$$

on K és una constant definida com a paràmetre d'entrada del mètode.

Amb aquest mètode s'han aconseguit segmentacions prou acceptables com per a continuar desenvolupant estratègies d'aquesta mena. És evident però, que decidir la tolerància a l'hora de crèixer mitjançant una constant externa no serà prou flexible davant de les diferents imatges, ni dels diferents teixits. Per tant, cal trobar un criteri d'agregació que es formi en funció de les dades.

La solució al problema ha estat fer intervenir un altre estadístic per formar el llindar. Aquest estadístic ha estat la desviació estàndard, la qual ve definida per la fórmula 3.6.

$$\sigma = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 = \sqrt{\frac{(x_1 - \mu)^2 + \dots + (x_n - \mu)^2}{n}} \quad (3.6)$$

on, en aquest cas, x_i és el nivell d'intensitat del vòxel i μ la mitjana dels nivells d'intensitat de la regió crescuda fins al moment.

La desviació estàndard és un estadístic que dona informació sobre la desviació de les dades. Es a dir, informarà de com d'allunyades estan els nivells d'intensitat respecte de la mitjana de tota la regió. En una distribució normal, que s'aproxima als volums de MRI, se sap que les dades es dispersen segons indica la figura 3.21.




Figura 3.21: Distribució normal. L'àrea representada sota de la corba representa la totalitat de les dades[15].

Per tant, en el projecte es definirà l'interval per acceptar nous vòxels per a una regió amb 2.5σ , com mostra la fórmula 3.7. D'aquesta forma s'ajustarà el llindar de forma automàtica a les dades i també s'evitarà d'agregar vòxels, amb valors extrems, a la regió.

$$\Delta = 2.5\sigma \quad (3.7)$$

Fer servir la desviació estàndard comporta un problema d'inicialització. Fins ara l'algorisme començava amb un sol vòxel inicial, però la desviació es calcula a partir d'un conjunt de dades. Si no es modifiqués, la desviació d'un sol vòxel serà 0 i, per tant, la regió només creixeria en els valors iguals que el vòxel inicial. Aprofitant l'avinentessa, s'ha habilitat el mètode perquè en el moment de l'execució es pugui decidir la mida de la llavor. Aquesta llavor tindrà forma esfèrica i es definirà mitjançant el radi, figura 3.22. Aquesta modificació, soluciona el problema de la inicialització i, a més a més, la fa més robusta. No obstant, no es pot fer servir una llavor massa gran perquè s'envaïrien teixits diferents. S'ha d'estar totalment segur que la llavor només conté vòxels de la regió que es vol segmentar.

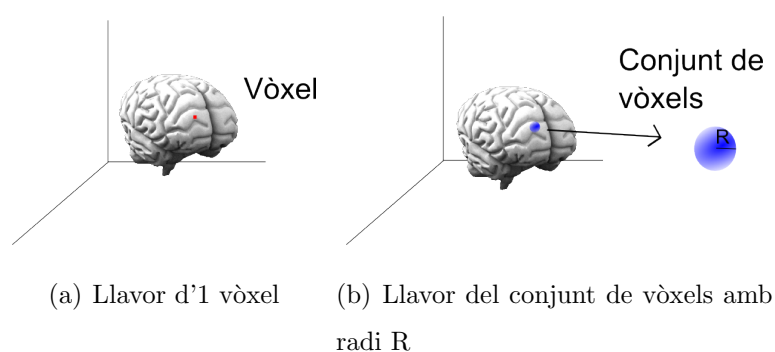


Figura 3.22: Modificació de la llavor. D'inicialitzar amb un sol vòxel, imatge (a), es passa a inicialitzar amb el vòxel que s'indiqui i els seus veïns segons el radi que es defineixi, imatge (b).

A més a més, si es recalcula la desviació a cada iteració del mètode, es produeix una pèrdua d'eficiència important, ja que la regió cada cop és més gran i, per tant, té més valors. Per solventar això només cal descomposar l'estadístic segons el raonament següent, per calcular la desviació de forma incremental.

$$\sigma = \sqrt{\frac{(x_1 - \mu)^2 + \dots + (x_n - \mu)^2}{n}} \quad (3.8)$$

$$\sigma^2 = \frac{(x_1 - \mu)^2 + \dots + (x_n - \mu)^2}{n} \quad (3.9)$$

$$\sigma_n^2 = \frac{Quadrats_n}{n} = \frac{(x_1 - \mu)^2 + \dots + (x_n - \mu)^2}{n} \quad (3.10)$$

$$\sigma_{n+1} = \sqrt{\frac{Quadrats_n + (x_{n+1} - \mu_n)^2}{n + 1}} \quad (3.11)$$

A la figura 3.23 es pot veure el diagrama de l'algorisme amb les novetats.

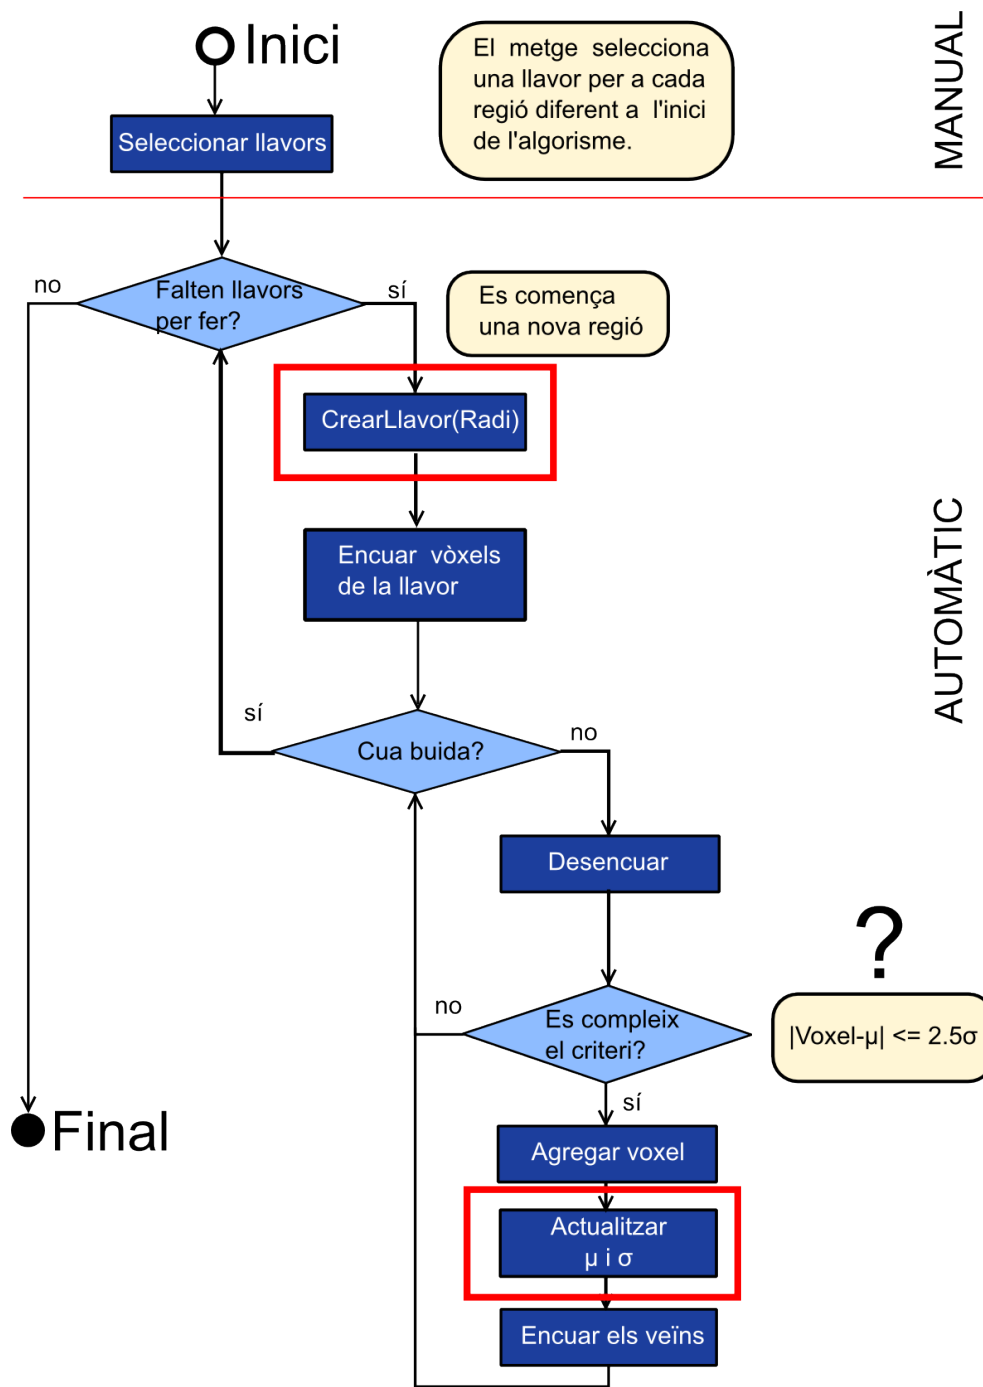


Figura 3.23: Diagrama del Region Growing amb les modificacions de la llavor variable i de l'estadístic de la desviació estàndard al criteri d'agregació.

Cal esmentar també, que per evitar alguns problemes de sotasegmentació en les imatges sintètiques sobre les quals no hi fa efecte cap fenomen extern, les quals són massa homogenies, s'ha imposat un mínim en la desviació a cada iteració, valor que es pren com a desviació si l'estadístic de la regió segmentada fins aquell moment no el supera.

Estadístic Local

En aquesta línia s'han implementat mètodes tenint en compte la informació més propera al vòxel que s'està inspeccionant. Això s'ha fet per evitar ser perjudicats per la inhomogeneïtat o la variabilitat entre les diferents zones del volum. En concret s'han desenvolupat 2 tècniques diferents. A la primera, es divideix el volum en diferents subvolums en forma d'ortocedre. En la segona, es calculen els estadístics fent servir una finestra al voltant del vòxel inspeccionat.

Amb la primera tècnica cal, abans de començar, definir els subvolums. Això es fa en funció de 3 paràmetres d'entrada que defineixen l'alt, l'ample i el fons. Si aquest valor no es divisor del total del volum, una part dels subvolums quedaran més petits en aquella dimensió. S'explica amb un dibuix a la figura 3.24.




Figura 3.24: Subvolums

Un cop fet això, i conegut el total de subvolums, enlloc de guardar un valor per estadístic de tota la regió, s'haurà de treballar amb estadístics formats per vectors. Cada posició del vector guardarà el valor d'un estadístic diferent per cada subvolum. Els subvolums estan indexats, i es pot saber a quina posició de l'estadístic pertany un vòxel segons les seves coordenades. S'il·lustra a la figura 3.25




Figura 3.25: Estadístic pels subvolums

Després d'això només cal incorporar un control per saber si és el primer cop que s'inspecciona un subvolum, ja que com també es fa servir la desviació no es pot inicialitzar l'estadístic amb només un vòxel. El problema

es soluciona de la mateix manera que s'ha vist al mètode anterior. Un cop fetes varies proves s'ha vist que resulta difícil controlar el creixement de les diferents regions, degut a que canvia d'un subvolum a un altre varies vegades i pot entrar al mateix subvolum des de diferents d'ells. Per tant, com també era una tècnica poc fonamentada teòricament s'ha decidit abandonar aquesta línia.

