Universitat de Girona
Escola Politècnica Superior

Projecte/Treball Final de Carrera

Estudi: Enginyeria Tècnica en Informàtica de Sistemes

Títol:

Document: **Memòria**

Alumne: **Gerard Alcorlo Bofill**

Director/Tutor: Jordi Freixenet i Bosch / Anna Bosch Rue
Departament: Electrònica, Informàtica i Automàtica
Àrea: Visió per Computador

Convocatòria: Juliol 2004

1 DESCRIPCIÓ DEL PROJECTE 7
1.1 Introducció 8
1.2 Objectius 11
1.3 Planificació 12
1.4 Organització de la memòria 15
2 ENTORN DE TREBALL 16
2.1 Introducció 17
2.2 Modalitats bàsiques 17
2.3 Tipus de lesions 18
2.4 Masses 19
2.5 Segmentació de lesions 21
2.5.1 Segmentació global 21
2.5.2 Segmentació de masses 22
3 DESCRIPTORS BÀSICS DE FORMA 24
3.1 Introducció 25
3.2 Descriptors bàsics 25
3.3 Resultats i Conclusions 28
4 DESCRIPTORS AVANÇATS DE FORMA 30
4.1 Introducció 31
4.2 Mètode de Chang 32
4.2.1 Punts de màxima corbatura (PMC) 33
4.2.2 Descriptors de Chang 39
4.2.3 Resultats i conclusions 41
4.3 Mètodes de Fourier 44
4.3.1 Extracció de contorn 46
4.3.2 Signatura de la Forma 48
4.3.3 La Transformada de Fourier 53
4.3.4 Transformada Discreta de Fourier (TFD) 54
4.3.5 Equidistància 55
4.3.6 Resultats i Conclusions 63
5 CBIR I CLASSIFICACIÓ 64
5.1 INTRODUCCIÓ 65
5.2 SISTEMA CBIR 65
5.3 CLASSIFICACIÓ 68
6 DISSENY 70
6.1 INTRODUCCIÓ 71
6.2 BASE DE DADES 71
6.2.1 Model Entitat Relació 71
6.2.2 Model Relacional 72
6.3 APLICACIÓ 73
6.3.1 DESCRIPTORS BÀSICS 73
6.3.2 MÈTODE DE CHANG 74
6.3.3 MÈTODE DE FOURIER 75
6.3.4 Sistemes de classificació i CBIR 76
7 RESULTATS 77
7.1 Introducció 78
7.2 Imatges utilitzades 79
7.2.1 Imatges geomètriques 79

7.2.2 Imatges Sintètiques 80
7.2.3 Imatges Mamogràfiques 81
7.3 Resultats 82
7.3.1 Reconeixement 82
7.3.2 CBIR 92
8 CONCLUSIONS I TREBALLS FUTURS 101
8.1 CONCLUSIONS 102
8.2 TREBALLS FUTURS 103
9 REFERÈNCIES 105
ANNEX A 108
L'APLICACIÓ 109
ANNEX B 116

ÍNDEX DE FIGURES

Fig. 1 – Esquema bàsic del funcionament del sistema HRIMAC 9
Fig. 2 – Esquema bàsic de l'aplicació desenvolupada en aquest PFC 10
Fig. 3 – Cranio Caudal 17
Fig. 4 – Medio Lateral Obliqua 18
Fig. 5 – Tipus de lesions 19
Fig. 6 – Esquema de les possibles masses presents a una mamografia, ordenades segones la seva benignitat 20
Fig. 7 – Masses reals 20
Fig. 8 – Lesions espiculars reals 21
Fig. 9 – Diferents parts d'una mamografia: etiquetes i marcs, pit i muscle, fons de la imatge ..22
Fig. 10 – Mamografia desprès d'aplicar-hi l'algorisme de segmentació global 22
Fig. 11 – (a) Massa de la mamografia original (b) Segmentació d'una massa (c) binarització de la massa segmentada 23
Fig. 12 – Distància entre píxels 25
Fig. 13 – Connectivitats possibles 26
Fig. 14 – Representació d'una diagonal depenent de la connectivitat 26
Fig. 15 – Exemples dels descriptor bàsic *Compactesa* 27
Fig. 16 – Exemple del rectangle mínim envolvent 27
Fig. 17 – Dues figures diferents que presenten el mateix mínim rectangel envolvent 29
Fig. 18 – Diferents vistes d'un objecte 31
Fig. 19 – Angle β en funció del contorn 34
Fig. 20 – Troba contorns verticals 35
Fig. 21 – Troba contorns horitzontals 35
Fig. 22 – Amb blau la representació del mòdul M i l'angle φ 36
Fig. 23 – Representació d'alguns dels valors del gradient 37
Fig. 24 – Amb vermell el contorn de Sobel. Amb una creu s'han marcat els píxels sobrants 37
Fig. 25 – Representació de l'àrea USAN 38
Fig. 26 – Punts de màxima corbatura 39
Fig. 27 – Centre de masses C 39
Fig. 28 – a) Distància entre el centre de masses i els PMC b) Representació de les distàncies en forma de gràfica 40
Fig. 29 – Distàncies normalitzades 40
Fig. 30 – Distàncies ordenades 41
Fig. 31 – SUSAN troba 5 PMC en un el·lipse 42
Fig. 32 – SUSAN troba 10 PMC en un el·lipse 42
Fig. 33 – Figures diferents considerades iguals pel mètode de Chang 42
Fig. 34 – Amb sobel només trobem 6 PMC 43
Fig. 35 – Amb SUSAN trobem els 9 PMC 43
Fig. 36 – La rotació d'una mateixa figura no presenta correspondència de manera directa 44
Fig. 37 – Procediment d'obtenció dels descriptors de Fourier 45
Fig. 38 – Procés d'obtenció del contorn 47
Fig. 39 – Fals contorn d'una figura 48
Fig. 40 – Representació de la recta pp' de la signatura Chord Length 49
Fig. 41 – Punts del contorn agafats en sentit contrari a les agulles del rellotge 50
Fig. 42 – Perímetre d'un rectangle 51
Fig. 43 – Mòduls de la Fig. 42 agafats com a signatura 51

Fig. 44 – Representació de les distàncies respecte el centre pels punts escollits del contorn de la 52
Fig. 45 – Contorn de dues imatges diferents 52
Fig. 46 – Representació de la distància respecte el centre de dues figures de la Fig. 45 52
Fig. 47 – Modus operandis de la interplació per splines lineals 57
Fig. 48 – Pas 1 i pas 2 de l'otenció dels descriptors de Fourier 58
Fig. 49 – Signatura coordenada complexe.....58
Fig. 50 – Signatura distància respecte el centre.....58
Fig. 51 – Espectre utilitzant signatura coordenada complexe 59
Fig. 52 – Espectre utilitzant signatura distància respecte centre 59
Fig. 53 – Reconstrucció d'un quadrat de K mostres utilitzant P descriptors.....60
Fig. 54 – Esquema d'un sistema CBIR. Recuperació d'imatges basat en el seu contingut.....66
Fig. 55 – Sistema de Classificació. Fase d'aprenentatge.....68
Fig. 56 – Sistema de classificació. Fase de reconeixement 69
Fig. 57 – Representació esquemàtica dels tipus d'imatges de cada classes que hem utilitzat per fer resultats 79
Fig. 58 – Exemples d'imatges del tipus Y de la classe de les imatges geomètriques 80
Fig. 59 – Exemples d'imatges del tipus ocells de la classe sintètiques 80
Fig. 60 – Exemples de masses espiculars 81
Fig. 61 – Representació del descriptor únic FF a l'eix Y per cada tipus d'imatge geomètrica.....84
Fig. 62 – Representació del descriptor únic FF a l'eix Y per cada tipus d'imatge sintètica.....89
Fig. 63 – Representació del descriptor únic FF a l'eix Y per cada tipus d'imatge mamogràfica ..91
Fig. 64 – Resultats obtinguts d'aplicar Fourier utilitzant coordenada complexe a partir d'un total de 512 descriptors de Fourier 93
Fig. 65 – Resultats obtinguts d'aplicar Fourier utilitzant distància respecte el centre a partir d'un total de 256 descriptors de Fourier.....93
Fig. 66 – Resultats obtinguts a partir del descriptor únic calculat utilitzant 512 descriptors de Fourier.....94
Fig. 67 – Resultat que dóna cada mètode per la classe d'imatges geomètriques.....94
Fig. 68 – Resultats obtinguts d'aplicar coordenada complexe utilitzant 512 descriptors de Fourier 95
Fig. 69 – Resultats obtinguts a partir del descriptor únic calculat a partir de 512 mostres.....96
Fig. 70 – Resultats obtinguts de calcular 256 descriptors utilizant distància al centre 96
Fig. 71 – Resultat que dóna cada mètode per la classe d'imatges sintètiques.....97
Fig. 72 – Resultats obtinguts utilitzant signatura de coordenada complexe i un total de 1024 descriptors de Fourier 98
Fig. 73 – Resultats obtinguts utilitzant signatura respecte distància al centre i un total de 512 descriptors de Fourier 98
Fig. 74 – Resultats obtinguts a partir del descriptor únic calculat a partir de 1024 mostres.....99
Fig. 75 – Resultats que dóna cada mètode per la classe d'imatges mamogràfiques.....99
Fig. 76 – Aspecte de l'aplicació.....110
Fig. 77 – Detall dels menús i botons del programa.....110
Fig. 78 – Aspecte del diàleg de Chang 112
Fig. 79 – Diàleg de Fourier 113

1 DESCRIPCIÓ DEL PROJECTE

1.1 INTRODUCCIÓ

El càncer de pit és un tumor maligne que s'origina d'una única cèl·lula que ha sofert mutacions o canvis anormals respecte les cèl·lules sanes. Aquest tumor es reprodueix activament augmentant el seu volum a expenses dels teixits i òrgans veïns. A més a més, aquest tumor té la capacitat de difondre's a distància fins arribar a altres òrgans; quan això succeeix s'anomena metàstasi.

El càncer de mama és el tipus de càncer més freqüent entre el sexe femení. Entre els 15 i 54 anys d'edat és el càncer que més morts provoca. Aquesta malaltia es sol presentar a partir dels 50 anys però a una tercera part de les dones se'ls presenta entre els 39 i 49 anys; fent així que una de cada 9 dones en quedi afectada al llarg de la seva vida. Les possiblitats de cura són molt elevades, properes al 90%, sempre i quan es localitzi a temps. És per aquest motiu que és molt important oferir als radiòlegs eines que permetin ajudar-los a diagnosticar la presència del càncer de mama.

Amb la introducció dels programes de screening (mamografies, ecografies i examen físic) a principis dels anys 80 es produeix un augment important en el diagnòstic de tumors en estadis precoços i tumors microscòpics [1]. Tot i això, la incidència de tumors de gran tamany no ha disminuït.

Els programes de screening, particularment amb l'ús de les mamografies, poden reduir la mortalitat del càncer un 25% [1]. Per aquesta raó, els metges recomanen controls mamogràfics periòdics per tal de facilitar la detecció precoç d'un possible origen de càncer. Aquestes polítiques de screening generen un gran volum d'imatges mamogràfiques difícils de manipular pels radiòlegs. És important doncs, estructurar-ne la informació i facilitar l'accés a les mamografies que puguin ser útils pel cas que s'estigui intentant diagnosticar.

El present Projecte Final de Carrera (PFC) s'emmarca dins el projecte HRIMAC (*Herramienta de Recuperación de Imágenes Mamográficas por Análisis de Contenido),* iniciat l'any 2003 i subvencionat pel "Ministerio de Ciencia y Tecnología" i els fons FEDER. En aquest projecte hi participa la Universitat de Girona, la Universitat Ramón Llull, i especialistes de l'hospital de Girona Josep Trueta. La planificació del projecte es realitza a tres anys vista, distribuint les tasques a realitzar entre diferents directors responsables dels tres centres.

El projecte HRIMAC, pretén ser un projecte de recuperació d'imatges mamogràfiques per contingut. Així doncs, a partir d'una imatge mamogràfica sobre la qual es pretén emetre un diagnòstic, HRIMAC busca a la base de dades les mamografies més similars. D'aquesta manera, cada cerca proporciona un conjunt limitat de casos amb característiques molt semblants a la mamografia que s'està estudiant. L'anàlisi d'aquests casos, pot ajudar al radiòleg a diagnosticar amb més garanties d'èxit i augmentar d'aquesta forma el grau d'eficàcia en la interpretació. Els PFCs realitzats durant el curs 2002-2003 per David Raba [**2**], Anna Bosch [**3**] i Joan Espunya [4], aporten una descripció més detallada del sistema.

Tot seguit a la Fig. 1 es pot veure el funcionament de l'arquitectura del sistema d'HRIMAC, on s'ha marcat de color vermell la part en què s'ha treballat en aquest projecte (extracció de característiques).