D'altra banda, sí ha donat bons resultats el mètode de la finestra. En concret, els vòxels que es tenen en compte són els que formen part de la regió actual delimitats per una esfera de radi R amb centre al vòxel inspeccionat. S'aclareix gràficament a la figura 3.26.

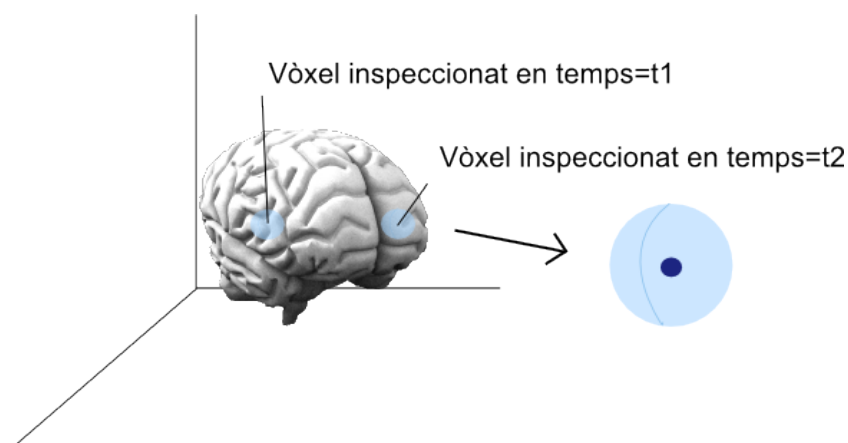



Figura 3.26: Finestra

Aquest mètode té l'inconvenient, però, que a cada iteració cal recalculer la desviació estàndar, fet que enlenteix molt el procés, com a mínim en la implementació amb MATLAB.

3.3.4 Adaptació del Region Growing. Desenvolupament Multimodalitat



En aquesta part del projecte s'ha desenvolpat un mètode per aprofitar que es disposa de 3 modalitats diferents de MRI. D'aquesta manera es pot fer servir informació provinent de 3 fonts diferents per aconseguir un criteri d'agregació més robust. El mètode implementat ha estat el que fa servir un estadístic global amb la desviació estàndard. Així a mesura que la regió creix es va actualitzant la mitjana i la desviació, independentment, de cada modalitat. Llavors al criteri d'agregació es combinen amb una operació AND. A la figura 3.27 es representa el criteri d'agregació.

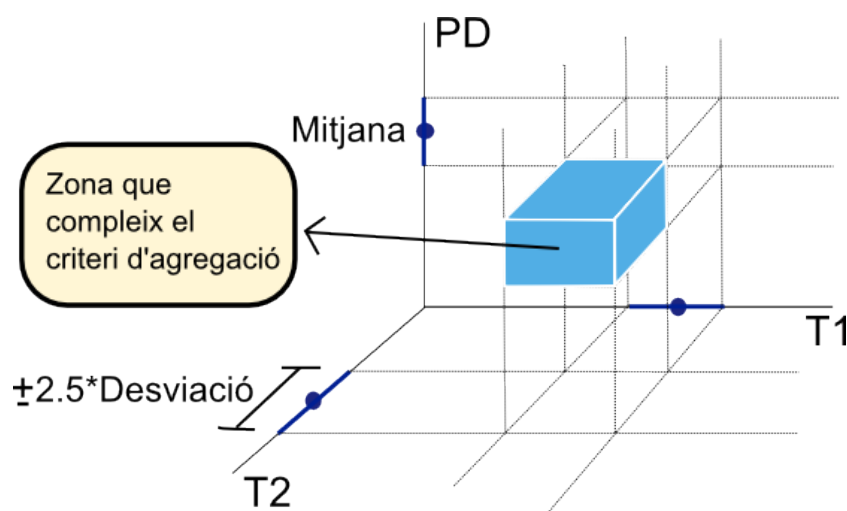


Figura 3.27: Zona que compleix el criteri d'agregació

Com no sempre es disposa de les 3 modalitats, també s'ha adaptat el mètode per fer-ne servir només 2. Cal dir que en totes les proves fetes la

modalitat T2 no sembla massa adient per a la segmentació, i és possible que s'obtinguin millors resultats sense fer-la servir.

3.3.5 Segmentació de lesions amb Region Growing

Els mateixos mètodes que s'han desenvolupat per la segmentació de teixits es poden fer servir per a segmentar les lesions. Durant els desenvolupament del projecte, s'han dut a terme diverses reunions amb els metges col·laboradors de la Clínica Girona, l'Hospital Universitari de Girona Dr. Josep Trueta i l'Hospital Vall d'Hebron. En aquestes trobades els metges han explicat els mètodes que fan servir actualment. Aquest mètode té alguns aspectes en comú, i d'altres que es diferencien de com s'encara la segmentació en aquest projecte.

El mètode que tenen els metges a la seva disposició actualment funciona de la següent forma:

1. Seleccionar un punt, la llavor, per a cadascuna de les lesions amb el ratolí en una llesca de la MRI.
2. El programa segmenta la lesions de forma aproximada.
3. Ajustar la zones segmentades ampliant i reduint les zones arrossegant amb el ratolí.
4. Repetir el procés per a cada llesca de la MRI.

El mètode desenvolupat en aquest projecte funcionarà de la següent forma:

1. Seleccionar un punt, la llavor, per a cadascuna de les lesions amb el ratolí amb una vista 3D de la MRI.

2. El programa segmenta la lesions de forma aproximada.
3. Supervisar les zones segmentada.

Fent balanç dels dos mètodes es pot observar que tots dos responen a un mètode semiautomàtic que necessita d'una persona qualificada per inicialitzar la segmentació. Però la gran diferència, i a la vegada millora, és que la tècnica que es desenvoluparà treballa en 3 dimensions, reduint dràsticament aquesta tasca d'inicialització i aprofitant la informació de les llesques més properes, no només la informació d'una d'elles. És a dir, es necessitarà una llavor per lesió i no una llavor per a cada llesca en la que apareixi una lesió. A l'apèndix B s'explica com es fa una segmentació amb imatges de la interfície.

Capítol 4

Resultats

4.1 Tipus de dades

Com s'ha explicat en el capítol 1 per avaluar els mètodes es faran servir tant imatges sintètiques, procedents de la base de dades Brainweb, com un cas real, proporcionat per la Clínica Girona.

En el Brainweb es poden trobar tant MRI simulades d'un cervell sà com d'un cervell amb lesions. Aquests cervells base es poden trobar amb diferents nivells de soroll i de *bias*. Això serà molt útil per a comprovar la robustesa del mètode. Aquests volums sintètics també es coneixen amb el nom de *phantom*. Pel que fa al cas real només es disposa d'un volum del qual coneixem la segmentació correcta de les lesions i, no així dels teixits. Per tant, és farà una valoració qualitativa d'aquest.

Durant el desenvolupament del projecte s'ha pogut comprovar la varietat de formats que existeixen en aquest camp. Els utilitzats en aquest projecte han estat MINC, NIFTI-1 i DICOM.

DICOM Digital Imaging and Communication in Medicine, és un estàndard per adquirir, guardar, imprimir i transmetre informació en la imat-

ge mèdica, el qual inclou la definició d'aquest format de fitxer. Aquest estàndard ha estat desenvolupat per la NEMA, National Electrical Manufacturers Association. En aquest format a part de la informació de la MRI es disposa d'una capçalera amb la informació del nom, edat i característiques de la imatge entre d'altres. No tots els camps són obligatoris, fet que dificulta la conversió cap a altres formats. Les imatges són en 2 dimensions i per aconseguir un volum es guarden en una estructura de directoris que defineix un fitxer anomenat DICOMDIR. A partir d'aquest fitxer es disposa de tota la informació per treballar amb el volum, i es pot fer servir per visualitzar la informació de manera correcta. Aquest format és l'utilitzat pels scanners de MRI, fet pel qual és el format del cas real que s'avaluarà.

MINC Medical Imaging NetCDF, va ser creat per Peter Neelin del McConnell Brain Imaging Center (McBIC) que a la vegada forma part del Montreal Neurological Institute. És un format orientat a la recerca i es va desenvolupar pel mateix Brain Imaging Center. Aquest format és el de les imatges de la base de dades BrainWeb que també pertany al centre.

NIFTI-1 Neuroimaging Informatics Technology Initiative, es va crear perquè existien moltes implementacions diferents del format DICOM entre els diferents fabricants. Aquest format defineix una capçalera estricta que conté característiques del volum. La capçalera i el volum es poden guardar en un mateix fitxer, amb extensió .nii o per separat, la capçalera amb extensió .hdr i el volum amb extensió .img. Aquest format és l'únic que accepta SPM, llibreria que s'ha utilitzat per corregir el *bias* de les imatges. Aquesta mateixa llibreria té eines per conver-

tir DICOM en NIFTI-1 i, d'altra banda, les llibreries de MINC també tenen eines per convertir a NIFTI-1.

4.2 Metodologia d'avaluació

Abans de començar a donar resultats es farà un repàs sobre els mètodes d'avaluació i les mesures que intervenen.

4.2.1 Ground truth

El ground truth és la segmentació correcta del volum. En el cas de les imatges sintètiques la base de dades BrainWeb ofereix un volum amb la correcta classificació dels diferents teixits i lesions. D'altra banda, en el cas real, és necessària la intervenció d'un radiòleg que segmenti, manualment, la imatge. No obstant, aquests especialistes col·laboradors, han donat les pautes per aconseguir la segmentació automàticament, és a dir, com poder diferenciar els teixits i també les lesions.

4.2.2 Avaluació a nivell de vòxel

Per aclarir a què correspon cada avaluació s'acompanyaran les definicions, ja exposades a la secció 2.1.4, d'una imatge representativa.

- **True positive.** Classificat correctament com a pertanyent a la regió d'interès.
- **True negative.** Classificat correctament com a no pertanyent a la regió d'interès.
- **False positive.** Classificat incorrectament com a pertanyent a la regió d'interès.

- **False negative.** Classificat incorrectament com a no pertanyent a la regió d'interès.
- **Imatge representativa.**




Figura 4.1: Avaluació dels vòxels. Es pot observar que si l'àrea blava representa la regió segmentada pel ground truth i la vermella la segmentada automàticament, l'àrea de solapament són els vòxels *true positive*, mentre que la zona més blava representen *false negative* i la més vermella *false positive*.

4.2.3 Coeficients d'avaluació

Expressar els resultats en valors absoluts de la quantitat de vòxels que pertanyen a cadascun dels tipus explicats a la secció anterior es fa difícil d'interpretar. És per aquesta raó, que en la recerca es fan servir alguns coeficients que permeten donar un nombre relatiu referent a la correcció de la segmentació. En aquest projecte, s'avaluarà en funció de tres d'aquests: TPF, DSC, i Area Overlap.

TPF, True positive fraction. En aquesta valoració només es tenen en compte els *true positive* enfront de tota la regió a segmentar. Això vol dir que es pot obtenir un valor molt alt de TPF però, a la vegada, estar

sobresegmentant. S'obtindrà un bon valor sempre que es clasifiquin com a positius els vòxels de la regió que es vol segmentar. A la fórmula 4.1 es representa matemàticament.

$$Tpf = \frac{TP}{TP + FN} \quad (4.1)$$

DSC, Dice Similarity Coefficient. Amb aquesta valoració es penalitza la sobresegmentació, ja que es tenen en compte els *false positive* en el denominador. No obstant, es multipliquen els *true positive* per 2 per a donar-los-hi més pes i d'aquesta manera premiar els píxels segmentats correctament. S'expressa a la fórmula 4.2.

$$DSC = \frac{2TP}{2TP + FP + FN} \quad (4.2)$$

Area overlap. En aquest cas es tenen en compte els errors de classificació sense premiar els *true positive* donant el mateix pes a tots els vòxels. Espacialment representa l'àrea segmentada correctament enfront de tota l'àrea segmentada ja sigui pel ground truth o la segmentació obtinguda. S'indica a la fórmula 4.3.

$$Aov = \frac{TP}{TP + FP + FN} \quad (4.3)$$

4.3 Resultats Sintètics

En el projecte s'ha posat especial èmfasi en la segmentació de teixits, motiu pel qual es desenvoluparà més l'anàlisi de resultats en aquesta matèria. També es mostrarà, però, quina resposta dona el sistema pel que fa a la segmentació de lesions.

Quan es parla de segmentació d'imatges mèdiques és important que els mètodes no es vegin afectats pels fenòmens externs que actuen sobre les dades, ja que sino, s'obtidran resultats dolents que no ajudaran al diagnòstic. Primer, s'analitzarà la robustesa davant del soroll i, tot seguit, la robustesa al *bias*.

4.3.1 Robustesa davant del soroll



Per mostrar els resultats més clarament s'han separat els resultats per matèries de forma que es puguin observar les diferències entre les diferents modalitats i mètodes. D'aquesta manera s'analitzen els resultats fent servir tant el mètode amb un estadístic global, com el mètode amb un estadístic local.

ESTADÍSTIC GLOBAL

Cal puntualitzar que s'han fet algunes proves per trobar el millor valor del mètode en el qual s'imposa una desviació mínima i, finalment, s'han fet les proves amb un valor de 100.


En els gràfics de la figura 4.2 es pot observar que el soroll afecta a la segmentació de la matèria blanca. S'observa com, sense soroll, es poden aconseguir valors de DSC superiors a 0.9, mentre que amb un soroll del 9% els millors valors es queden per sota del 0.7. A més a més, en les tres modalitats, T1, T2 i PD, sense imposar cap mínim a l'estadístic, s'observa que el soroll fa canviar notablement el resultat. Si es fa un cop d'ull als valors de TPF es pot observar, que el baix valor de DSC quan no hi ha soroll es deu a la sotasegmentació, ja que els valors de TPF no superen el 0.4, és a dir, no s'ha segmentat ni una quarta part de la regió verdadera, ja que els valors d'area overlap semblants indiquen que no s'han penalitzat els falsos negatius. D'altra banda, la modalitat T1, en les dues variants, és en

Matèria Blanca



(a) TPF. True positive fraction

(b) DSC. Dice Similarity Coefficient



(c) Area Overlap

Figura 4.2: Avaluació de la matèria blanca amb estadístic global.

general la que dóna millors resultats per la segmentació de la matèria blanca, ja que s'aconsegueixen valors de DSC més alts i no es veuen tant afectats per l'increment del soroll. L'Area Overlap també indica que quan el soroll és considerable, amb valors inferiors al 0.5, però amb el TPF proper a 1, la regió s'ha sobresegmentat i es veuen penalitzats els falsos positius.


A la figura 4.3 es pot veure que la matèria gris, segmentada utilitzant un estadístic global, dóna valors de DSC al voltant del 0.7. Un fet interessant que es produeix en aquesta matèria es la robustesa al soroll. Deixant de banda els valors de 0% de soroll, en els mètodes sense mínim que sotasegmenten, el resultat és molt semblant independentment de la quantitat de soroll. La modalitat T1 també està lleugerament per sobre de les altres en quant a resultats, i imposar un mínim a l'estadístic dóna més robustesa davant del soroll.

De la figura 4.4 es pot dir que la segmentació del CSF, a la vegada que no dóna bons resultats, es veu molt afectada pel nivell de soroll de la imatge. S'observa com, per exemple, en la modalitat T1, es passa d'un bon resultat de DSC de 0.9 amb un soroll del 5% a un valor que no es prou satisfactori del 0.32 amb un 7% de soroll. No obstant, si es pot apreciar que la modalitat PD no es gens apropiada per segmentar aquest teixit, ja que en cap cas es supera el valor de DSC de 0.35, quan es considera un resultat acceptable a partir del 0.7.


Discussió de l'estadístic global

Tenint en compte totes les matèries, podem extreure que la modalitat que funciona millor amb estadístic global és la T1. Els valors més alts de DSC s'aconsegueixen per la matèria blanca, obtenint bons resultats i més robustos al soroll pel que fa a la matèria gris. En canvi, no s'aconsegueix un bon


Matèria Gris



(a) TPF. True positive fraction




(b) DSC. Dice Similarity Coefficient




(c) Area Overlap

Figura 4.3: Avaluació de la matèria gris amb estadístic global


CSF



(a) TPF. True positive fraction



(b) DSC. Dice Similarity Coefficient



(c) Area Overlap

Figura 4.4: Avaluació del CSF amb estadístic global

resultat a l'hora de segmentar el CSF.

ESTADÍSTIC LOCAL


Després de fer varies proves s'ha utilitzat com a finestra una esfera de radi de 25 unitats. Una unitat ha estat considerada la distància entre dos vòxels adjacents seguint eixos ortogonals que tenen la mateixa direcció que les dimensions dels volums d'entrada.

Als gràfics de la figura 4.5 els valors de DSC, fent servir l'estadístic local, per a la matèria blanca, es troben en el rang del 0.48-0.72, en les tres modalitats, fet que provoca que es pugui considerar el mètode com a estable o robust al soroll. No obstant, aquest valors estan per sota del que podríem considerar un bon resultat. Si s'observen els valors de TPF és pot concloure que les imatges amb poc soroll queden sotasegmentades, valors de 0.4, mentre que les imatges amb més soroll es sobresegmenten perquè el TPF és proper a 1 però el DSC i l'Area Overlap continuen en els mateixos valors.


En el cas de la matèria gris, representada a la figura 4.6, gairebé tots els valors de DSC estan en el rang de 0.6-0.75, variant molt poc en funció de la quantitat de soroll. Per tant, aquest mètode és molt resistent al soroll però no s'aconsegueixen segmentacions òptimes. Es pot veure que els valors de TPF són principalment majors que els de DSC o Area Overlap, fet que indica que el mètode sobresegmenta.

En la figura 4.7 es mostra que els resultats obtinguts pel CSF, tot i ser estables en funció del soroll, no arriben a un nivell suficient. Si s'observa la gràfica de TPF es veu que mai s'aconsegueixen distingir tots els vòxels de la regió com a pertanyents i la diferència amb les altres mesures és conseqüència de que, a més a més, es consideren de la regió molts vòxels que no ho són.


Matèria Blanca



(a) TPF. True positive fraction




(b) DSC. Dice Similarity Coefficient




(c) Area Overlap

Figura 4.5: Avaluació de la matèria blanca amb estadístic local.


Matèria Gris



(a) TPF. True positive fraction



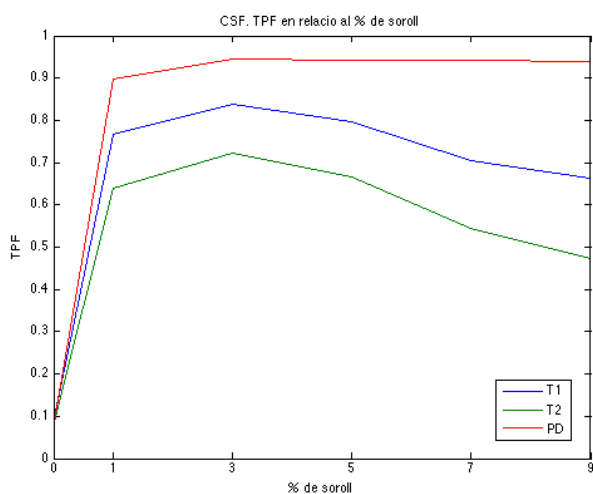
(b) DSC. Dice Similarity Coefficient




(c) Area Overlap

Figura 4.6: Avaluació de la matèria gris amb estadístic local.

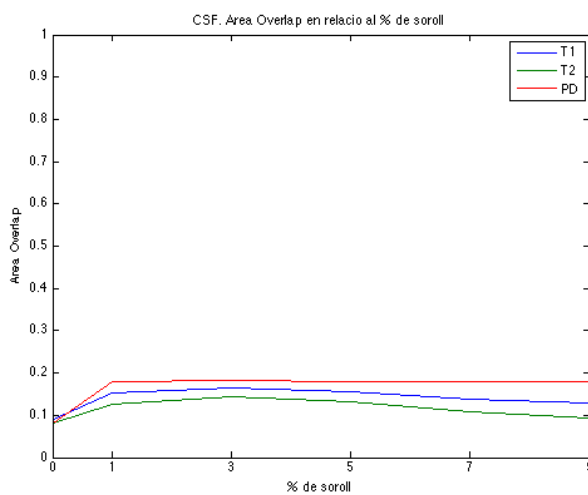
CSF



(a) TPF. True positive fraction



(b) DSC. Dice Similarity Coefficient



(c) Area Overlap

Figura 4.7: Avaluació del CSF amb estadístic local

Discussió de l'estadístic local

Amb l'estadístic local s'aconsegueix un mètode robust al soroll. Els millors resultats s'obtenen amb la matèria gris, els quals són lleugerament millors que els obtinguts amb la matèria blanca. En el CSF els resultats no arriben als nivells desitjats. En general, els resultats obtinguts no són optims, trobant-se els millors a la frontera d'allò que podríem considerar com un resultat bo o dolent.

Discussió estadístic global vs estadístic local

La conclusió que es pot extreure a partir dels dos estadístics és que amb un estadístic global es pot aconseguir un valor de DSC més alt, però el mètode és més sensible al soroll que un estadístic local. No obstant, si el mètode no es capaç d'arribar a un cert valor la seva robustesa al soroll no és suficient per ajudar als metges. Aquest últim cas és el de l'estadístic local.