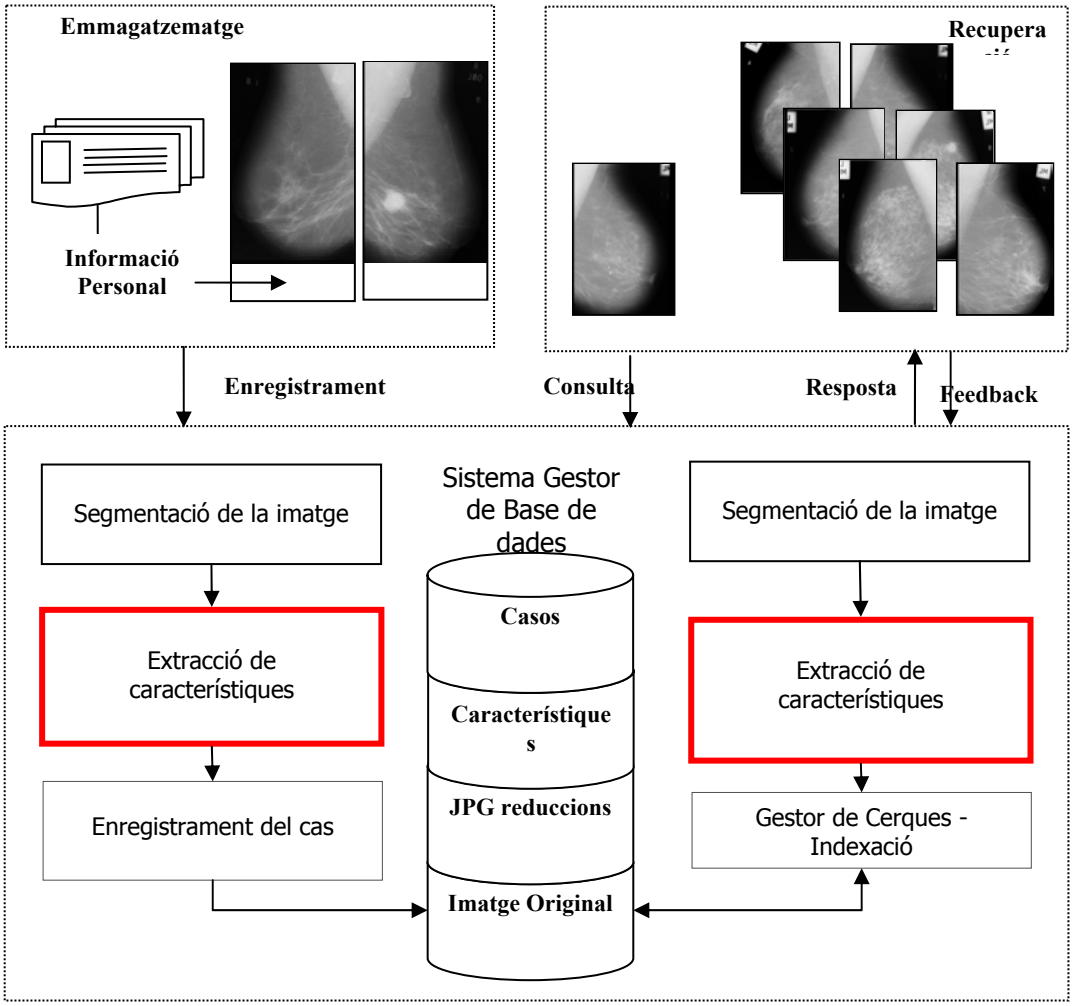

Fig. 1 – Esquema bàsic del funcionament del sistema HRIMAC

En aquest PFC s'han estudiat, discutit, analitzat i implementat una petita part del projecte HRIMAC, concretament la que es correspon amb caracterització de lesions segons la seva forma. S'han estudiat diferents descriptors de forma per tal de determinar quins són els millors a l'hora de tractar amb lesions mamogràfiques. La següent figura mostra esquemàticament les tasques dutes a terme.

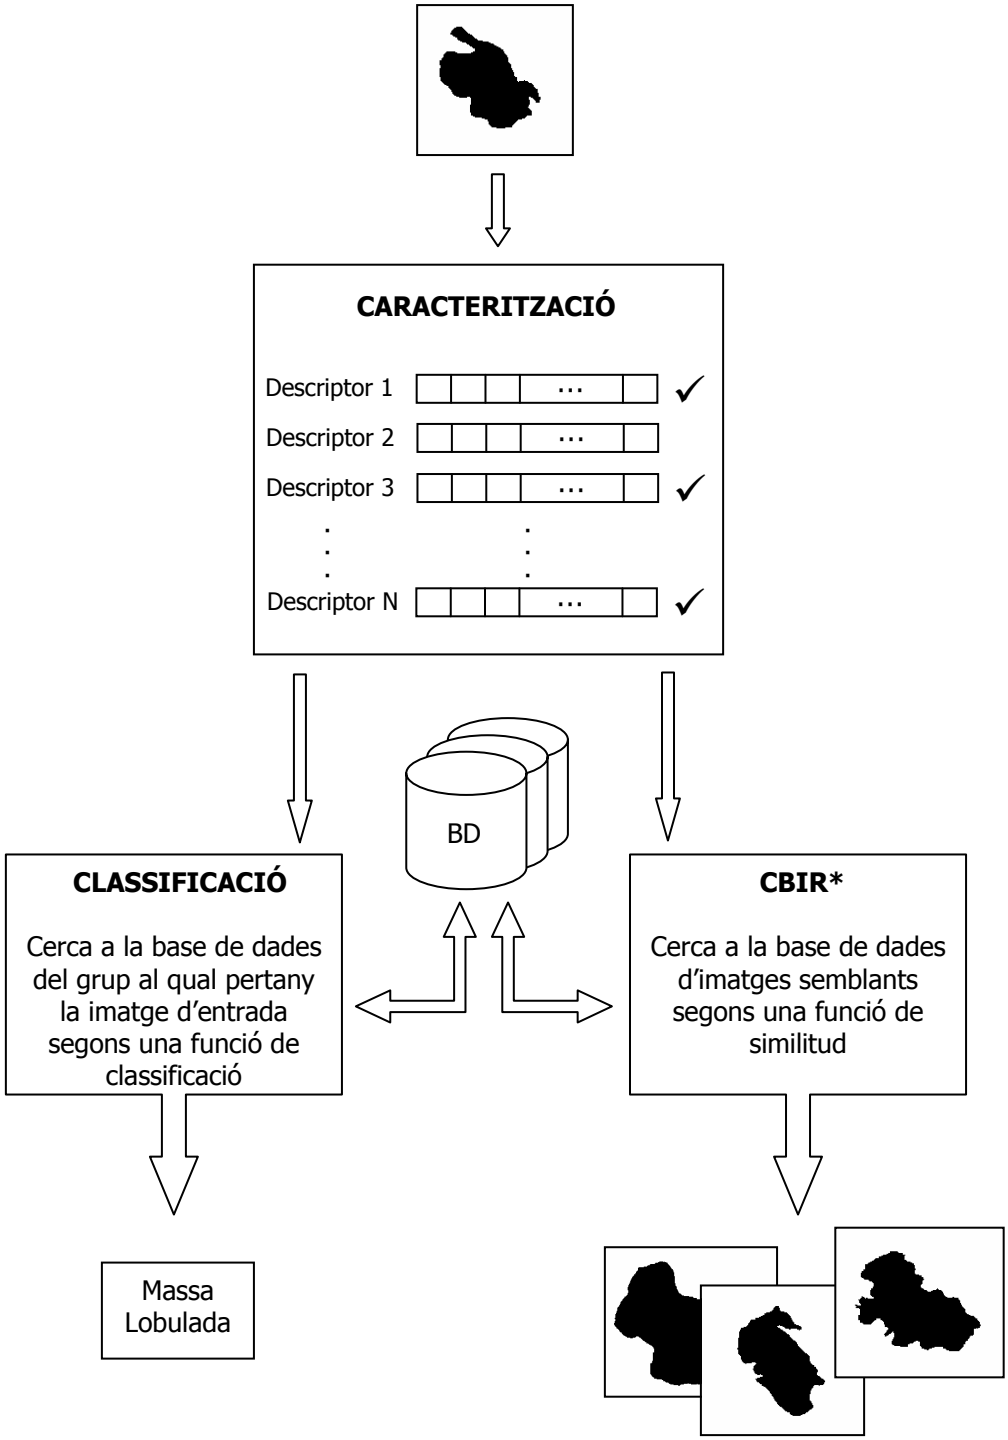

Fig. 2 – Esquema bàsic de l'aplicació desenvolupada en aquest PFC

*Content Based Image Retrieval

L'entrada del sistema desenvolupat és una imatge binaritzada (dos colors, blanc i negre) que conté una lesió segmentada. El que fa l'aplicació desenvolupada, és caracteritzar la lesió segons la seva forma per tal de poder obtenir un conjunt de característiques que ens descriuen el tumor de la mamografia que s'està estudiant. Tot seguit l'usuari pot seleccionar els descriptors que vol estudiar i el sistema és capaç de:

a) recuperar d'una base de dades altres mamografies que contenen lesions similars segons una mesura de similitud basada en els descriptors de forma seleccionats per l'usuari.

b) determinar a quin tipus de lesió de les ja classificades pertany el tumor que s'està estudiant. Cal fer notar que aquesta opció no és un objectiu del projecte HRIMAC, tot i així s'ha cregut oportú tenir-la en compte per tal de determinar quin és l'abast d'utilitzar característiques de forma en el processament d'imatges en general.

1.2 OBJECTIUS

Aquest projecte final de carrera pretén ésser una eina per testejar diferents mètodes d'extracció de característiques útils a l'hora de recuperar casos de la base de dades de HRIMAC. Per fer-ho ens centrarem en característiques de forma, donant èmfassis en aquelles que es basen en l'estudi del contorn de la lesió.

Concretament, a partir d'una imatge mamogràfica que conté una lesió segmentada, ens hem centrat en:

- Estudiar diferents mètodes tradicionals d'extracció de forma (àrea, perímetre, elongació...) que ens puguin donar una indicació de la mida, amplada, o posició del tumor.
- Analitzar i implementar diferents mètodes de descripció de forma que es basen en el contorn.
- Testejar els mètodes implementats tant per imatges sintètiques com per imatges mamogràfiques:
    a) En una aplicació CBIR, de recuperació d'imatges per contingut.
    b) En una aplicació de classificació, de reconeixement de casos patològics.
- Crear una base de dades independent de la base de dades HRIMAC per tal de poder testejar els descriptors de forma.

- Desenvolupar una aplicació prou flexible que permeti la incorporació de nous mètodes d'extracció de característiques, ja sigui de forma o de textura.

1.3 PLANIFICACIÓ

Per tal d'organitzar la feina a realitzar s'han temporitzat les tasques. D'aquesta manera serà més fàcil poder assolir els objectius fixats a la data prevista i realitzar-ne el seu seguiment. La planificació de treball que s'ha realitzat en aquest PFC, es divideix en 13 etapes:

1) *Familiarització amb l'entorn de treball*
   Assolir els conceptes bàsics de visió per computador, així com fer una primera aproximació a les eines de desenvolupament utlitzades en el projecte HRIMAC (Kdevelop, Qt, PostgreSql).

2) *Estudi de diferents descriptors de forma bàsics*
   Recollir informació sobre els descriptors bàsics de forma utlitzats en visió per computador (àrea, perímetre,...) així com començar l'anàlisi i disseny de l'aplicació en kdevelop.

3) *Implementació dels descriptors bàsics més interessants*
   Implementar els descriptors bàsics seleccionats en l'etapa prèvia.

4) *Anàlisi i disseny del mètode de Chang*
   Cerca d'informació i avaluació del mètode de Chang com a eina per l'extracció de forma d'un objecte. Anàlisi i disseny per tal d'implementar posteriroment el mètode a l'aplicació.

5) *Implementació de Chang*
   Implementar el disseny realitzat a l'etapa prèvia.

6) *Proves amb Chang*
   Fer proves amb el mètode implementat. Les proves consisteixen en avaluar el seu funcionament primerament utlitzant imatges sintètiques (triangles, rodones), posteriorment utlitzant imatges que contenen ojectes naturals ja binaritzats, i finalment fer una avaluació del funcionament del mètode amb mamografies.

7) *Recopilació i estudi de documentacio de la transformada de Fourier i tot el que té a veure amb el domini freqüencial*

   Recollida d'informació sobre la transformada de Fourier. Familiarització amb els conceptes i aplicacions en la visió per computador.

8) *Anàlisi i disseny del mètode basat en Fourier*

   Anàlisi i disseny del mètode d'extracció de descriptors de forma basat en la transformada de Fourier.

9) *Implementació del mètode de Fourier*

   Implementació i integració de l'anàlisi i disseny realitzats a l'etapa prèvia.

10) *Resultats de Fourier*

    Tal i com hem fet amb el mètode de Chang, avaluar els resultats del mètode amb imatges sintètiques, imatges amb objectes naturals i finalment amb imatges mamogràfiques.

11) *Anàlisi, disseny i implementació de la base de dades*

    Anàlitzar i fer el disseny de la base de dades per tal de poder enmagatzemar la informació obtinguda i posteriorment avaluar de forma més acurada el funcionament dels mètodes.

12) *Anàlisi i comparativa de resultats, amb imatges sintètiques, naturals i mamogràfiques*

    Realitzar proves dels mètodes utilitzant una aplicació CBIR i una aplicació de classificació. Fer un anàlisi de quins són els millors mètodes per avaluar cada tipus d'imatges. Avaluar les aplicacions de CBIR i classificació utilitzant els mètodes implementats.

13) *Acabar la documentació*

Octubre 2003

			1	2	3	4	5
	6	7	8	9	10	11	12
1	13	14	15	16	17	18	19
	20	21	22	23	24	25	26
	27	28	29	30	31		

Novembre 2003

						1	2
2	3	4	5	6	7	8	9
3	10	11	12	13	14	15	16
4	17	18	19	20	21	22	23
	24	25	26	27	28	29	30

Desembre 2003

5	1	2	3	4	5	6	7
	8	9	10	11	12	13	14
6	15	16	17	18	19	20	21
	22	23	~~24~~	~~25~~	~~26~~	27	28
	~~29~~	~~30~~	~~31~~				

Gener 2004

			~~1~~	~~2~~	3	4
	~~5~~	~~6~~	~~7~~	~~8~~	~~9~~	10	11
7	12	13	14	15	16	17	18
	19	20	21	22	23	24	25
	26	27	28	29	30	31	

Febrer 2004

							1
	2	3	4	5	6	7	8
8	9	10	11	12	13	14	15
	16	17	18	19	20	21	22
	23	24	25	26	27	28	29

Març 2004

9	1	2	3	4	5	6	7
	8	9	10	11	12	13	14
	15	16	17	18	19	20	21
	22	23	24	25	26	27	28
	29	30	31				

Abril 2004

10				1	2	3	4
	5	6	7	8	9	10	11
	12	13	14	15	16	17	18
11	19	20	21	22	23	24	25
	26	27	28	29	30		

Maig 2004

						1	2
12	3	4	5	6	7	8	9
	10	11	12	13	14	15	16
	17	18	19	20	21	22	23
13	24	25	26	27	28	29	30
	31						

Juny 2004

	1	2	3	4	5	6
7	8	9	10	11	12	13
14	15	16	17	18	19	20
21	22	23	24	25	26	27
28	29	30				

- Dies treballats
- Dies festius
- Examens de Nadal
- Entrega de la memòria

1.4 ORGANITZACIÓ DE LA MEMÒRIA

La memòria s'ha organitzat en 9 capítols que a continuació es detallen breument.