4.3.2 Robustesa davant del *bias*

A la base de dades Brainweb, el nombre de casos disponibles afectats per *bias* és menor, només es disposa de 2 nivells diferents de *bias*, 20% i 40% a diferència del soroll pel qual ofereix 6 nivells diferents. De la mateixa forma que s'ha fet amb l'anàlisi del soroll, també s'han separat els casos segons el teixit i l'estadístic utilitzat.


ESTADÍSTIC GLOBAL

En el gràfics de la figura 4.8 crida l'atenció la gran diferència en el resultat entre una modalitat i totes les altres. Concretament, quan es fa servir la modalitat T1 imposant el mínim de desviació. S'aconsegueixen valors de


Matèria Blanca



(a) TPF. True positive fraction



(b) DSC. Dice Similarity Coefficient



(c) Area Overlap

Figura 4.8: Avaluació de la matèria blanca amb estadístic global.

DSC superiors al 0.95 mentre que totes les altres modalitats no superen el 0.6. El *bias* però afecta força al TPF en les altres modalitats, dificultant distingir tots els vòxels de la regió. No obstant, el fet de que els valors de DSC i Area Overlap no canvin, vol dir que, tot i que sotasegmenta la regió, no provoca que s'afegeixin vòxels d'altres texits.

Referent a la matèria gris, figura 4.9, la modalitat T1 amb mínim de desviació continua essent la que proporciona millors resultats. En canvi, no dista tant de les altres modalitats, i els resultats són més discrets. L'increment del *bias* afecta de manera similar a com ho feia en la matèria blanca, fent perdre precisió a l'hora de detectar els vòxels pertanyents al teixit que es vol segmentar.

La segmentació del CSF, figura 4.10, torna a ser inestable, sense donar pas a extreure'n cap conclusió. Per exemple, a la modalitat T1 amb mínim de desviació l'increment de *bias* afecta gairebe de forma linial mentre que en altres modalitats el resultat sembla totalment aleatori.


Discussió de l'estadístic global

Amb aquest mètode els millors resultats s'aconsegueixen amb la matèria blanca aconseguint valors superiors a 0.95, acompanyats de valors acceptables per a la matèria gris. El problema es troba en el CSF on els resultats són completament aleatoris dificultant l'extracció de conclusions per a millorar en aquesta línia.

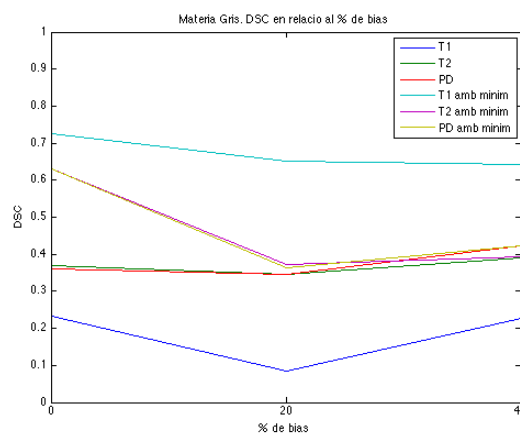
ESTADÍSTIC LOCAL

En la figura 4.11, la gràfica més rellevant és la de TPF. És pot observar que cap dels valors no supera el 0.5. Per tant, no s'han aconseguit segmentar ni la meitat dels vòxels pertanyents a matèria blanca. A més a més, l'Area


Matèria Gris



(a) TPF. True positive fraction




(b) DSC. Dice Similarity Coefficient




(c) Area Overlap

Figura 4.9: Avaluació de la matèria gris amb estadístic global


CSF



(a) TPF. True positive fraction




(b) DSC. Dice Similarity Coefficient




(c) Area Overlap

Figura 4.10: Avaluació del CSF amb estadístic global


Matèria Blanca



(a) TPF. True positive fraction



(b) DSC. Dice Similarity Coefficient



(c) Area Overlap

Figura 4.11: Avaluació de la matèria blanca amb estadístic local.

Overlap té els mateixos valors, fet que indica que no s'han obtingut un gran nombre de falsos positius els quals farien baixar els valors d'aquesta última mesura. En definitiva, la matèria blanca queda sotasegmentada sense veure's afectada per la diferència del % de *bias*.

La discussió per a la matèria gris, figura 4.12, és similar a l'anterior, figura 4.11. S'obtenen valors molt baixos en les tres mesures que indiquen que es produeix un cas de sotasegmentació.

Pel que fa a la figura 4.13, si observem la gràfica de TPF, en el CSF, l'augment de *bias* en les dades fa pujar els valors obtinguts. No obstant, el DSC i l'area overlap continuen en el mateix valor, fet que indica que ara no es produeix un cas de sotasegmentació, sino que és classifiquen molts vòxels com a pertanyents a CSF que en realitat no ho són. Es pot observar en els gràfics d'area overlap que aquests falsos positius han penalitzat molt els resultats en comparació al TPF.


Discussió de l'estadístic local

Amb l'estadístic local no s'aconsegueixen resultats realment bons. El principal problema és la sotasegmentació. No obstant, el mètode sembla robust al *bias* ja que no canvia massa els valors en funció d'aquest, i per tant, el problema pot estar en el mateix algorisme. Això dóna l'esperança que potser amb algun petit canvi en l'algorisme es podria aconseguir un mètode robust al *bias* i amb el qual s'obtinguessin millors resultats.


Discussió estadístic global vs estadístic local

De la mateixa manera que en el cas del soroll, l'estadístic global permet aconseguir resultats millors, i també amb la modalitat T1 amb el mínim de desviació. No obstant, l'estadístic global és menys robust davant del *bias*


Matèria Gris



(a) TPF. True positive fraction




(b) DSC. Dice Similarity Coefficient




(c) Area Overlap

Figura 4.12: Avaluació de la matèria gris amb estadístic local.


CSF



(a) TPF. True positive fraction



(b) DSC. Dice Similarity Coefficient



(c) Area Overlap

Figura 4.13: Avaluació del CSF amb estadístic local

ja que els resultats són més variats. D'altra banda, amb els dos estadístics, a excepció d'una modalitat, resulta difícil aconseguir valors alts de TPF, fet que dificulta una bona segmentació. Cal esmentar també, que els valors d'Area Overlap no difereixen gaire dels de TPF, i per tant, no s'obtenen molts falsos positius. De la mateixa forma, es pot concloure, que tot i que els valors obtinguts amb l'estadístic global no són tant estables com els de l'estadístic local, aquests últims no son prou bons per a ser considerats acceptables.


4.3.3 Cost computacional

Un altre aspecte que cal tenir en compte és el cost computacional que comporta fer servir cada tipus d'estadístic. El mètode de la finestra, el de l'estadístic local, obliga a recalculer a cada iteració la desviació estàndard dels vòxels més propers, que primer s'ha de comprovar si pertanyen a la regió que s'està segmentant. Aquest fet en temps real, en un Intel Core 2 Duo a 3 GHz, significa que el mètode en el qual s'utilitza l'estadístic global necessita només entre 3 i 5 minuts per a segmentar tot el volum, mentre que el de l'estadístic local triga entre 3 i 4 hores per volum.

4.4 Combinació de modalitats


Després d'analitzar els algorismes sobre cada modalitat independentment, s'ha fet una sèrie de proves mirant com responia, el millor mètode, a la combinació de modalitats. Les proves s'han fet en sintètic, ja que es disposa de totes les modalitats pel mateix cas. Si es té en compte que BrainWeb ofereix tres modalitats, T1, T2 i PD, llavors es podran fer la combinació a tres, T1-T2-PD i les combinacions a dos, T1-T2, T1-PD i T2-PD. Degut a la gran quantitat de casos que resultarien de fer totes les combinacions

també amb els diferents diferents de soroll i de *bias*, s'ha realitzat l'anàlisi sense l'efecte dels fenòmens externs. En els gràfics de la figura 4.14 es poden observar els diferents resultats.



(a) TPF. True positive fraction

(b) DSC. Dice Similarity Coefficient



(c) Area Overlap

Figura 4.14: Avaluació de la combinació de modalitats

En referència al teixit en el qual s'obtenen millors resultats és clarament la matèria blanca. Això és positiu perquè es el teixit on afecten més els

símptomes de la malaltia tractada en aquest projecte.

D'altra banda, pel que fa a les diferents modalitats i a la combinació entre elles s'aprecia una tendència a la millora, sobretot en el cas de la matèria gris. En el cas del CSF es contradiu aquesta hipòtesi, però no s'ha d'oblidar que no s'han obtingut resultats coherents en cap de les proves que s'han dut a terme en aquest teixit.


Si s'ha d'optar per una combinació en concret, el resultat més bo s'aconsegueix mitjançant T1+PD, amb un DSC, tant per la matèria gris com per la matèria blanca, superior al 0.9.

4.5 Resultats cas real

Un cop analitzat el cas sintètic s'ha executat el millor mètode, el que fa servir un estadístic global, en un cas real. En el moment de fer l'experiment només es disposava de les MRI en la modalitat T2 i PD d'un volum complet. Per mala sort, no es disposa encara d'un ground truth realitzat pels metges de manera que no es podran exposar resultats numèrics. No obstant, gràcies a les reunions amb els metges, pròximament es disposarà de molts casos amb el ground truth corresponent, per a poder dur a terme avaluacions exhaustives.

D'altra banda, la part de l'extracció del crani del preprocessat s'ha omès, ja que obliga a reduir el nombre de llesques utilitzades. En aquest mètode, l'extracció faria que algunes regions que estan connectades, en aquestes llesques que no es tenen en compte, ho deixessin d'estar i això perjudicaria al creixement.

Així doncs, de moment, s'haurà d'avaluar visualment. La modalitat que dóna un millor resultat, entre T2 i PD, és la primera. El resultat es pot observar a la figura 4.15.



(a) Imatge original de la (b) Resultat de la segmentació MRI original en modalitat tació T2


Figura 4.15: Segmentació en cas real.

De la figura 4.15(b) es pot comentar que es produeixen diferents problemes. La matèria blanca es sobresegmenta agafant algunes zones que són matèria gris, i aquesta a la vegada creix cap a regions que són CSF, a la part més externa del cervell. No obstant, es pot observar a la figura 4.15(a) que la matèria gris no té una distinció clara ni amb la matèria blanca, ni amb el CSF, quedant aquests dos últims més distingits entre ells a les zones més interiors de cada matèria.

4.6 Segmentació de lesions

Per comprovar el funcionament a l'hora de segmentar les lesions, el mètode que s'ha fet servir ha estat indicar un vòxel inicial pertanyent a la lesió i creixer a partir d'aquest. Les lesions que s'aconsegueixen segmentar són les més grans i que es troben menys connectades a la matèria gris. Les lesions tenen nivells d'intensitat molt similars a aquest teixit i es produeix una sobresegmentació, creixent per tota la matèria gris, molt fàcilment. Per tant, només es possible segmentar-les quan la connectivitat no és molt accentuada

entre la lesió i la matèria gris. No s'han extret valors numèrics perquè no s'aconsegueix un resultat prou bo. A la figura 4.16 es posa un exemple de segmentació d'una lesió.



(a) Lesió a segmentar

(b) Lesió segmentada

Figura 4.16: Segmentació d'una lesió

Capítol 5

Interfície gràfica

5.1 Anàlisi de requeriments

Abans de dissenyar la interfície s'ha fet una anàlisi per trobar tots els aspectes necessaris de la interfície, tant per part dels metges, que seran els usuaris finals, com la part tècnica. A continuació es detallen els requeriments.

Visualitzar els volums originals. Des del punt de vista mèdic és imprescindible poder visualitzar el volum d'una forma senzilla i pràctica. Com es tracta de volums també és necessari disposar de diferents seccions i plans des de diferents punts de vista.

Possibilitat d'interactuar per escollir les llavors. Com els mètodes desenvolupats són semiautomàtics és necessari que el metge pugui interactuar per inicialitzar l'execució. Llavors, s'haurà de trobar la manera que el metge indiqui un punt de cada teixit per a començar a creixer les regions.

Visualitzar el resultat. Evidentment, un cop finalitzada l'execució s'ha de poder observar d'una manera clara el resultat obtingut.

Possibilitat de comparar entre els 2 volums i amb els volums originals. També és necessari a l'hora de comparar dos volums tenir una visió ràpida i simultània dels dos per a poder-ne treure conclusions.

5.2 Disseny

En aquesta secció s'explica breument l'enginyeria del software que hi ha darrera de l'interfície. Degut a la simplicitat d'aquesta només es mostren els diagrames de cas d'ús i d'activitat.

5.2.1 Diagrames de cas d'ús

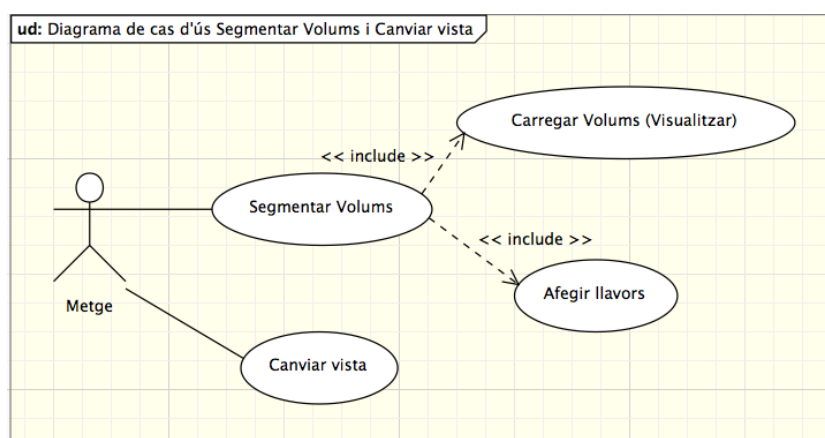


Figura 5.1: Diagrama de casos d'ús.

Especificacions dels diagrames de cas d'ús

A les taules 5.1 i 5.2 es fan les especificacions dels casos d'ús.

5.2.2 Diagrames d'activitat

A la figura 5.2 és mostra el diagrama d'activitat de la interfície.

Cas d'us	Segmentar Volums.
Descripció	L'usuari vol segmentar 1 ó 2 volums.
Actors	El metge.
Precondició	Els volums estan guardats als sistema en el format adequat
Flux principal	<ol style="list-style-type: none">1. Carregar els volums.2. Afegir les llavors.3. Segmentar.
Postcondició	Si tot OK apareix en pantalla el volum.
Comentari	Veure diagrames d'activitat adjunts

Taula 5.1: Especificació de cas d'us Segmentar Volums.

5.3 Implementació

Per implementar la interfície s'ha agafat la idea d'un visualitzador de volums 3D per a MATLAB disponible a la xarxa desenvolupat l'any 2008 per Marian Uhercik del CMP (Center for Machine Perception) pertanyent a la CTU (Czech Technical University) ubicada a Prague [24]. Aquesta interfície té l'aspecte mostrat a la figura 5.3.

Cas d'us	Canviar Vista.
Descripció	L'usuari canvia la vista des del volum original al segmentat o viceversa.
Actors	El metge.
Precondició	Els volums han estat segmentats.
Flux principal	<ul style="list-style-type: none">• Si vista = original llavors canvia a segmentat.• Si vista = segmentat llavors canvia a original.
Postcondició	Si tot OK es canvia la vista.
Comentari	Si els volums no han estat segmentats canvia la vista pero no mostra res.

Taula 5.2: Especificació de cas d'us Canviar Vista.

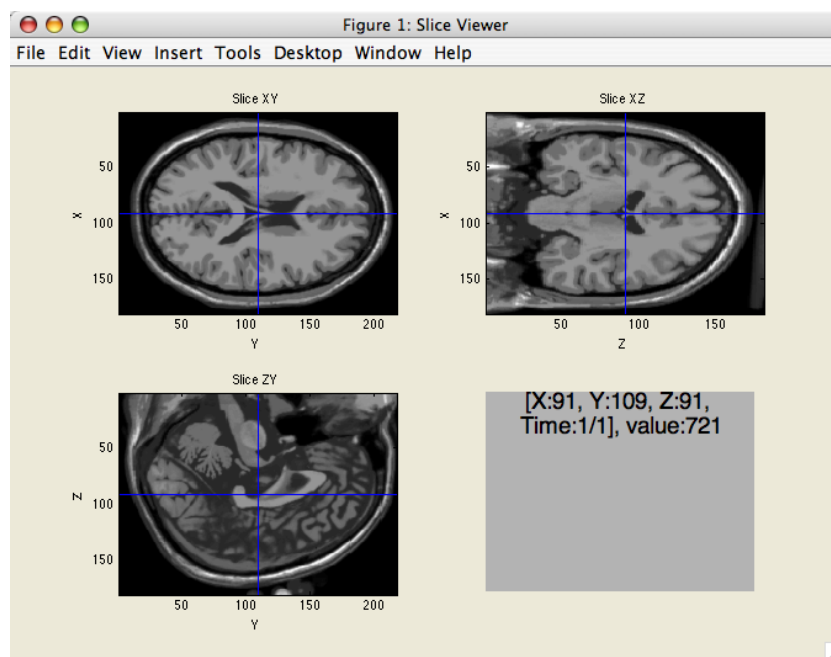


Figura 5.3: Slice Viewer 3D per Marian Uhercik.

A la interfície es pot observar el volum des de diferents punt de vista i seleccionar la secció que es vol veure, tant situant el punter del mouse en un punt, com movent amb les feltxes del teclat. Les línies blaves mostren el punt seleccionat, mentre al requadre gris s'indica la posició numèrica. Aquesta interfície només soluciona parcialment el primer dels requeriments fets pel qual s'han agut de fer les modificacions següents.

Duplicar la quantitat de volums visibles.. Per això ha calgut duplicar totes les variables que en feien referència i també els eixos on es mostren les imatges. A més a més, ha calgut desenvolupar una lògica més complexa de mostratge ja que ara el fet de canviar el posicionament afecta a les 6 imatges, enlloc de les tres de la interfície anterior.

Afegir la possibilitat de carregar els volums mitjançant la interfície gràfica. Anteriorment el volum era carregat directament amb la co-

manda que crida la interfície. Això és incòmode ja que requereix un aprenentatge per part dels metges de tasques alienes a la seva feina. Per això s'ha afegit un botó per a carregar cada volum, mitjançant el qual apareix un explorador per a localitzar el volum que es vol carregar. Llavors es fa tot el procés necessari fins a obtenir una imatge vàlida per a representar en els eixos.

Afegir una comunicació entre la interfície i les dades per a poder seleccionar les llavors. Ara ja no només es tracta de visualitzar les dades sinó que cal una interacció amb el mètode de segmentat per a poder fer-li arribar les dades. Per a fer això, en prèmer dos botons específics per la tasca, es guarda la posició on es vol situar la llavor i llavors es passen al mètode, el qual un cop finalitzat retorna el resultat a la interfície perquè els mostri.

Permetre dues vistes pel mateix volum, l'original i el segmentat, i el canvi entre vistes. Un cop finalitzat el resultat, amb l'objectiu de permetre una exhaustiva exploració per part dels metges es pot canviar la vista entre el volum original i el volum segmentat tants cops com es desitgi. A més a més, en cas de voler comparar dos volums adquirits en diferents dates es poden observar simultàniament gràcies a tenir 2 volums a la mateixa interfície.

A continuació es mostrarà la interfície amb les dues vistes de que disposa, la vista original, a la figura 5.4, i la vista amb els volums segmentats, a la figura 5.5. A l'annex B s'adjunta el manual d'usuari de la interfície.