Al capítol 1 s'exposa la problemàtica del càncer de pit, es situa el marc del projecte i es mostra la planificació proposada. Al capítol 2 s'ensenya quins són els tipus de lesions més freqüents que han de tractar els metges, fent especial èmfasi en les masses, que és el tipus de lesió que centrerà el nostre PFC. També s'exposa quin és el procés que ha de patir una mamografia per tal de ser tractada amb el sistema que hem desenvolupat. El capítol 3 presenta una primera manera de caracterització de figures utilitzant els descriptors bàsics de forma. El capítol 4 mostra dues línies de treball a l'hora de caracteritzar figures. La primera línia ve descrita pel mètode de Chang que intentarà captar punts essencials de la imatge per tal d'obtenir una representació de la figura que ens sigui d'utilitat. I la segona línia es basa amb el domini freqüencial i presenta diferents variants en funció de quina sigui la informació que utilitzem per definir la figura. El capítol 5 és l'explicació de què són i com funcionen un sistema de classificació i de CBIR. Al capítol 6 es mostra el disseny entitat relació, el model relacional de la base de dades i l'esquema de l'aplicació. El capítol 7 es mostren els resultats obtinguts amb tres classes d'imatges i les conclusions que se'n dedueixen. Al capítol 8 s'hi exposen les conclusions que se n'extreuen i es proposen algunes tasques de treball futur. El capítol 9 és un capítol de referències.

La documentació també consta de dos annexes A i B que contenenn un manual d'usuari de l'aplicació respectivament i exemples de les imatges utilitzades per obtenir els resultats.

2 ENTORN DE TREBALL

2.1 INTRODUCCIÓ

Aquest capítol pretén situar al lector en l'etorn de treball del PFC, introduint breument les modalitats bàsiques en que s'estudien les mamografies, així com els tipus de lesions que han de tractar els radiòlegs. Finalment es detallarà quin és el tractament previ de les imatges mamogràfiques per tal de poder-ne estudiar posteriorment les seves característiques.

2.2 MODALITATS BÀSIQUES

Les mamografies es realitzen comprimint cada mama amb el mamògraf. Generalment es prenen dues vistes bàsiques de cada mama, tot i que posteriorment és possible que se'n requereixin de noves. Les projeccions bàsiques són les següents:

- **Cranio Caudal (CC)** → El tub de raig x es situa a 0º respecte l'eix vertical. Els raigs, travessen la mama de dalt a baix. A la Fig. 3.a es mostra el procediment d'obtenció de mamografies d'aquesta perspectiva i a la Fig. 3.b la mamografia obtinguda.

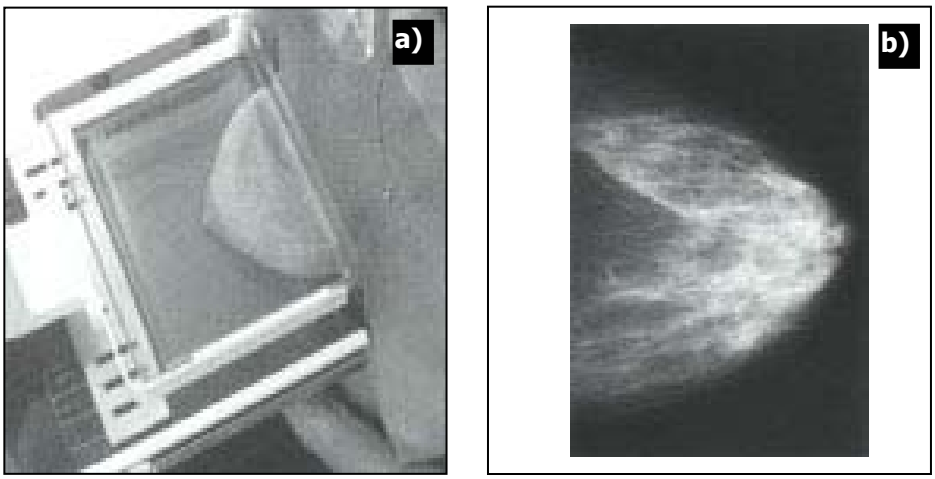

Fig. 3 – Cranio Caudal
a) Obtenició de la mamografia en la modalitat CC
b) Mamografia en la modalitat CC

- **Medio Lateral Obliqua (MLO)** -> El tub de raig x es situa a 45º otenint així tant informació pectoral com de la regió axil·lar. Mostra una quantitat més gran de teixit mamari i estructures més profundes del quadrant superior extern. La forma

de realitzar aquesta modalitat es mostra a la Fig. 4.a, i la mamografia resultant és la que es pot observar a la Fig. 4.b.

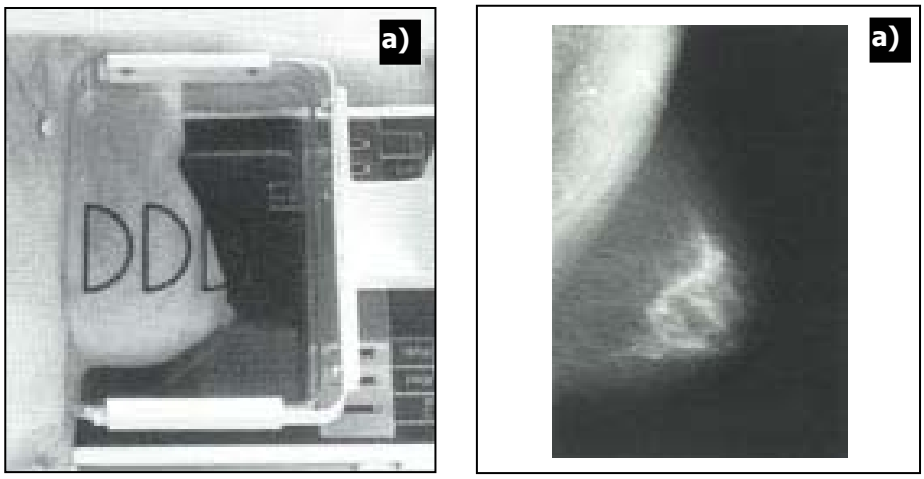

Fig. 4 – Medio Lateral Obliqua
a) Obtenició de la mamografia en la modalitat MLO
b) Mamografia en la modalitat MLO

Un cop obtingudes les dues vistes, el radiòleg estudiarà les radiografies. Les vistes anteriorment comentades, són complementàries les unes amb les altres, de manera que s'estudien conjuntament. Pot ser que es realitzi posteriorment una ecografia de la mama. Això serà útil al radiòleg per realitzar una valoració més acurada. L'ecografia és un mètode complementari, i és el radiòleg qui decideix si s'ha de realitzar o no.

2.3 TIPUS DE LESIONS

Donada una mamografia el tipus de lesions que hi podem trobar són les següents:

- Microcalcificacions: Són acumulacions de minerals dins el teixit del pit, tal i com es pot observar a la Fig. 5a. Es poden trobar com a dipòsits gruixuts de calç o en partícules minúscules de menys de 1/50 polzades. Aques tipus de lesió es presenta en la mamografia com a punts petits brillants.

- Masses: Són concentracions de teixit voluminós, que es veuen en dos o més projeccions diferents, (veure Fig. 5.b). Les masses es caracteritzen per tenir una estructura oval o lobulada.

- Lesions espiculars: Són com les masses, concentracions de teixit voluminós, però difereixen d'aquestes en la forma, on es caracteritzen per ser línies radiades des dels marges de la massa, donant així una forma estrellada, com es pot observar a la Fig. 5c.

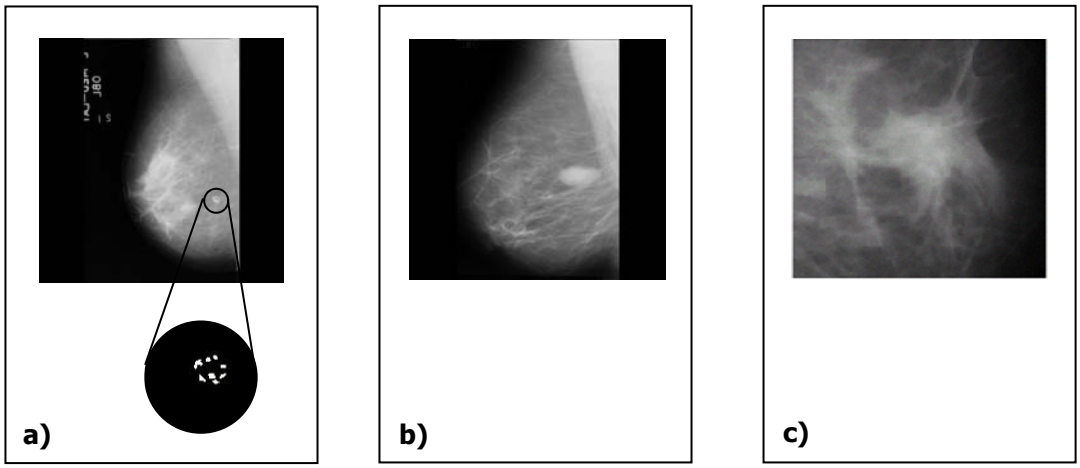

Fig. 5 – Tipus de lesions
a) Microcalcificacions b) Una massa c) Una lesió espicular

Entre els diferents criteris d'avaluació utilitzats pels radiòlegs, un dels més comuns es basa en realitzar comparatives entre la mamografia actual i les anteriors. Analitzen la imatge cercant els canvis que hi pugui haver hagut respecte les anteriors visites. En cas d'observar algun canvi, com pugui ser un augment del quist o la variació de la forma, es procedeixen a fer més mamografies des de diferents punts de vista per tal d'identificar amb més precisió el tipus de lesió. Així doncs, és evident que la forma i la mida de la lesió juguen un paper molt important pel radiòleg, essent-li de molta utilitat una eina que permeti recuperar casos ja diagnosticats que presentin lesions similars, sinó la mateixa, a la que s'està estudiant.

Depenent de la forma i la mida de la lesió, aquestes podran ser malignes o benignes. Tot seguit entrem a veure la importància que té la forma quan el metge preten diagnosticar el tipus de lesió que es pateix.

2.4 MASSES

El tipus de lesions que han estat objectiu d'estudi d'aquest PFC són les masses, i com a tal anem a detallar com la seva forma és reveladora de la seva nocivitat. Tant és així, que aproximadament entre el 80 i el 85% de càncers de pit són diagnosticats per l'aparença del

tumor a la mamografia [7]. Les principals característiques que s'utilitzen per diagnosticar la nocivitat d'un tumor són densitat, tamany, forma i contorns.

Pel que fa a les masses que es poden trobar en una mamografia, les que són d'origen maligne, sovint s'escampen pel voltant del teixit. Aquest fet provoca que el perfil consisteixi en fils fins extesos irregularment des del centre de la massa cap a fora. Aquest tret diferenciador de les masses malignes fa que poguem utilitzar la forma de la massa per discriminar entre masses malignes i masses benignes. Tot i així, cal deixar clar que la nostra intenció no és diagnosticar, sinó exclusivament utilitzar la forma per recuperar casos de la base de dades per tal que siguin de gran ajuda sobretot en mamografies poc clares. La Fig. 6 mostra la gama de masses que freqüentment es poden veure a les mamografies.