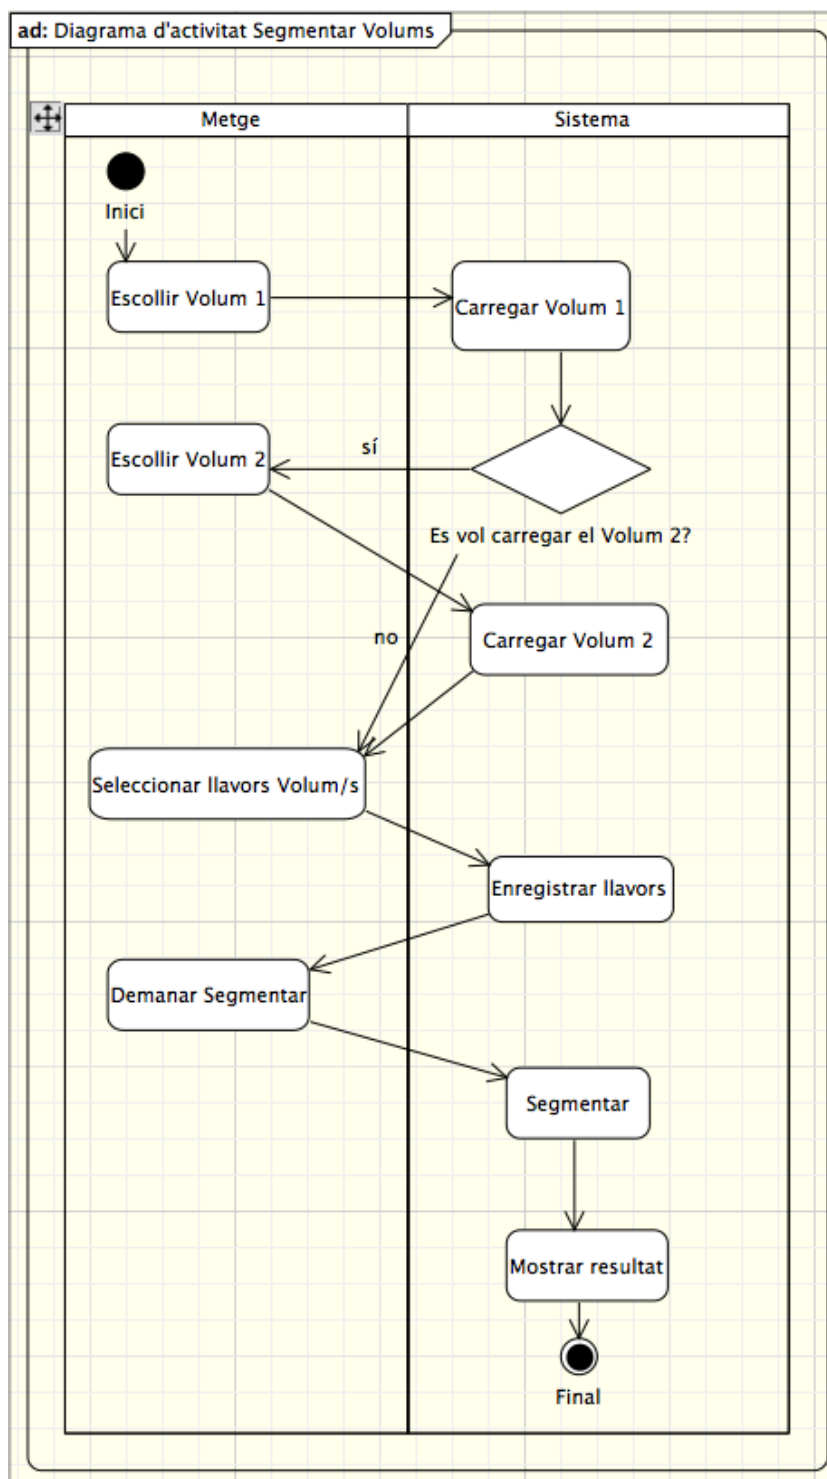


Figura 5.2: Diagrama d'activitat.