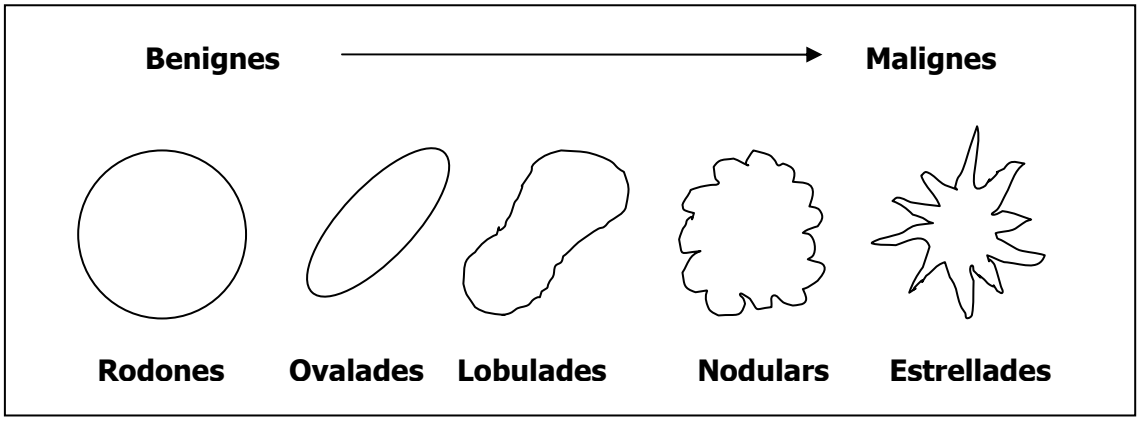

Fig. 6 – Esquema de les possibles masses presents a una mamografia, ordenades segones la seva benignitat

Evidenment l'aspecte que presenten les masses a les mamografies no sempre està tant ben definit com es voldria, per aquest motiu el procés de segmentació és un pas importantíssim. Perquè ens en fem una idea de la dificultat del procés de segmentació, a continuació podem veuren a les Fig. 5i Fig. 6 alguns exemples dels tipus de masses que es poden observar a les mamografies:

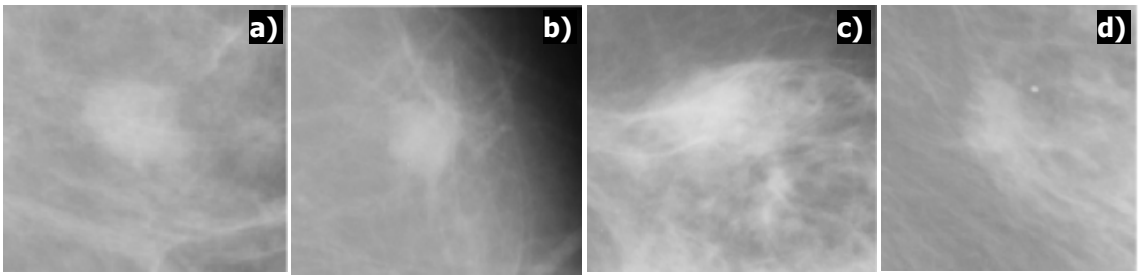

Fig. 7 – Masses reals
a-b) masses circumscrites c-d) masses ben definides

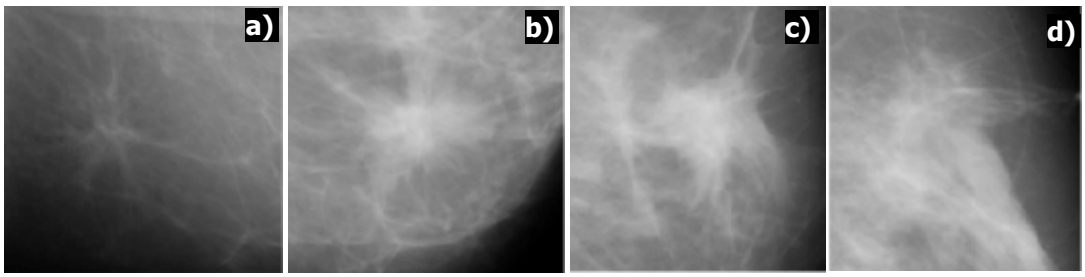

Fig. 8 – Lesions espiculars reals
a-b) lesions espiculades c-d) distorció arquitectural

2.5 SEGMENTACIÓ DE LESIONS

En aquest PFC ens hem centrat en estudiar, analitzar i implementar algorismes per tal de caracteritzar les lesions presents a una mamografia segons la seva forma. Si bé, abans d'aplicar els algorismes per extreure'n la informació que ens interessa, cal un procés previ de segmentació per tal de diferenciar clarament el que és la lesió de la resta de la imatge.
Amb la segmentació es preten extreure les regions d'interès de la imatge. Segons l'objectiu, això pot voler dir distingir totes les regions presents, (per intentar etiquetar-les), i separar l'objecte del fons. A continuació es presenten les passes a seguir en aquest procés, i algunes de les tècniques de segmentació més utilitzades per la segmentació de lesions.

2.5.1 Segmentació global

Una mamografia presenta etiquetes de les dades de la pacient així com marques que indiquen la modalitat i la mama de la que s'ha adquirit la imatge. Així doncs, prèviament a aplicar els algorismes específics per detectar les lesions cal aillar les regions de teixit mamari del que no ho és. Anomenem a aquest procés segmentació global.

La segmentació global d'una mamografia consisteix en separar la regió del pit i muscle de la resta de la imatge. En una mamografia hi podem trobar diferents regions:

- *Fons de la imatge*. És la part de la radiografia on la pel·lícula no ha estat exposada sobre l'objecte.
- *Zona del pit i muscle.* Trobarem el muscle en imatges MLO, i l'extraurem per dur a terme algorismes de segmentació de lesions, ja que és una zona que no ens interessa.

- *Etiquetes i marcs de la radiografia*. Donen informació sobre el contingut de la imatge.

  Per a separar la zona del pit de la resta de la imatge s'utilitzen algorismes basats en segmentació per histograma. Permetent obtenir resultats com els mostrat a les Fig. 9 i Fig. 10.

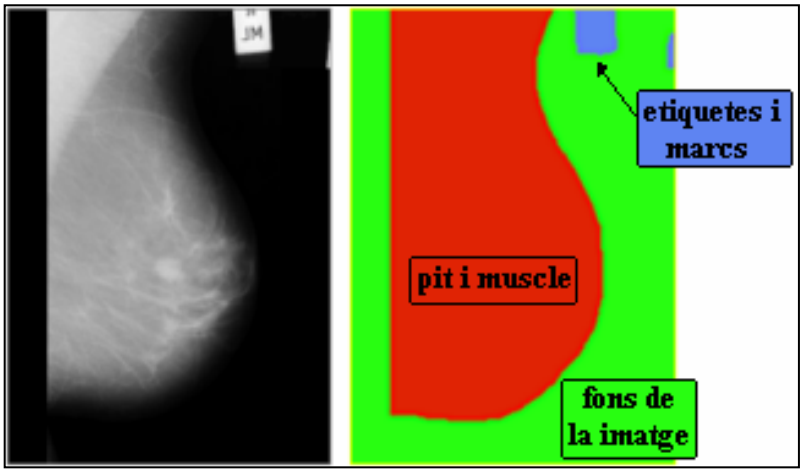

Fig. 9 – Diferents parts d'una mamografia: etiquetes i marcs, pit i muscle, fons de la imatge

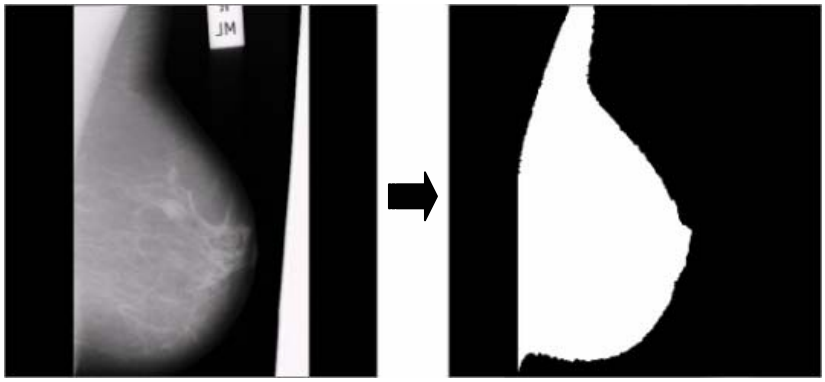

Fig. 10 – Mamografia desprès d'aplicar-hi l'algorisme de segmentació global

Si es vol obtenir més informació sobre aquest tema es pot consultar el PFC d'en Joan Espunya.

2.5.2 Segmentació de masses

Amb el pit ben definit després d'aplicar la segmentació global, podem utilitzar algorismes de creixement de regions a partir d'un punt llavor per tal de segmentar lesions. Per fer la segmentació de la lesió en concret, tenim dues polítiques a seguir. Una basa en la

segmentació per textura i l'altra en segmentar per intensitat. A HRIMAC s'hi han implementat una proposta de cada que tot seguit es detallaran [4]:

1. *Segmentació per textura:* aquest algorisme consisteix en un creixement de regions a partir d'una llavor i intenta agregar els píxels veïns sempre i quan tinguin una textura similar.
2. *Segmentació per intensitat:* mètode que segmenta les masses segons la intensitat dels píxels que les formen.

Amb algorismes de segmentació que acabem de comentar som capaços d'obtenir resultats com el mostrat a la Fig. 11.

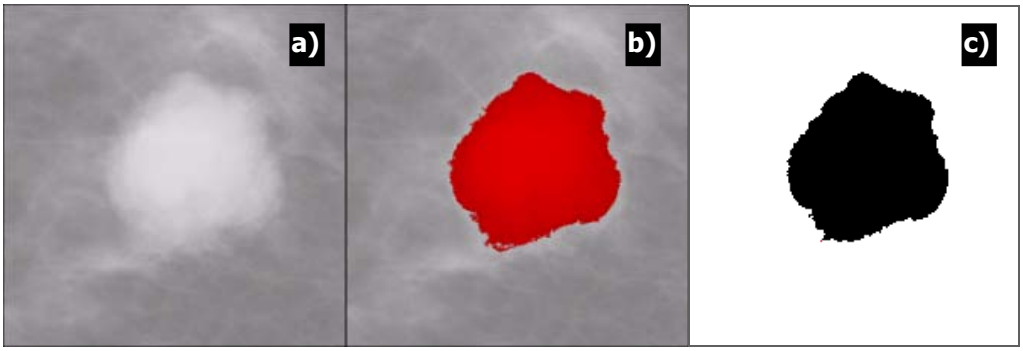

Fig. 11 – (a) Massa de la mamografia original (b) Segmentació d'una massa (c) binarització de la massa segmentada

Un cop separades les lesions de la resta de la mamografia, ja es pot passar a analitzar-ne la seva forma i textura. Els capítols següents descriuen detalladament els algorismes utilitzats per tal d'obtenir descriptors de forma bàsics i descriptors de forma basats en el contorn de l'objecte que s'està estudiant.

3 DESCRIPTORS BÀSICS DE FORMA

3.1 INTRODUCCIÓ

Donada una imatge els descriptors ens permetran obtenir informació per tal de caracteritzar la lesió o objecte que aquesta contingui. En altres paraules, ens permeten descriure la forma mitjançant un conjunt de valors numèrics, amb els quals podrem treballar. Els descriptors bàsics de forma són de gran interès pel fet que si els utilitzem com a complement dels descriptors avançats, permeten fer cerques més restrictives o d'un interès més específic per part del metge. A més a més, ocupen poc espai i són ràpids de calcular.

3.2 DESCRIPTORS BÀSICS

Tot seguit comentem quins han estat els descriptors bàsics que s'han tingut en compte.

Àrea:

És la propietat més simple i natural d'una regió. S'obté contant el nombre de píxels que formen part de la figura i ens diu, per tant , quin és el tamany d l'objecte.

Perímetre:

És la longitud del contorn d'una figura. Tenint present que les imatges són discretes pel fet d'estar formades per píxels, s'ha considerat que el perímetre estava format per la unió dels centres de cada píxel. Fent aquesta consideració i considerant connectivitat A8 ens trobem que la distància entre un píxel i el següent, no sempre val 1, tal i com podem veure a la Fig. 12.

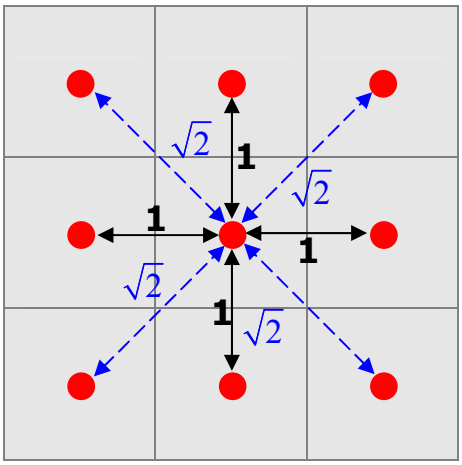

Fig. 12 – Distància entre píxels

Si haguéssim considerat connectivitat A4, tindríem que totes les distàncies entre píxels valdrien 1. Això és així perquè els únics veïns que pot tenir un píxel considerant connectivitat A4 són els quatre que s'indiquen a la Fig. 13.a en detriment dels 8 que presenta la connectivitat A8 tal i com mostra la Fig. 13.b.

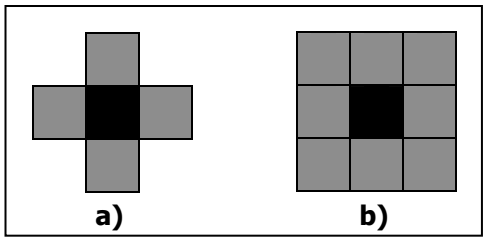

Fig. 13 – Connectivitats possibles
a) Veïns d'un píxel en connectivitat A4
b) Veïns d'un píxel en connectivitat A8

Les diferents connectivitats provoquen que les diagonals siguin vistes de manera diferent. Utilitzant connectivitat A4 les diagonals tenen 2 píxels de gruixària, encanvi amb A8 això no passa (veure Fig. 14).

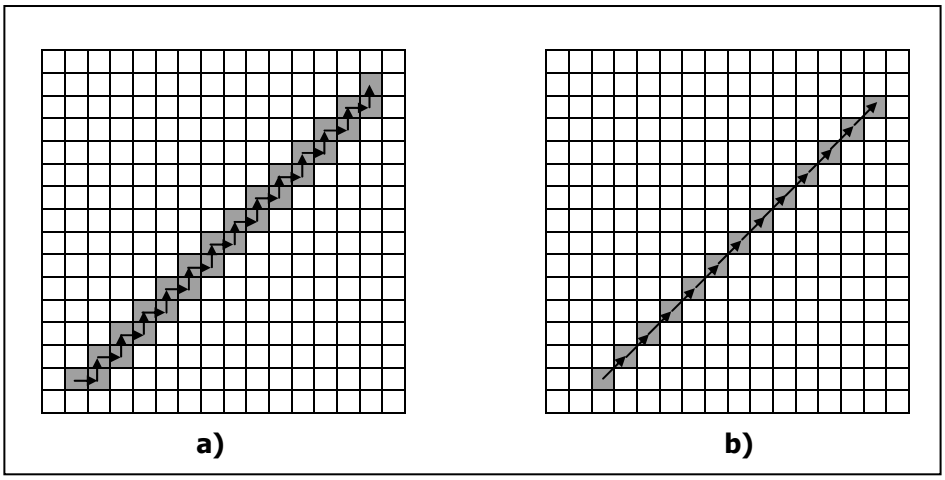

Fig. 14 – Representació d'una diagonal depenent de la connectivitat
a) Connectivitat A4 b) Connectivitat A8

Tant el perímetre com l'àrea poden servir per fer el control de com evoluciona el tamany d'una massa maligne.

Compactesa:

Aprofita els dos descriptros comentats (àrea i perímetre), per calcular-ne un de nou. La combinació de l'àrea i el perímetre ens aporta un valor que ens mesura la compactesa d'una lesió. Es defineix, com:

$$Compactesa = \frac{perímetre^2}{4 * \pi * area}$$ **Equació 3-1**

D'aquesta manera la figura amb menor compactesa és el cercle, i val 1. És una mesura que relaciona la superfície amb el perímetre. Ens trobarem que imatges amb poca àrea i molt de perímetre com poden ser lesions espiculars tindran una compactesa elevada. Aquesta mesura pot ser d'una manera directa, reveladora de la malignitat d'una lesió.

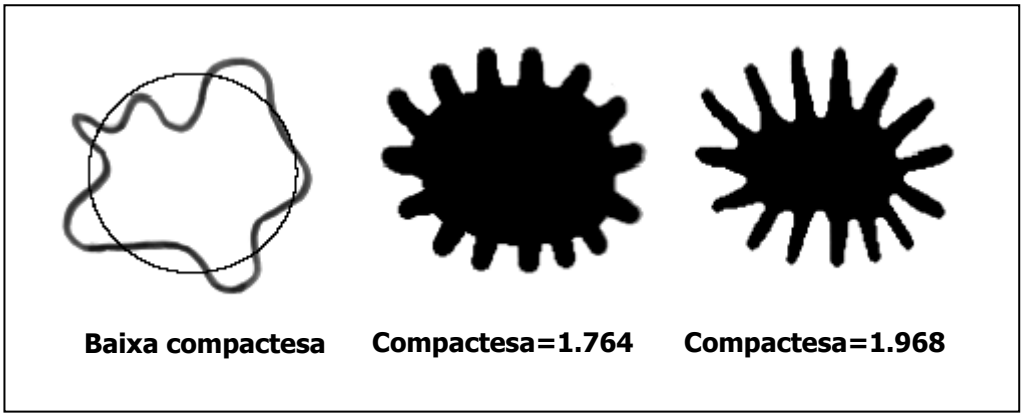

Fig. 15 – Exemples dels descriptor bàsic *Compactesa*

Rectangle Mínim Envolvent:

És el rectangle d'àrea més petita que inclou la figura sencera dins seu. Ve definit per quatre coordenades. Aquestes coordenades es calculen trobant la component mínima i màxima de l'eix Y i la component mínima i màxima de l'eix X. A la Fig. 16 se'n pot veure un exemple.

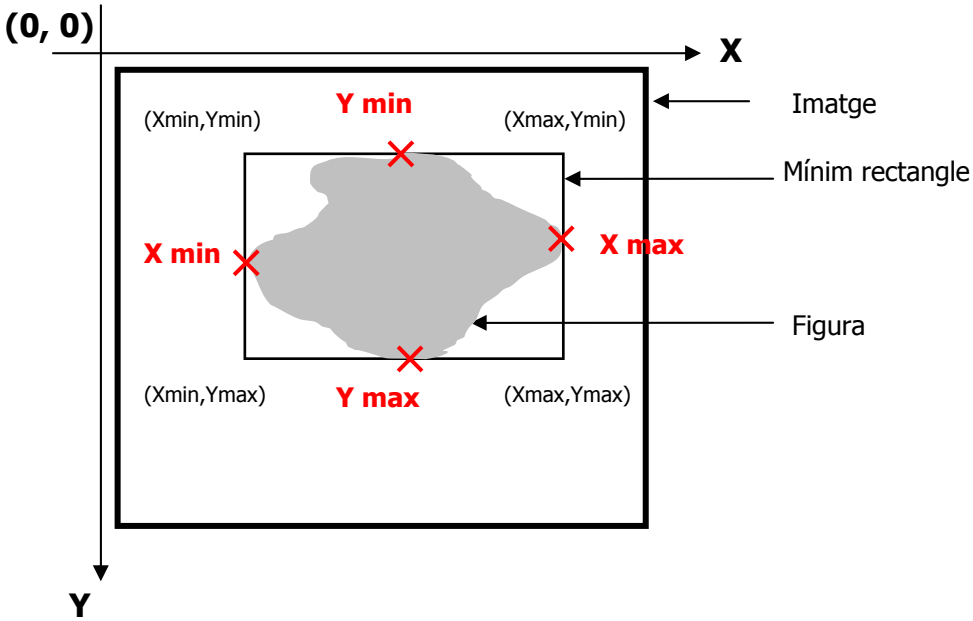

Fig. 16 – Exemple del rectangle mínim envolvent

Alçada:

Mesura la llargaria d'una lesió a partir del rectangle mínim. Es defineix com:

Alçada = Ymax – Ymin.

Amplada:

Mesura l'amplada d'una lesió a partir del rectangle mínim. Es defineix com:

Amplada = Xmax – Xmin.

Elongació:

És el quocient entre l'alçada i la amplada del rectangle mínim que conté una figura.

$$Elongació = \frac{Alçada}{Amplada}$$ **Equació 3-2**

Centre Gravetat:

És la coordenada del centre de masses de l'objecte. Es defineix com (Xc, Yc), on

$$Xc = \frac{1}{N}\sum_{t=0}^{N-1} x(t)$$ **Equació 3-3**

$$Yc = \frac{1}{N}\sum_{t=0}^{N-1} y(t)$$ **Equació 3-4**

essent N el nombre total de píxels de l'objecte i x(t) i y(t) la component X, i la component Y de cada píxel de l'objecte respectivament.

La informació que ens aporta ens permet situar la figura dins la imatge, ja que l'eix de coordenades agafat és el situat al píxel (0, 0) de la imatge. Una altra opció seria col·locar l'eix de coordenades a l'òs pectora de manera que la informació que n'obtindríem seria respecte el pit i no respecte la imatge.

3.3 RESULTATS I CONCLUSIONS

En aquest capítol s'han vist alguns mètodes per caracteritzar la forma dels objectes. Amb ells, es podrà saber el tamany (àrea), la posició, etc, de l'objecte. És difícil però, determinar amb exactitud quina és la forma exacte que s'està analitzant principalment per dues raons.

Podem tenir dos objectes amb diferent forma i en canvi tenir els descriptors bàsics iguals tal i com mostra la Fig. 17.

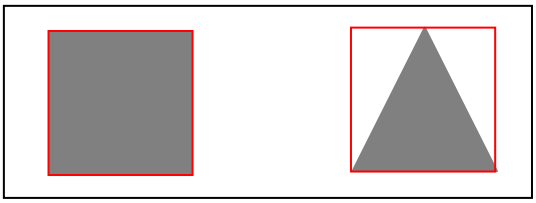

Fig. 17 – Dues figures diferents que presenten el mateix mínim rectangel envolvent

La figura Fig. 17 tot i presentar dues figures diferents, com que tenen el mateix mínim rectangle envolvent també presentaran exactament els mateixos descriptors bàsics que s'extreuen a partir d'ell iguals. Aquest fet provoca que els descriptors bàsics no ens permetin distingir entre les dues figures.
L'altre inconvenient és el fet que la majoria d'aquests descriptors donen valors diferents quan una mateixa figura es presenta amb diferent tamany o rotada. La figura mostra com una rotació ens varia pràcticament tots els descriptors bàsics excepte l'àrea i el perímetre.

La seva principal virtud és que són molt ràpids i que ens proporcionen una primera impressió de la figura que s'analitza. Aquesta primera impressió pot ser d'utilitat en cas de voler distingir entre figures molt i molt diferents o que essencialment es diferenciïn per alguna de les mesures que miren aquests descriptors.

4 DESCRIPTORS AVANÇATS DE FORMA

4.1 INTRODUCCIÓ

Els descriptors avançats de forma, com nosaltres els hem anomenat, tenen el propòsit d'obtenir una bona representació d'una figura. Una bona representació ha de permetre caracteritzar figures de manera que si dues figures tenen la mateixa forma, han de ser considerades iguals.

Per obtenir una representació que ens sigui d'utilitat, els descriptors avançats es basaran amb la informació del contorn. A partir de punts del contorn calcularem uns valors que anomenarem descriptors que ens caracteritzaran la figura. El que es pretén amb els descriptors és que el seu valor coincideixi per totes les figures que presentin la mateixa forma. D'aquesta manera l'objecte de la Fig. 18, ha de tenir els mateixos descriptors independenment del tamany, la posició o de si està rotada.

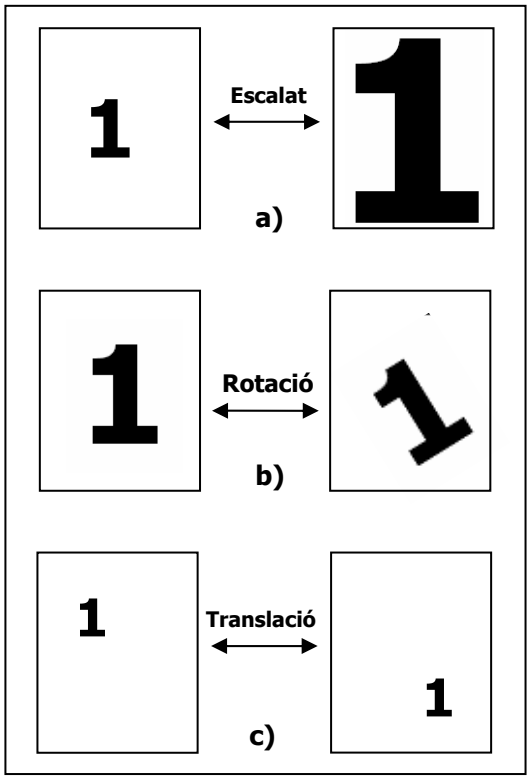

Fig. 18 – Diferents vistes d'un objecte
a) Objecte escalat b) Objecte rotat c) Objecte traslladat

Entre les diferents propostes, s'han considerat el mètode de Chang i el mètodes basats en Fourier:

- *Mètode de Chang*. Descriu la figura a partir de punts característics del contorn. Col·loquialment parlant, es busquen les cantonades de la figura per fer-ne una representació que ens sigui d'utilitat.
- *Mètodes de Fourier*. A la bibliografia hi trobem diferents propostes que es basen en la representació de figures mitjançant la representació espectral del contorn que s'obté coma resultat d'aplicar la transformada de Fourier. Nosaltres ens hem centrat en tres propostes.

4.2 MÈTODE DE CHANG

El mètode de Chang [10] utilitza exclusivament uns determinats punts del contorn de l'objecte per tal d'obtenir uns descriptors de forma, que anomenarem descriptors de Chang. Els descriptors que obtindrem amb aquest mètode compliran les invariances anteriorment comentades.

Primer s'obtindran els PMC del contorn, per fer-ho proposem dues opcions que a continuació presentarem. El nombre total de descriptors dependrà del total de PMC que trobem. A continuació caldrà que normalitzem aquestes mostres perquè només depenguin de la forma de la figura sense que importi res més. Per fer-ho primer canviarem el punt d'origen de la figura per posar-lo centrat just al centre de masses. D'aquesta manera aconseguim que les figures siguin invariants a la posició on es trobin dins la imatge. Tot seguit calcularem la distància entre els PMC i el centre de masses. Agafarem les distàncies que hem trobat i les dividirem totes per la distància més gran per tal de continuar amb el procés de normalització de resultats. Fent aquestes divisions aconseguim que els descriptors siguin invariants al tamany de la figura, ja que el rang dels nostres descriptors queda afitat entre 0 i 1. I finalment, perquè el fet que la imatge estigui rotada no ens afecti ordenarem els valors de més gran a més petit de manera que el primer descriptor sempre valdrà 1, per ser aquest el valor més gran possible per un descriptor que surt de dividir el descriptor més gran per ell mateix. Un esquema dels passos a seguir el podem veure a continuació:

1)

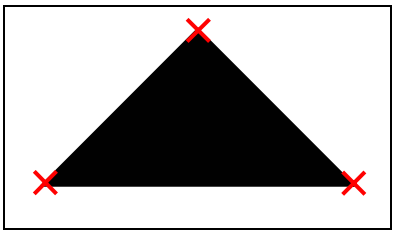

Calcular els punts de màxima curbatura

P=[(P1x, P1y), ... ,((Pnx, Pny))]

2)

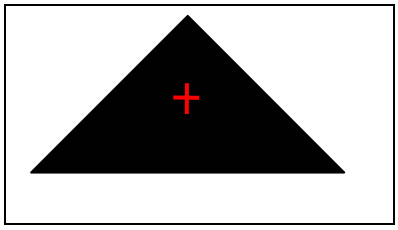

Calcular el centre de masses de la figura

C=(Cx, Cy)

3)

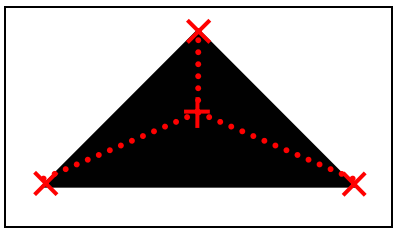

Valor absolut de les distàncies entre el centre i els PMC

D=[|D1|, |D2|, ... ,|Dn|]

4)

a)

Dmax = Valor màxim del conjunt D

$$D = \left[\frac{|D1|}{|D\max|}, \frac{|D2|}{|D\max|}, \ldots, \frac{|Dn|}{|D\max|} \right]$$

b)

Ordenar D amb sentit descendent

4.2.1 Punts de màxima corbatura (PMC)

El mètode de Chang utilitza els punts de màxima corbatura (PMC) per tal d'obtenir uns descriptors que identifiquin la figura. Per aquest motiu prèviament a la presentació del mètode, n'expliquem les bases per fer-lo més entenedor.