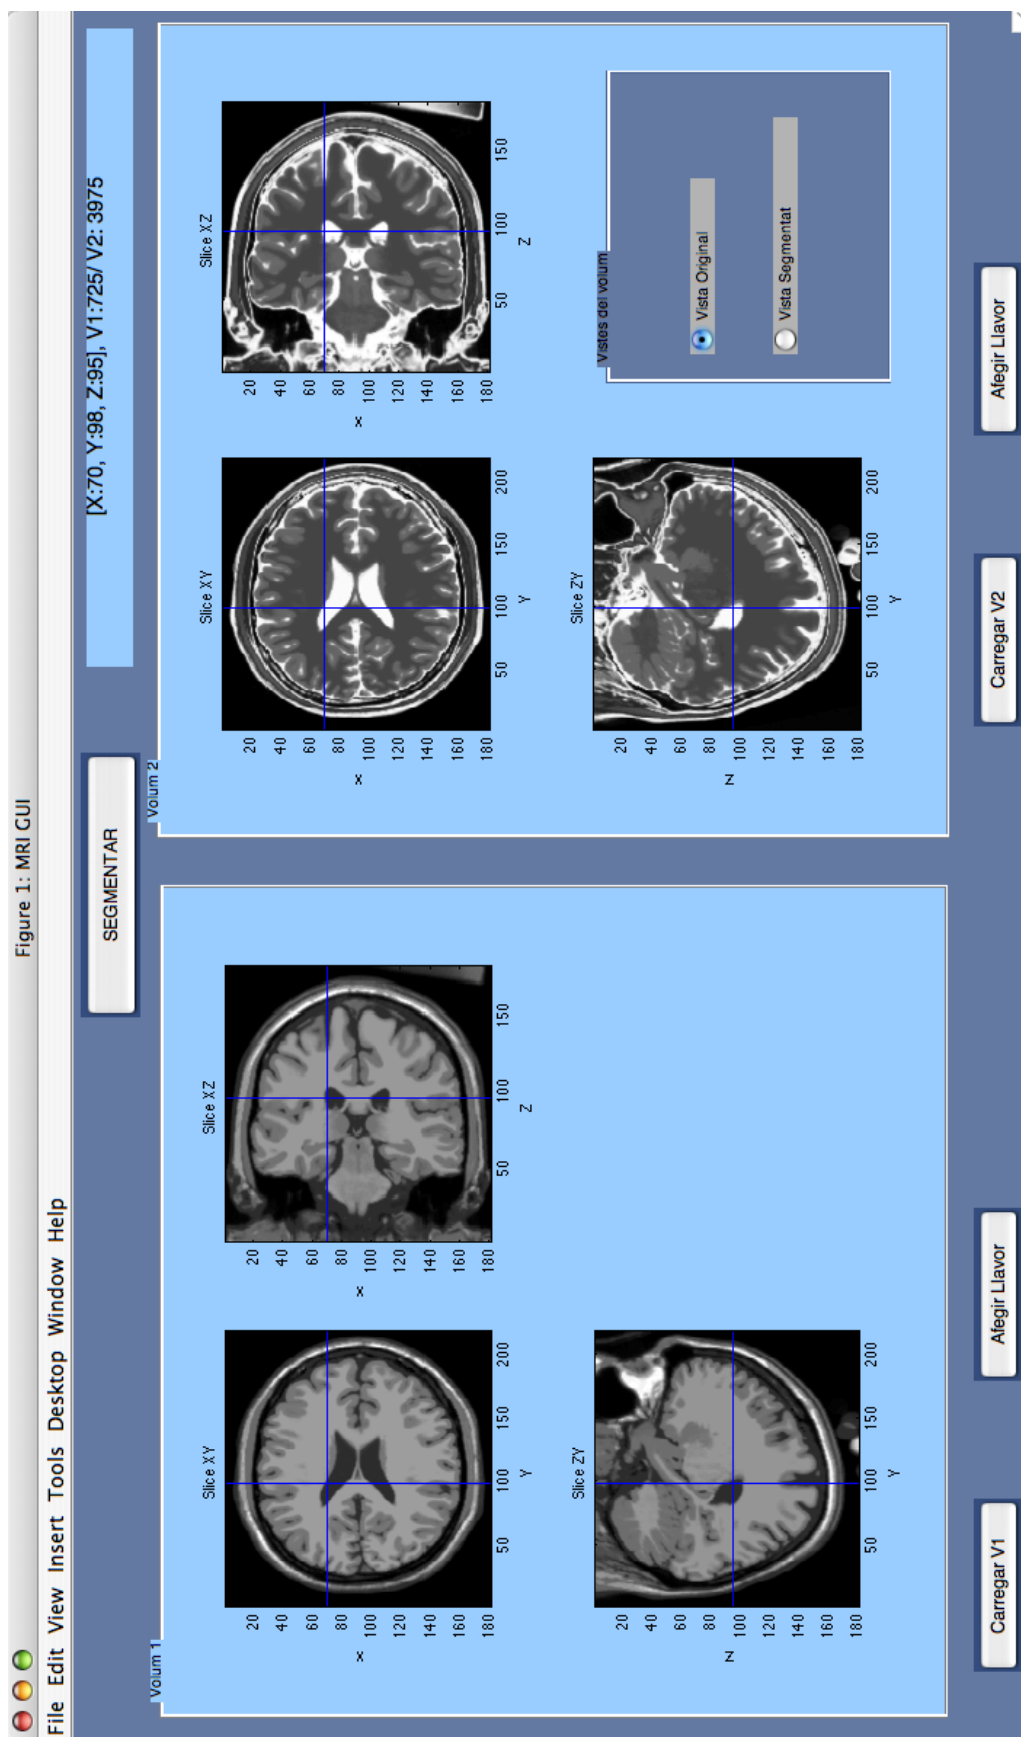


Figure 1: MRI GUI

Figura 5.4: Interfície gràfica. Vista original

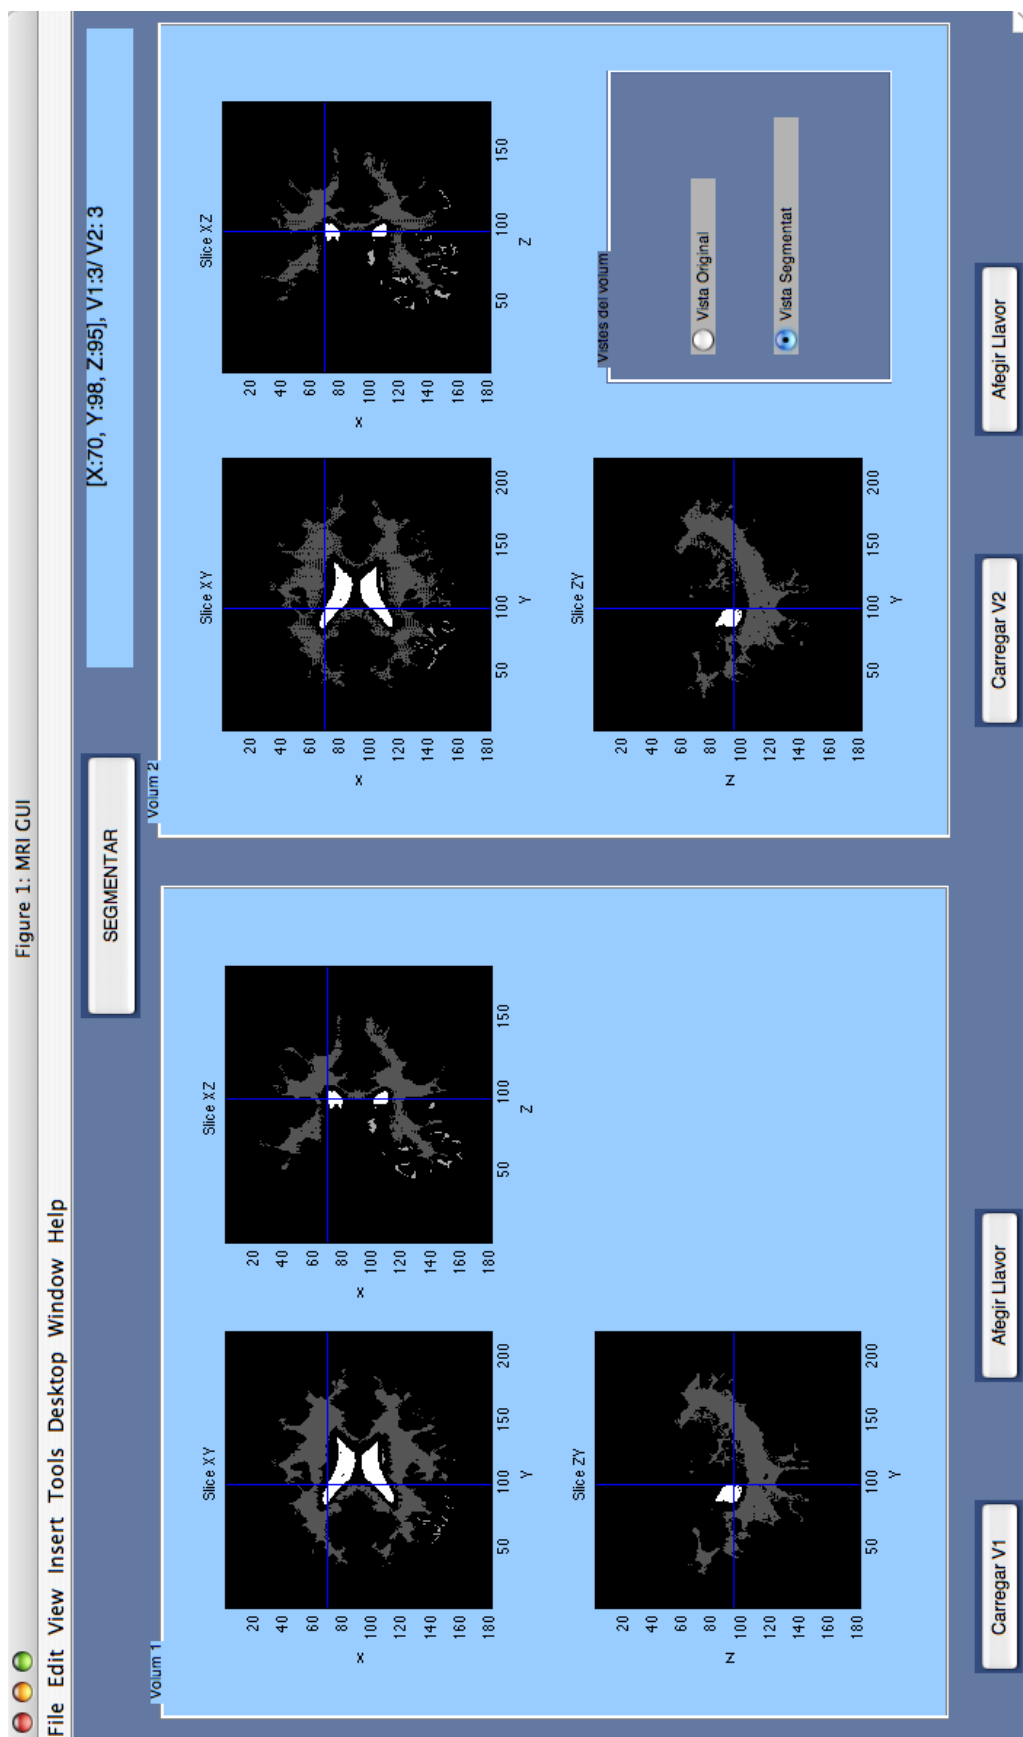


Figura 5.5: Interfície gràfica. Vista segmentat

Capítol 6

Conclusions i treballs futurs

En aquesta secció es farà una discussió de les conclusions que es poden treure a partir de la realització d'aquest projecte i també dels possibles treballs futurs, tant per a millorar la feina feta com per a obrir noves línies de recerca en aquest camp.

6.1 Conclusions extretes a partir del projecte

Després de totes les anàlisis realitzades en aquest projecte se'n poden extreure una sèrie de conclusions, les quals, a més a més de concretar la línia a seguir, obren pas a altres estratègies a desenvolupar en el futur.

Preprocessat. La primera conclusió important és la necessitat d'un bon preprocessat, ja que s'ha vist en les proves fetes amb quantitats importants de soroll i *bias*, tot i el preprocessat executat, que els fenòmens externs afecten molt negativament al resultat de la segmentació.

Tipus d'estrategia. També es pot concloure que, malgrat la tendència d'utilitzar estratègies de clustering, les basades en regions, poden ajudar

notablement a la millora dels resultats obtinguts. Concretament en la segmentació de teixits s'han aconseguit, en alguns casos, segmentacions molt acurades. D'altra banda no sembla una bona opció en el cas de segmentar lesions, ja que fàcilment es produeix una sobresegmentació per tota la matèria gris. Segurament, l'opció més intel·ligent pot ser la de fer servir tècniques basades en regions un cop s'ha fet la segmentació mitjançant estratègies de clustering amb l'objectiu de separar les regions no connectades espacialment però que són iguals en l'espai de mesures.

Estadístic. En un dels grans debats del projecte, el de fer servir un estadístic global o local, ara ja es pot argumentar a favor de la opció de l'estadístic global, que permet obtenir resultats bons, tot i ser més sensible als fenòmens externs que la opció de fer servir un algorisme amb estadístic local, però que no arriba a resultats acceptables. A més a més, s'ha comprovat que això es degut a que en els límits entre els diferents teixits no es produeix un canvi definit, de forma que la segmentació és més precisa si és fa servir un estadístic que també tingui en compte les parts més interiors de cada teixit.

Metodologia. Pel que fa al tema tractat al projecte, cal destacar que és molt important la interacció amb els metges i radiòlegs col·laboradors per a poder encaminar aquesta nova línia de recerca dins del grup VICOROB.

Objectius. En referència als objectius, s'ha aconseguit assolir els més importants. A la primera part, s'ha fet una revisió sobre els mètodes actuals. A partir d'aquí, s'ha aconseguit desenvolupar diferents mètodes per segmentar tant teixits com lesions de MRI de diferents modalitats, i també

s'ha desenvolupat una estratègia que combina diferents modalitats per fer la segmentació. Per finalitzar, s'ha implementat una interfície que facilita la seva utilització i permet comparar dos volums del mateix pacient obtinguts en diferents dates per observar-ne l'evolució.

6.2 Treballs futurs

Un cop acabat aquest projecte queden alguns punts per millorar, i també han sorgit altres treballs interessants.

Seguint en la línia del projecte:

Ampliar anàlisi de casos reals. Realitzar una anàlisi exhaustiva en casos reals. En les últimes reunions amb els metges s'han demanat i aviat es disposarà d'aquestes dades.

Implementar-ho en C++. MATLAB és una eina molt útil en la recerca perquè disposa d'una ampla llibreria però es força lenta en l'execució. Per aquest motiu podria ser interessant traduir les funcions a una altra tecnologia més ràpid, per exemple C++, llenguatge que disposa de bons compiladors i optimitzadors.

Altres possibles treballs podrien ser:

Millorar el preprocessat. Qualsevol sistema implementat ha de tenir una bona base, i per tant, seria interessant millorar els sistemes de preprocessat, ja que s'ha comprovat que les imatges afectades pels fenòmens externs, tot i sotmetre-les al preprocessat, no permeten aconseguir bons resultats. Per tant, els mètodes de preprocessat disponibles es podrien millorar.

Mètode de selecció de llavors. El desenvolupament d'un mètode que escollís les llavors inicials, per a cada matèria o lesió, permetria una total automatització del procés, fet que deslligaria totalment el sistema de la necessitat d'especialistes qualificats, els quals només jugarien el paper de la supervisió del resultat.

Apèndix A

Manual d'usuari de la toolbox de matlab

A.1 Funcions d'obtenció de les dades

A.1.1 llegirRAW

Crida a la funció:

`I = llegirRAW(filename, width, height, deep)`

Descripció:

Permet carregar a memòria un volum guardat en format `.raws`.

Paràmetres d'entrada

`filename` = nom del fitxer.

`width` = amplada del volum.

`heigh` = alçada del volum.

`deep` = profunditat del volum.

Paràmetres de sortida

`I` = Matriu de mida `width` x `heigh` x `deep` amb els valors corresponents a la

MRI.

A.1.2 load_nii

Aquesta funció forma part d'una toolbox desenvolupada per Jimmy Shen, membre del Rotman Research Institute (RRI).

Crida a la funció:

`I = load_nii(filename, [img_idx], [old_RGB], [tolerance], [preferredForm])`

Descripció:

Carrega dades en format NIFTI. És vàlida tant per formats *.nii com per *.hdr/*.img. Si no es concreta l'extensió *.hdr/*.img es farà servir per defecte.

Paràmetres d'entrada

`filename` = nom del fitxer NIFTI.

`img_idx`(opcional) = matriu numèrica dels índex del volum. Només es carregaran els volums especificats.

`old_RGB`(opcional) = un número escalat per indicar la diferència entre l'RGB24 i el vell.

`tolerance`(opcional) = distorsió permesa en la imatge carregada a qualsevol rotació no ortogonal o qualsevol tall de la matriu NIFTI afí. S'indica un valor entre 0 i 1. Si es posa a 0 no és permet cap distorsió, si es posa a 1 es permet qualsevol distorsió.

`preferredForm`(opcional) = indica la transformació des de voxels a coordenades RAS.

Paràmetres de sortida

`I` = estructura nii.

`I.hdr` = estructura amb els camps de la capçalera NIFTI.

`I.filetype` = indica si el format és *.hdr/*.img, o bé *.nii.

I.fileprefix = nom del fitxer sense extensió.

I.machine = variable string machine.

I.img_idx = índexs de la imatge a ser carregada.

I.img = matriu 3D (o 4D) amb els valors del volum NIFTI.

A.2 Funcions de preprocessat

A.2.1 wavelet_denoise

Crida a la funció:

vol_out=wavelet_denoise(vol_in,level,display)

Descripció:

Funció que treu el soroll blanc d'una imatge a nivell de gris (basat en S. Grace Chang et al., "Adaptive Wavelet Thresholding for Image Denoising and Compresion)

Paràmetres d'entrada

vol_in = volum d'entrada amb soroll.

level = nivell de descomposició (per defecte, 5).

Paràmetres de sortida

vol_out = volum sense soroll.

A.2.2 eliminar_crani

Crida a la funció:

volum_out = eliminar_crani(volum_in, mask)

Descripció:

Elimina la part de la imatge que no pertany al cervell, és a dir, os, pell,

múscul, etc.

Paràmetres d'entrada

volum_in = volum d'entrada.

mask = mascàra de les zones que no són cervell.

Paràmetres de sortida

volum_out = volum 3D amb només el cervell.

A.3 Funcions de segmentació

A.3.1 regionGrowing_global

Crida a la funció:

$[g, NR] = \text{regionGrowing_global}(f, S, \text{connectivitat})$

Descripció:

Segmenta un volum 3D fent servir com a estadístic la desviació estàndard de tota la regió segmentada.

Paràmetres d'entrada

f = volum d'entrada.

S = vector amb les coordenades de les llavors.

connectivitat = matriu que defineix el veïnatge d'un vòxel.

Paràmetres de sortida

g = volum segmentat.

NR = numero de regions segmentades.

A.3.2 regionGrowing_global_min

Crida a la funció:

`[g, NR] = regionGrowing_global_min(f, S, connectivitat, minim)`

Descripció:

Segmenta un volum 3D fent servir com a estadístic la desviació estàndard de tota la regió segmentada o un mínim imposat sempre que el valor de l'estadístic sigui inferior.

Paràmetres d'entrada

f = volum d'entrada.

S = vector amb les coordenades de les llavors.

connectivitat = matriu que defineix el veïnatge d'un vòxel.

minim = cota inferior dels valors que s'accepten com a desviació.

Paràmetres de sortida

g = volum segmentat.

NR = numero de regions segmentades.

A.3.3 regionGrowing_local_particions

Crida a la funció:

`[g, NR] = regionGrowing_local_particions(f, S, connectivitat, mida_x, mida_y, mida_z)`

Descripció:

Segmenta un volum 3D fent servir com a estadístic la desviació estàndard de diferents subvolums del volum total.

Paràmetres d'entrada

f = volum d'entrada.

S = vector amb les coordenades de les llavors.

connectivitat = matriu que defineix el veinatge d'un vòxel.

mida_x = amplada dels subvolums.

mida_y = profunditat dels subvolums.

mida_z = alçada dels subvolums.

Paràmetres de sortida

g = volum segmentat.

NR = numero de regions segmentades.

A.3.4 regionGrowing_local_finestra

Crida a la funció:

[g, NR] = regionGrowing_local_finestra(f, S, connectivitat, Mida_radi_finestra)

Descripció:

Segmenta un volum 3D fent servir com a estadístic la desviació estàndard de la zona esfèrica amb el radi indicat amb centre al vòxels que s'està explorant.

Paràmetres d'entrada

f = volum d'entrada.

S = vector amb les coordenades de les llavors.

connectivitat = matriu que defineix el veinatge d'un vòxel.

Mida_radi_finestra = mida del radi de l'esfera amb la qual es calcula l'estadístic local.

Paràmetres de sortida

g = volum segmentat.

NR = numero de regions segmentades.

A.3.5 regionGrowing_multimodalitat

Crida a la funció:

[g, NR, SI, TI] = regionGrowing_multimodalitat(S, connectivitat, f1, f2, [f3])

Descripció:

Segmenta un volum 3D fent servir com a estadístic la desviació estàndard de tota la regió segmentada, utilitzant 2 ó 3 modalitats a la vegada.

Paràmetres d'entrada

S = vector amb les coordenades de les llavors.

connectivitat = matriu que defineix el veïnatge d'un vòxel.

f = volum d'entrada 1.

f2 = volum d'entrada 2.

f3 (opcional) = volum d'entrada 3.

Paràmetres de sortida

g = volum segmentat.

NR = numero de regions segmentades.

A.4 Funcions d'avaluació del resultat

A.4.1 comparar

Crida a la funció:

resultat = comparar(im_segm, ground_truth)

Descripció:

Donada la segmentació del volum i el ground truth proporciona tres coeficients d'avaluació. TPF, DSC i Area Overlap per a cada teixit.

Paràmetres d'entrada

im_segm = volum segmentat.

ground_truth = segmentació realitzada manualment del mateix volum per part d'un metge o radiòleg.

Paràmetres de sortida

resultat = estructura amb tots els coeficients.

resultat.TPF_MB = TPF de la matèria blanca.

resultat.TPF_MG = TPF de la matèria gris.

resultat.TPF_CSF = TPF del CSF.

resultat.DSC_MB = DSC de la matèria blanca.

resultat.DSC_MG = DSC de la matèria gris.

resultat.DSC_CSF = DSC del CSF.

resultat.Jaccard_MB = Area Overlap de la matèria blanca.

resultat.Jaccard_MG = Area Overlap de la matèria gris.

resultat.Jaccard_CSF = Area Overlap del CSF.

Apèndix B

Manual d'usuari de la interfície gràfica

B.1 Descripció de la interfície

Seguint la figura B.1 la interfície està formada pels elements següents:

1. **Segmentar.** Serveix per a començar l'execució de l'algorisme de segmentació.
2. **Visor volum 1.** Tres plans que mostren la MRI carregada al volum 1. Es pot canviar el punt d'interés clicant en un altre punt amb el ratolí o bé amb les fletxes del teclat.
3. **Afegir llavor (Volum 1).** Aquest botó afegeix com a llavor el punt seleccionat amb el visor del volum 1 per a la posterior segmentació.
4. **Carregar V1.** Serveix per escollir quina MRI es vol carregar com a volum 1.




Figura B.1: Descripció de la interfície.

5. **Informació actual.** Aquest 'box' mostra les coordenades del punt seleccionat i el valor que aquest té a cadascun dels volums.
6. **Visor volum 2.** Tres plans que mostren la MRI carregada al volum 2. Es pot canviar el punt d'interés clicant en un altre punt amb el ratolí o bé amb les fletxes del teclat.
7. **Selector de vista.** S'utilitza per canviar entre la vista original de les MRI i la vista segmentada.
8. **Afegir llavor (Volum 2).** Aquest botó afegeix com a llavor el punt seleccionat amb el visor del volum 2 per a la posterior segmentació.
9. **Carregar V2.** Serveix per escollir quina MRI es vol carregar com a volum 1.

B.2 Utilització de la interfície

La interfície té dues funcions principals. La primera és l'exploració dels volums. El fet de tenir dues vistes simultànies permet veure l'evolució temporal d'un pacient, com també, dues modalitats diferents de la mateixa MRI. La segona és la segmentació dels volums o lesions, per a poder fer les diferents valoracions.

B.2.1 Explorar volums

Per explorar els volums s'han de fer els següents passos:

1. Prémer el botó **Carregar V1** i escollir la MRI que es carregarà al **Visor volum 1**.

2. Prémer el botó **Carregar V2** i escollir la MRI que es carregarà al **Visor volum 2**.

3. Moure el punt d'interés.

Amb el ratolí, fent clic sobre un dels tres plans en el punt d'interés.

Amb les tecles \leftarrow , \rightarrow , \uparrow , \downarrow del teclat per moure sobre l'últim pla que s'ha seleccionat amb el ratolí.

B.2.2 Segmentar volums

Per segmentar els volums s'han de fer els següents passos:

1. Prémer el botó **Carregar V1** i escollir la MRI que es carregarà al **Visor volum 1**.

2. Prémer el botó **Carregar V2** i escollir la MRI que es carregarà al **Visor volum 2**.

3. Situar-se a sobre del punt d'interés.

Amb el ratolí, fent clic sobre un dels tres plans en el punt d'interès.

Amb les tecles \leftarrow , \rightarrow , \uparrow , \downarrow del teclat per moure sobre l'últim pla que s'ha seleccionat amb el ratolí.

4. Prèmer **Afegir llavor (Volum 1)** o **Afegir llavor (Volum 2)** segons es desitgi.

5. Repetir els últims dos passos fins a haver seleccionat totes les llavors necessàries.

6. Premer el botó **Segmentar**.

7. Canviar de vistes amb el botó **Selector de vista** per a una millor exploració.

Bibliografia

- [1] Brainweb: Simulated brain database. <http://www.bic.mni.mcgill.ca/brainweb/>.
- [2] J. Ashburner and K. J. Friston. *Unified segmentation*. NeuroImage, 2005.
- [3] A.O. Boudraa, S. M. R. Dehak, Y.M. Zhu, C. Pachai, Y.G. Bao, and J. Grimaud. *Automated segmentation of multiple sclerosis lesions in multispectral MR imaging using fuzzy clustering*. Computers in Biology and Medicine, 2000.
- [4] M. Bach Cuadra, C. Pollo, A. Bardera, O. Cuisenaire, J.-G. Villemure, and J.-P Thiran. *Atlas-based segmentation of pathological MR brain images using a model of lesion growth*. IEEE Transactions on Medical Imaging, 2008.
- [5] S. Datta, B. R. Sajja, R. He, J. S. Wolinsky, R. K. Gupta, and P. A. Narayana. *Segmentation and quantification of black holes in multiple sclerosis*. NeuroImage, 2006.
- [6] D.Vernon. *Machine Vision*. Ed. Prentice Hall, 1991.
- [7] Rosati G. *The prevalence of multiple sclerosis in the world: an update*. Neurol. Sci. 22, 2001.

-
- [8] M. Ghazel, A. Trabousee, and R. K. Ward. *Semi-automated segmentation of multiple sclerosis lesions in brain MRI using texture analysis*. In IEEE International Symposium on Signal Processing and Information Technology 2006, 2006.
- [9] Gonzalez and Woods. *Digital Image Processing*. Adisson Wesley Publishing Company, 1993.
- [10] González, Woods, and Richard E. *Digital image processing using Matlab*. Prentice, 2004.
- [11] Z. Hou and S. Huang. *Characterization of a sequential pipeline approach to automatic tissue segmentation from brain MR images*. International Journal of Computer Assisted Radiology and Surgery, 2008.
- [12] Kasuga Huang. Modern high field clinical mri scanner. http://en.wikipedia.org/wiki/File:Modern_3T_MRI.JPG, 2008.
- [13] B. Johnston, M. S. Atkins, B. Mackiewich, and M. Anderson. *Segmentation of multiple sclerosis lesions in intensity corrected multispectral MRI*. IEEE Transactions on Medical Imaging, 1996.
- [14] J. k. UDAPA, L. Wei, S. Samarasekera, Y.Miki, M. A. van Buchem, and R. I. Grossman. *Multiple sclerosis lesion quantification using fuzzy-connectednes principles*. IEEE Transactions on Medical Imaging, 1997.
- [15] Jeremy Kemp. Standard deviation diagram. http://en.wikipedia.org/wiki/File:Standard_deviation_diagram.svg, 2005.

-
- [16] A. W.-C. Liew and H. Yan. *IEEE Transactions on Medical Imaging*. An adaptive spatial fuzzy clustering algorithm for 3-D MR image segmentation, 2003.
- [17] Xavier Lladó. *Visió per Computador*. Universitat de Girona, 2008.
- [18] M.Cabezas. *Projecte de final de carrera: Mètodes de segmentació aplicats a MRI d'esclerosi múltiple*. Universitat de Girona, 2009.
- [19] S. Nie, Y. Zhang, W. Li, and Z. Chen. *A fast and automatic segmentation method of MR brain images based on genetic fuzzy clustering algorithm*. In Proceedings of the 29th Annual International Conference of the IEEE EMBS, 2007.
- [20] D. L. Pham. *Spatial models for fuzzy clustering*. Computer Vision and Image Understanding, 2001.
- [21] S. Ruan, B. Moretti, J. Fadili, and D. Bloyet. *Fuzzy Markovian segmentation in application of magnetic resonance images*. Computer Vision and Image Understanding, 2002.
- [22] D. W. Shattuck, S. R. Sandor-Leahy, K. A. Schaper, D. A. Rottenberg, and R. M. Leahy. *Magnetic resonance image tissue classification using a partial volume model*. NeuroImage, 2001.
- [23] N. Shiee, P. L. Bazin, J. L. Cuzzocreo, D. S. Reich, P. A. Calabresi, and D. L. Pham. *Topologically constrained segmentation of brain images with multiple sclerosis lesions*. In MICCAI workshop on Medical Image Analysis on Multiple Sclerosis (validation and methodological issues), 2008.

-
- [24] Marian Uhercik. 3d slice viewer. <http://www.mathworks.co.uk/matlab-central/fileexchange/20604>, 2008.
- [25] Y. Zhang, M. Brady, and S. Smith. *Segmentation of brain MR images through a hidden Markov random field model and the expectation-maximization algorithm*. IEEE Transactions on Medical Imaging, 2001.