Els PMC són els punts del contorn als quals se'ls imposa que la seva recta tangent tingui una diferència de graus τ, respecte la recta tangent del píxel anterior.

Variant el valor del llindar τ el que fem és indicar quins punts seran considerats punts de màxima corbatura. Com més gran sigui τ més angulosa haurà de ser la figura per tal de trobar-hi punts. Encanvi si imposem un angle petit ens podem trobar que tot el contorn sigui considerat com a PMC. Essent τ el llindar imposat, β la diferència d'angle entre la

tangent del punt actual i el punt anterior, i p les coordenades del punt actual, podem definir els PMC com:

$$F(\tau, \beta, p) \begin{cases} (\beta > \tau) \rightarrow p \in PMC \\ (\beta \leq \tau) \rightarrow p \notin PMC \end{cases}$$ **Equació 4-1**

Com diu l'expressió es considerarà com a punt de màxima corbatura, qualsevol punt del contorn que tingui un angle β més gran que el llindar τ imposat.

A la Fig. 19 es presenta de manera visual el que signifiquen els punts de màxima corbatura. Per tal de fer-ho més entenedor se n'han ampliat les zones d'interès. La Fig. 19.b mostra com els punts d'un contorn proper a una línia recta tenen tangents molt similars i com a conseqüència un angle β petit. Encanvi a la Fig. 19.c es veu que l'angle β és més gran pel fet d'estar en una zona on el contorn presenta un canvi de direcció més pronunciat.

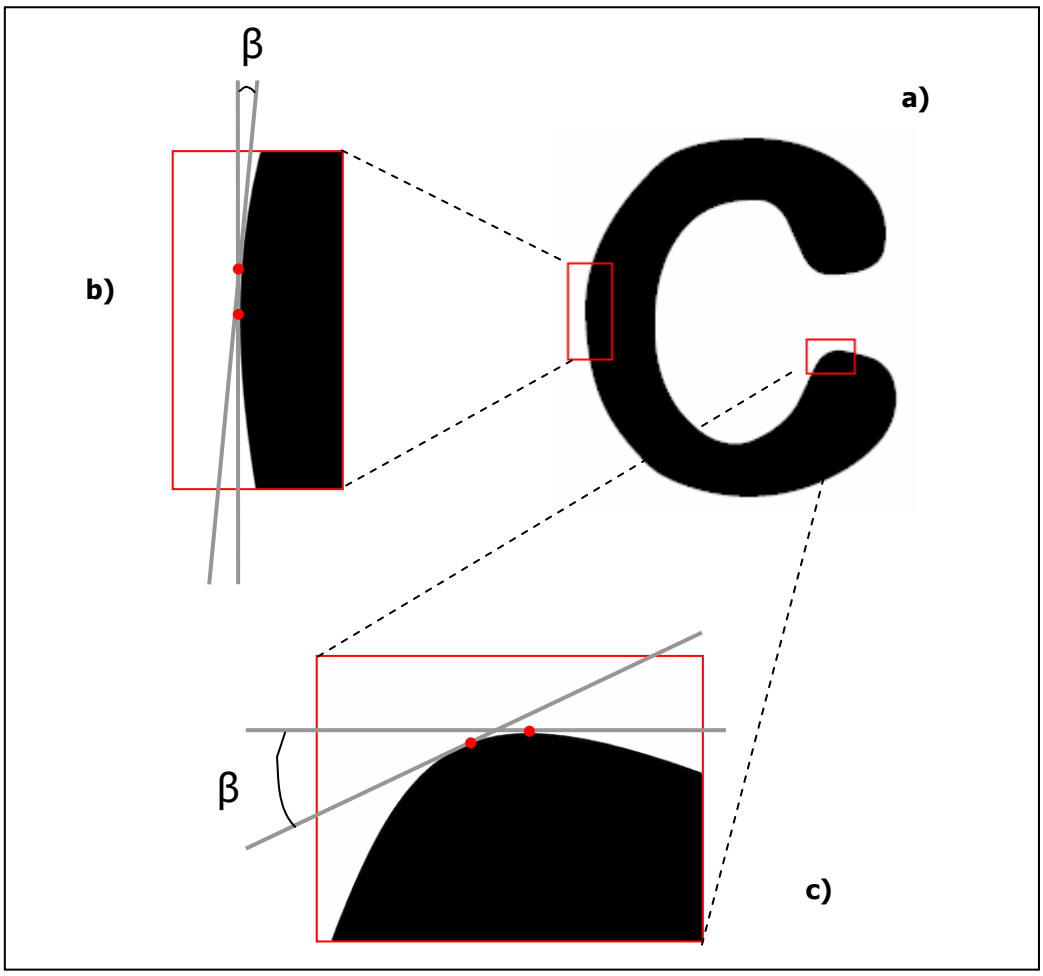

Fig. 19 – Angle β en funció del contorn.
a) Imatge tamany real b) Detall d'un punt amb un angle β petit
c) Detall d'un punt amb angle β gran

Per tal de trobar els PMC s'han implementat dos mètodes automàtics. Un es basa en aplicar un filtre de sobel per la imatge i el segon utilitza l'algorisme de Smith [15].

També es disposa de l'opció de fer-ho manualment, que tot i ser de poc interés a l'hora de reconèixer i classificar les imatges pel fet que implica la intervenció de l'usuari, pot ser d'utilitat en casos puntuals o bé per testejar-ne el funcionament.

4.2.1.1 Filtre de Sobel

Amb el filtre de Sobel pretenem trobar el contorn de la figura buscant els canvis d'intensitat que es produeixen en aquesta zona de la imatge.
És un filtre que analitza la variació d'inensitat a cada píxel, aquesta mesura es coneix amb el nom de gradient. Per calcular el gradient hem d'utilitzar les màscares de les Fig. 20 i Fig. 21. Cada màscara ens proporciona un valor per cada píxel de manera que acabem tenint les components del vector gradient. Amb la màscara de la Fig. 20, obtenim la component x que anomenarem Sx, i amb la de la Fig. 21 obtenim la component y que anomenarem Sy.
Per tal d'obtenir Sx i Sy en un píxel determinat cal centrar cada màscara al píxel en qüestió i calcular la suma dels valors extrets de multiplicar cada valor de la màscara per la intensitat del píxel corresponent a la imatge. Cal repetir la mateixa operació amb l'altra màscara.

Sx

-1	0	+1
-2	0	+2
-1	0	+1

Fig. 20 – Troba contorns verticals

Sy

+1	+2	+1
0	0	0
-1	-2	-1

Fig. 21 – Troba contorns horitzontals

Amb el gradient, a part d'obtenir el contorn, podem calcular els punts de màxima corbatura presents al perímetre. Per fer-ho s'utilitza la representació polar del vector, que consisteix en un mòdul (M) més un angle (ψ), tal i com es pot veure a la Fig. 22.

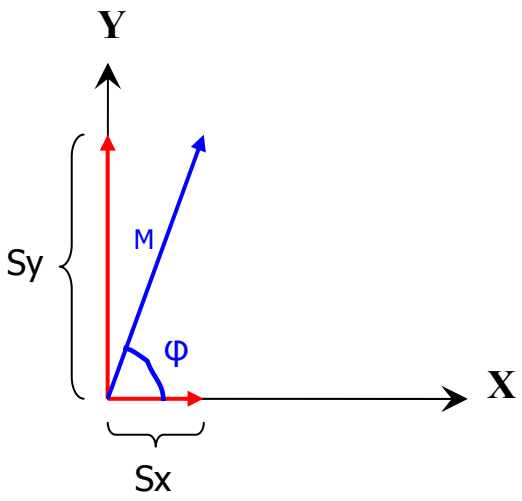

Fig. 22 – Amb blau la representació del mòdul M i l'angle φ
Amb vermell les components Sx i Sy

El mòdul (M) i l'angle (ψ) es calculen de la següent manera:

$$M = \sqrt{Sx^2 + Sy^2}$$ **Equació 4-2**

$$\psi = arctg\left(\frac{Sy}{Sx}\right)$$ **Equació 4-3**

D'aquesta manera el que tenim és un vector per cada píxel, on el mòdul indica com de brusca és el canvi d'intensitat i l'angle ens diu en quina direcció s'ha produit.

Si ara pensem el tipus d'imatges que tractem veurem per què ens va tant bé el filtre de Sobel. Les nostres imatges tenen únicament dos valors d'intensitat (blanc o negre), fet que farà que només s'observin canvis d'intensitat en els contorns de les imatges. Els canvis d'intensitat els apreciarem al mòdul, on qualsevol píxel que no formi part del contorn, tindrà mòdul 0. A la Fig. 23 es pot observar com el vector gradient de cada píxel coincideix amb la recta normal, perpendicular a la tangent del perímetre.

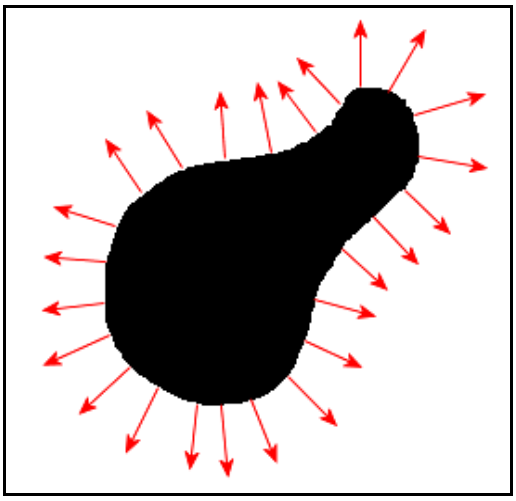

Fig. 23 – Representació d'alguns dels valors del gradient

Com que tenir el vector de la recta normal, és com tenir la tangent desfasada 90º, podrem trobar els PMC. Per fer-ho caldrà anar mirant els píxels del contorn seqüencialment i buscar l'angle β. Utilitzant la Equació 4-1 decidirem si un píxel és PMC.

L'inconvenient que presenta el filtre de Sobel és que tot i que ens troba contorns, aquests contorns no són de gruixària d'un píxel. Això és degut al fet que apareixen com a contorn, el píxel de la figura que està en contacte amb el fons, que és el que considerarem contorn, però també apareix com a contorn el píxel del fons que està en contacte amb la figura. Per salvar aquest problema hem considerat que només eren contorn, els píxels que eren trobats com a tal pel filtre de Sobel, però que a més a més eren pertanyents a la figura. Tot i així, si ens fixem atentament amb la Fig. 24, podem observar que hi ha zones que tenen dos píxels de gruixària.

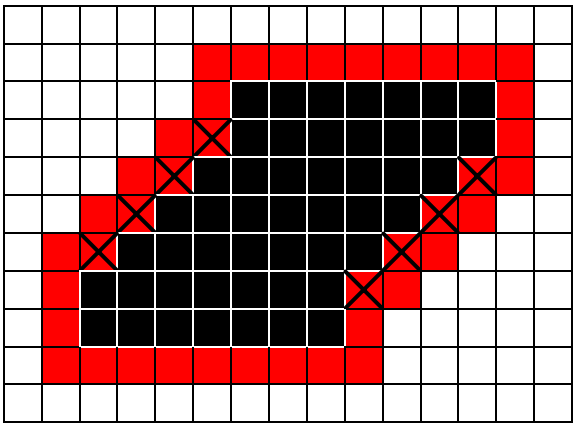

Fig. 24 – Amb vermell el contorn de Sobel. Amb una creu s'han marcat els píxels sobrants

El problema en qüestió, apareix a les diagonals, és com si tinguéssim un contorn amb connectivitat A4, fet que provoca que les línies diagonals tinguin dos píxels de gruixària. Per tal de tenir exclusivament un píxel a tot el perímetre de la figura i tenir rectes diagonals d'un sol píxel de gruix, hem passat el contorn a connectivitat A8 eliminant els píxels que sobraven. Un cop realitzat aquest últim pas ja tenim un contorn expressat en connectivitat A8.

4.2.1.2 Mètode de SUSAN

Per tal d'intentar millorar la detecció de PMC s'han buscat algorismes expressament pensats per aquesta tasca. Finalment, s'ha decidit adoptar l'algorisme SUSAN proposat per Smith [15]. El fet de decidir-nos per aquest mètode ha estat degut a què molts autors corroboren que obté millors resultats que d'altres algorismes àmpliament extesos amb la mateixa finalitat.

Aquest mètode es basa en la manipulació d'una màscara circular USAN (Univalue Segment Assimilating Nucleus), de 37 píxels, sobre cada píxel de la imatge.
A partir d'aquesta màscara podem definir l'àrea USAN com l'àrea formada per tots els píxels que estan dins la màscara i tenen una brillantesa similar o igual a la del píxel que es troba situat al centre de la màscara, conegut com el nucli. Com d'iguals ha de ser la brillantesa dels píxels per passar a formar part de l'àrea USAN, serà un paràmetre que s'haurà d'ajustar al tipus d'imatges que es tracti.
A la Fig. 25 es pot veure quines són dues de les àreas USAN trobades en una imatge binaritzada. Es pot observar que l'àrea USAN és mínima quan el nucli és proper a una cantonada, aquesta particularitat és utilitzada per detectar els corners, que nosaltres anomenem punts de màxima corbatura (PMC).

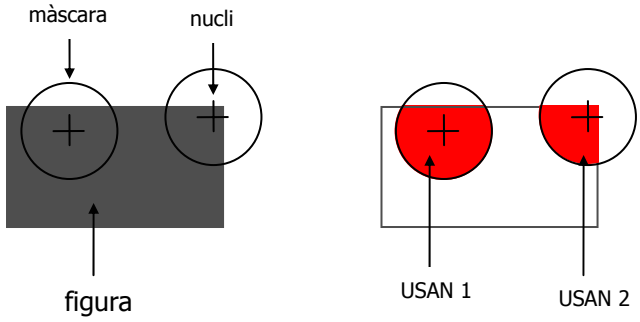

Fig. 25 – Representació de l'àrea USAN

L'algorisme té la particularitat de treballar amb sub-píxel accuracy, característica que és aprofitada per detectar falços punts de màxima corbatura.

4.2.2 Descriptors de Chang

Un cop definits els punts de màxima corbatura i explicades les diferents opcions per calcular-los, anem a detallar com el mètode calcula els descriptors de Chang [10] d'una figura qualsevol. Per fer-ho seguirem les següents passes:

1) Calcular els punts de màxima corbatura

Utilitzant qualsevol de les propostes proposades es calculen els PMC. És important que aquests siguin trobats correctament perquè sinó, per culpa de la representació que fa el mètode de Chang de la figura, ens trobem que una figura amb X punts i una altra amb X+1 punts no poden ser comparades de manera que es considera que són diferents. PMC' és el vector de punts de màxima corbatura que es defineix com:

$$PMC'=(PMC_1, PMC_2, \ldots PMC_N).$$

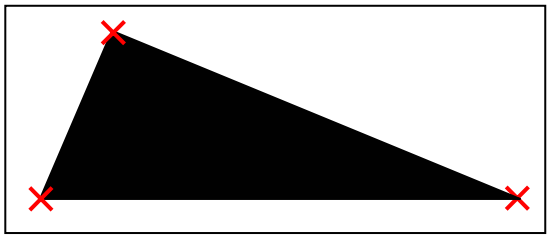

Fig. 26 – Punts de màxima corbatura

2) Extreure el centre de masses

Quan hem parlat dels descriptors bàsics al capítol 3, ja hem descrit com s'extreia aquest punt que anomenarem C. El centre de masses C ens servirà per fer que la figura no es vegi afectada per la posició on es trobi de la imatge.

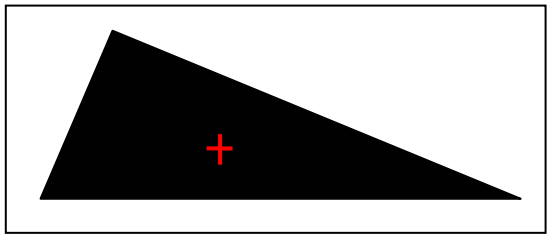

Fig. 27 – Centre de masses C

3) Obtenir distàncies DC= $|PMC_1|$, $|PMC_2|$, ... , $|PMC_N|$)

Es calculen les distàncies entre els PMC i el centre de masses de la figura . Aquestes distàncies són pràcticament els nostres descriptors de Chang, però encara tenen el problema que el seu valor és implícit al tamany de la imatge i de les rotacions.

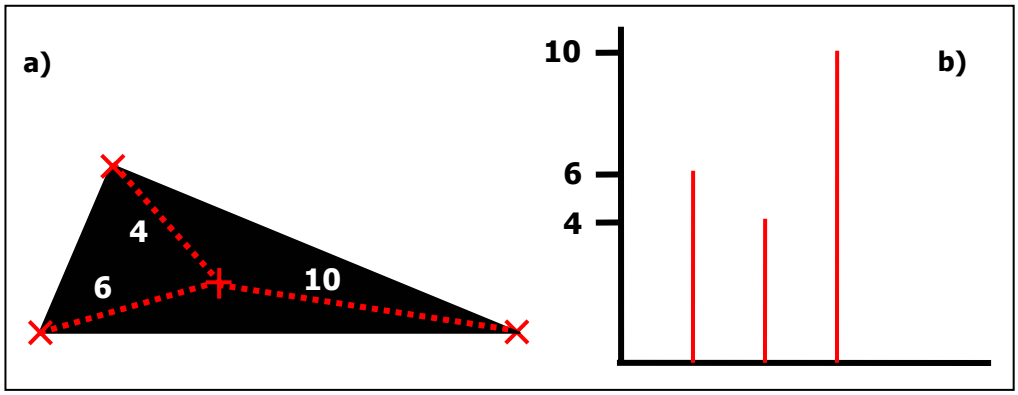

Fig. 28 – a) Distància entre el centre de masses i els PMC
b) Representació de les distàncies en forma de gràfica

4) Dividir per la distància més gran $DC' = \left[\frac{|PMC_1|}{\max(|PMC_x|)}, \frac{|PMC_2|}{\max(|PMC_x|)}, \ldots, \frac{|PMC_N|}{\max(|PMC_x|)} \right]$

Per tal que totes les figures siguin vistes igual tant si són grans com petites, dividim per la distància més gran, fent-ho així aconseguir que independentment del total de descriptors de Chang que tinguem, els valors d'aquests, estiguin situats entre 0 i 1.

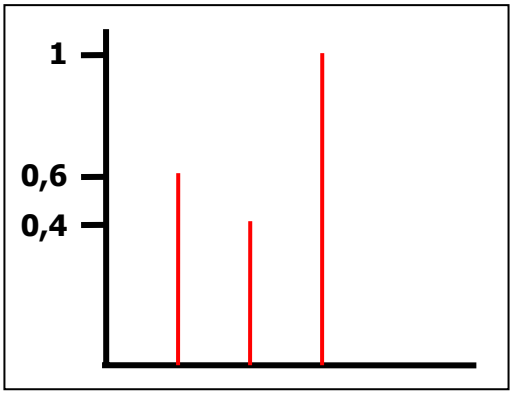

Fig. 29 – Distàncies normalitzades

5) Ordenar en sentit descendent els valors DC'

Un possible manera d'obtenir invariança a la rotació és prescindir de l'ordre amb què es trobaven els PMC a la figura. Un cop els hem extret i tractat per normalitzar-los els ordenem amb sentit descendent i d'aquesta maner obtenim els descriptors de Chang.

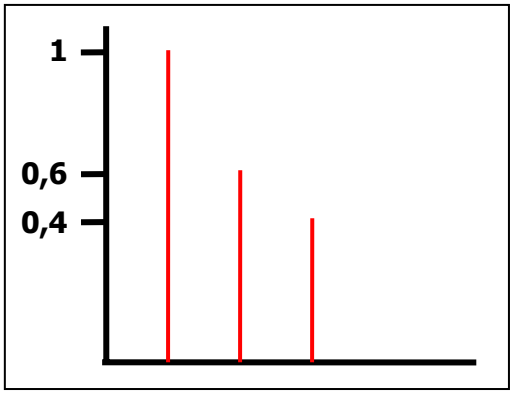

Fig. 30 – Distàncies ordenades

Amb els descriptors obtinguts, podem comparar i classificar imatges que tinguin el mateix número de PMC, en cas de no coincidir el nombre de PMC el mètode no pot dir res perquè considera que les imatges són diferents.

En el cas que el número de punts coincideixi és defineix la comparació mitjançant la distància euclidiana. La distància euclidiana d es defineix com:

$$d = \left(\sum_{i=0}^{N} \left| f_m^i - f_d^i \right|^2 \right)^{\frac{1}{2}}$$ **Equació 4-4**

Essent f_m i f_d dos conjunts de valors de Chang amb N valors cadascun.
D'aquesta manera com més petita sigui d més s'assemblaran dues figures.

Considerar que dues imatges amb diferent nombre de PMC no poden ser comparades és totalment lògic perquè pel fet de tenir un PMC més o menys podem passar de tenir un quadrat a tenir un triangle que evidenment no són iguals. D'altra banda, tot i sabent que els PMC no són sempre trobats correctament, no tenim manera possible de fer comparacions suposant que en realitat hi ha més PMC dels trobats.

4.2.3 Resultats i conclusions

El principal problema que té el mètode, el trobem quan es pretenen classificar figures amb formes més o menys arrodonides. En aquesta situació el nombre de PMC trobats és molt variable quan hem de tractar figures de formes arrodonides. Tot i que els descriptors de Chang són invariants, el procediment pel qual s'obtenen està fortament lligat a la disposició de la imatge quan els PMC no són clars. Aquest fet s'observa a les Fig. 31 Fig. 32.

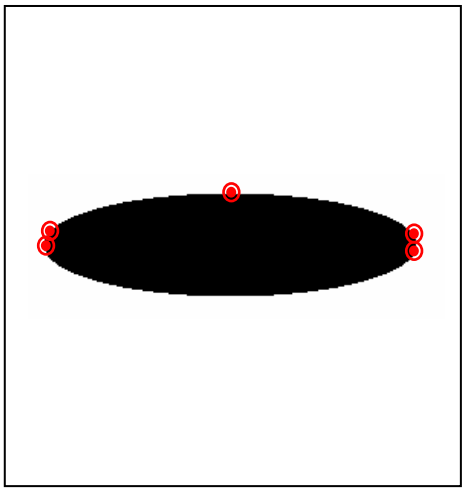

Fig. 31 – SUSAN troba 5 PMC en un el·lipse

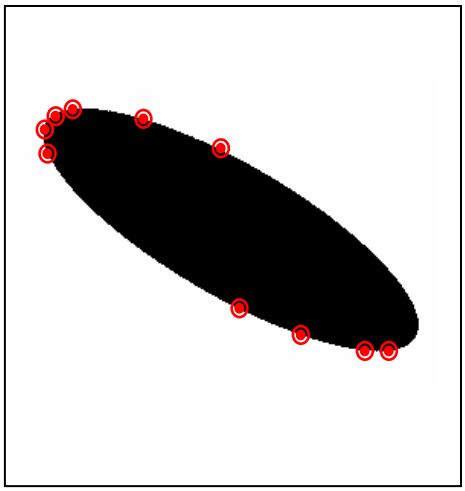

Fig. 32 – SUSAN troba 10 PMC en un el·lipse

El segon inconvenient és que només agafant els punts de màxima corbatura estem descartant informació de la imatge. Informació que ens pot ser d'utilitat per no confondre figures com les de la Fig. 33 i que segons els descriptors de Chang, són considerades igual. Això és degut al fet que se n'agafen el mateix nombre de punts i les distàncies respecte el centre de cada figura també coincideixen, donant com a resultat els mateixos descriptors de Chang [1, 1, 1, 1], per les dues imatges.

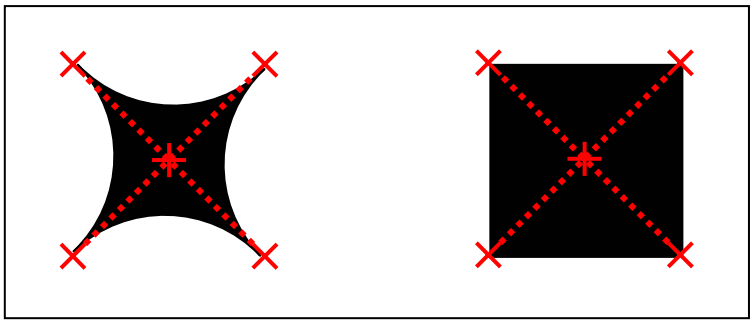

Fig. 33 – Figures diferents considerades iguals pel mètode de Chang

Les diferents proves realitzades han demostrat que és un bon mètode a l'hora de classificar figures sintètiques que no tinguin formes arrodonides. Però l'eficència del mètode cau estrepitosament quan es pretenen reconèixer o classificar figures que presenten parts més o menys arrodonides, ja que és fàcil que varii el nombre de PMC trobats.

Pot ser un mètode interessant d'utilitzar en entorns industrials per reconèixer peces i figures molt específiques. Però ni de bon tros es pot considerar un mètode d'àmbit general per classificar figures pels problemes que com ja hem vist presenta.

En referència a l'obtenció dels PMC s'ha pogut observar que SUSAN obté sempre millors resultats que no pas el filtre de Sobel. A les Fig. 25 i Fig. 35 es pot observar la millora que suposa l'algorisme SUSAN respecte el filtre de Sobel a l'hora de trobar punts de màxima corbatura en una imatge en concret.

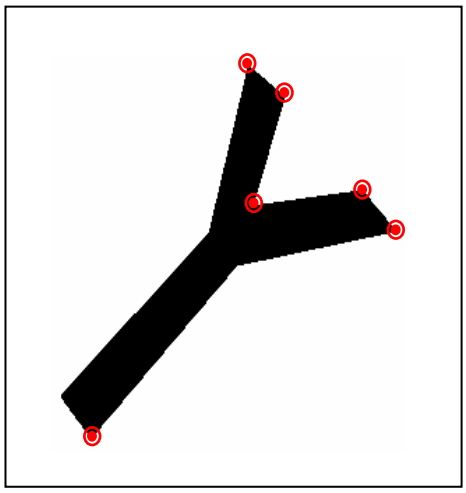

Fig. 34 – Amb sobel només trobem 6 PMC

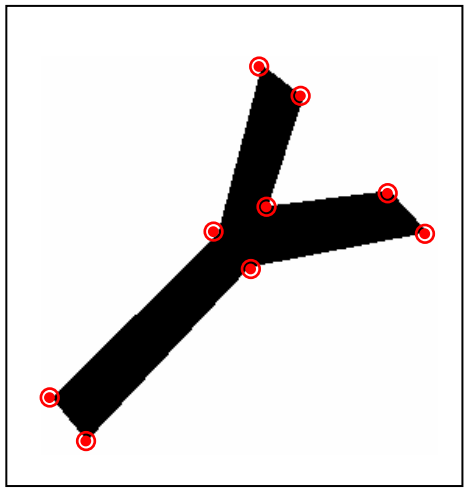

Fig. 35 – Amb SUSAN trobem els 9 PMC

El problema que té el filtre de Sobel és que utilitza una màscara molt petita per calcular el gradient. Aquest fet provoca que els PMC hagin de ser punts amb un canvi molt brusc en la direcció del contorn, de no ser així els punts són passats per alt. Per fer un símil al problema amb què ens trobem, podem entendre la imatge com el planeta terra, i les màscares que s'utilitzen com un ésser humà que habita al planeta terra. De la mateix manera que un home no s'adona del fet que la terra és rodona per la seva insignificància respecte el planeta; els valors del gradient han estat obtinguts amb una màscara tant petita, que la màscara tampoc és capaç de percebre la veritable forma del contorn. És massa petita en comparació la figura. Una possible solució per remediar-ho és utilitzar una màscara més gran que també ens serveixi per calcular el gradient.

4.3 MÈTODES DE FOURIER

Els descriptors de Fourier basen la seva representació en el domini freqüencial. En el nostre cas partim d'un senyal que és el contorn de la figura i el trobem representat a l'espai, o sigui en el domini espaial. El domini espaial té com a inconvenient principal la impossibilitat de poder comparar figures de manera directa perquè una simple rotació en fa impossible la comparació, pel simple fet que no se sap quins són el punts homòlegs a l'altra figura, com es veu a la Fig. 36.

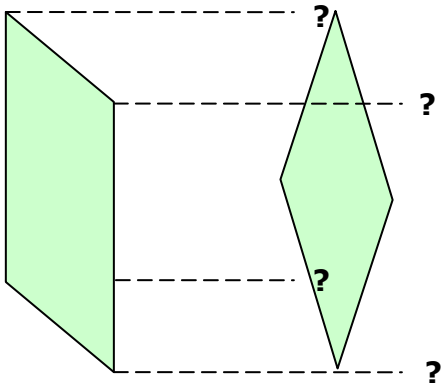

Fig. 36 – La rotació d'una mateixa figura no presenta correspondència de manera directa

Existeix un espai, el domini freqüencial, on és possible representar figures i fer que la comparació sigui una cosa directe. El que fa possible que la comparació resulti directe és la normalització que es pot aplicar als descriptors fent que una figura amb diferent tamany, i/o diferent rotació, i/o diferent posició, tinguin una mateixa representació.

L'esquema que tot seguit presentem ens mostra a grans trets com s'obtenen els descriptors de Fourier. Tot i que de moment és difícil que s'entengui, es pot observar com a partir d'una imatge s'acaben obtenint dos resultats. Això és degut al fet que depenent de la informació que utilitzem per representar la figura obtindrem uns descriptors o n'obtindrem uns altres.

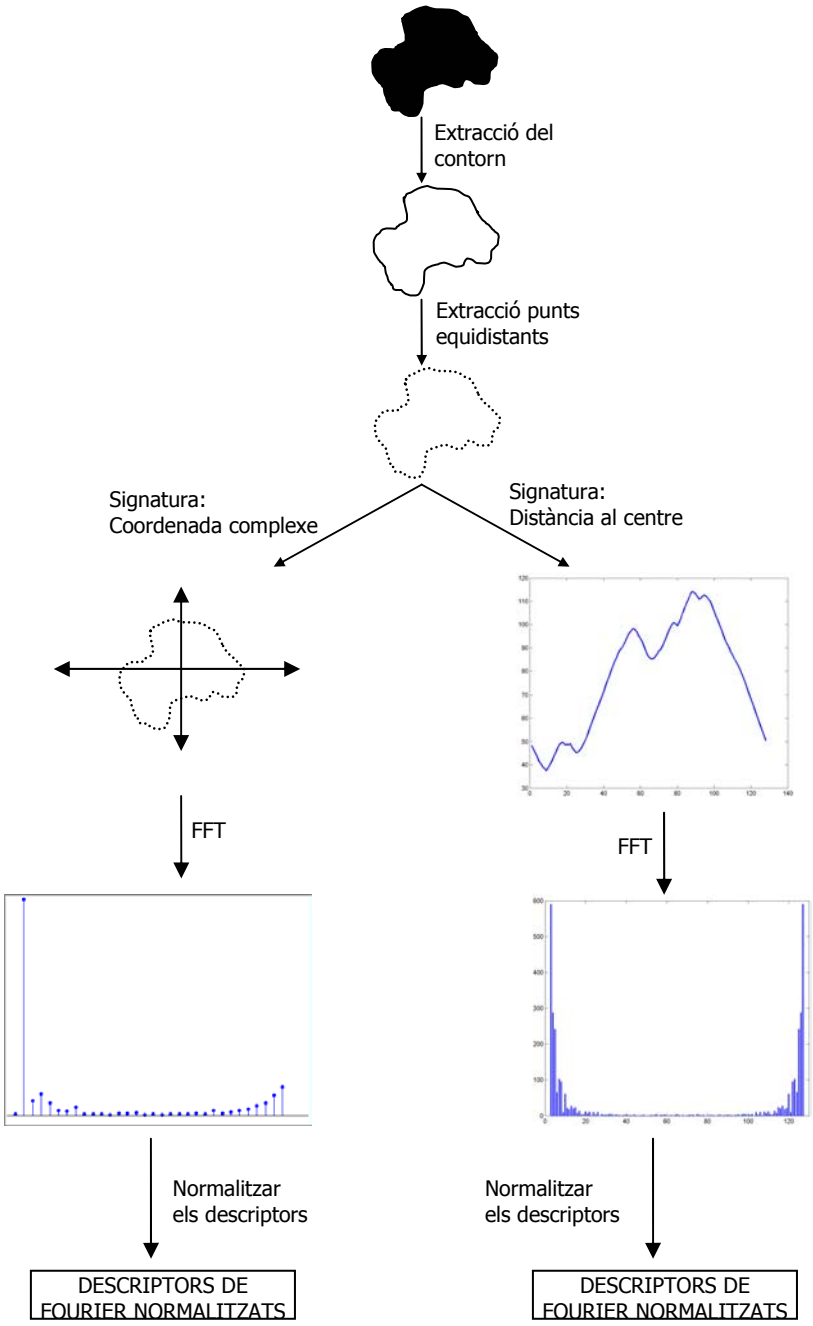

Fig. 37 – Procediment d'obtenció dels descriptors de Fourier

Tal i com es pot veure a la Fig. 37, els descriptors es poden aconseguir seguint una seqüència de passes. Tot seguit analitzarem cada pas i aprofundirem en els aspectes més teòrics sempre i quan sigui necessari per la comprensió del que s'està fent.

La primer etapa és molt important i consisteix en seleccionar quina és la informació que utilitzem per tal de representar la forma de la figura. Sembla evident que si agafem tots els punts del contorn podrem determinar la forma de la figura amb total exactitud. Ja s'ha vist com el mètode de Chang tenia el problema que per culpa de la poca informació que

utilitzava per representar el contorn, podia donar lloc a ambigüitats. Si en comptes d'agafar els punts del contorn que compleixen una condició, s'agafen tots, a l'hora de fer reconeixement, és provable que tinguem més bons resultats.

Així doncs, el primer pas que cal fer és, donada una imatge binaritzda, extreure'n el contorn.

4.3.1 Extracció de contorn

Partint de la idea que només tenim imatges bicolor (blanc i negre), on la part de la imatge que ens interessa és de color negre i el fons és blanc, es pot implementar un algorisme de cerca de contorns que busqui aquests canvis de color que es produeixen a aquesta zona. Per fer-ho, es fan dos recorreguts per la imatge, un d'horitzontal i un altre vertical, i es busquen les transicions de color. La unió de les imatges generades per aquests dos recorreguts dóna el perímetre de la figura.
En funció del canvi de color, de negre a blanc o de blanc a negre es pinta el píxel actual o l'anterior per tal d'obtenir com a contorn el perímetre pertanyent a la figura, i no pas els píxels dels fons que estan en contacte amb la figura. A la Fig. 38, es poden observar les imatges resultants de fer els dos recorreguts per la imatge, i com la unió de les dues ens proporciona exactament el contorn de la figura.

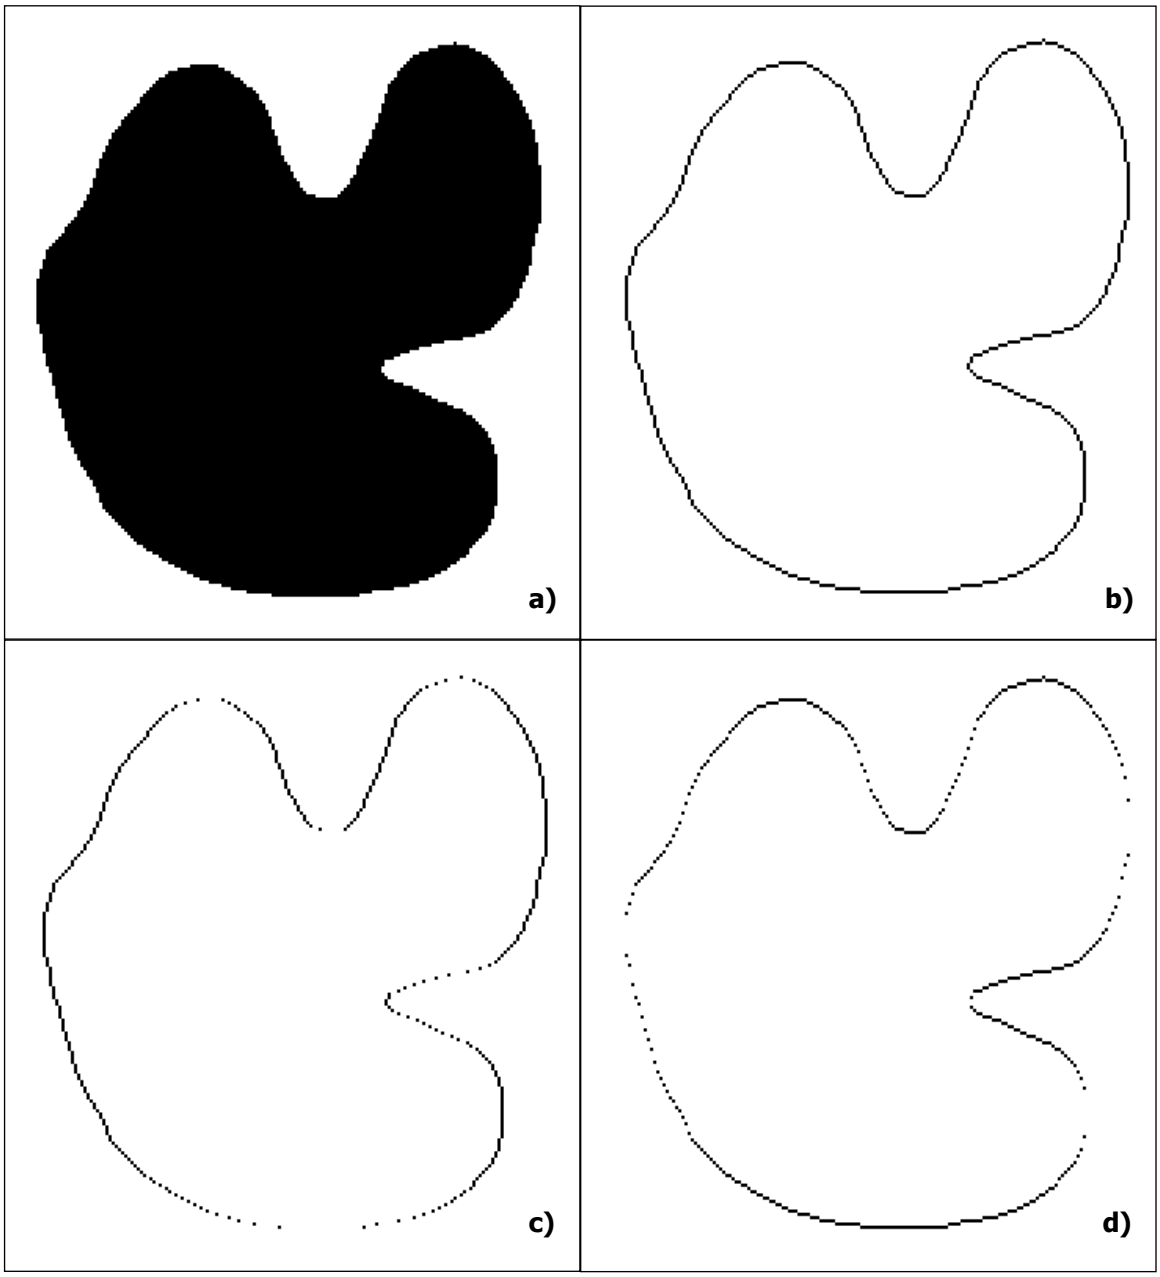

Fig. 38 – Procés d'obtenció del contorn
a) Imatge original, b) Imatge amb el contorn extret, c) Resultat d'aplicar el recorregut horitzontal, d) Resultat d'aplicar el recorregut vertical

Amb aquest procediment s'aconsegueix extreure el contorn, però com més endavant es veurà, per tal de treballar-hi, cal tenir els punts del contorn ordenats en sentit contrari a les agulles del rellotge.

Per tal d'obtenir els píxels en l'ordre desitjat s'implementa un algorisme, on el primer que cal fer és buscar el píxel del perímetre que té la component Y més petita, en cas d'haver-n'hi més d'un, s'escull el que també té la component X més petita. D'aquesta manera s'obté com a píxel de partida el que es troba més amunt i a l'esquerra de la figura. Sabent

aquesta informació podem utilitzar un algorisme que mirant de quin color són els píxels adjacents al que ens trobem, i imposant un ordre a l'hora de decidir quin és el píxel veí que s'afegeix a la llista del contorn, sigui capaç de recórrer la figura en el sentit que ens interessa.

L'algorisme fa una cerca pel contorn de la imatge fins tornar a trobar el píxel inicial, fet indicador que ja s'ha recorregut tot el contorn. En cas que l'algorisme es perdi perquè el contorn tenia "imperfeccions", s'aprofita la mateixa llista per recular i buscar un altre camí per tal d'arribar a trobar el píxel d'inici. A la Fig. 39 s'aprecia en groc els píxels que visita l'algorisme, però com que no pot continuar perquè el contorn no és en aquella direcció, recula fins trobar una altra ruta de manera que al final arribi al píxel inicial.

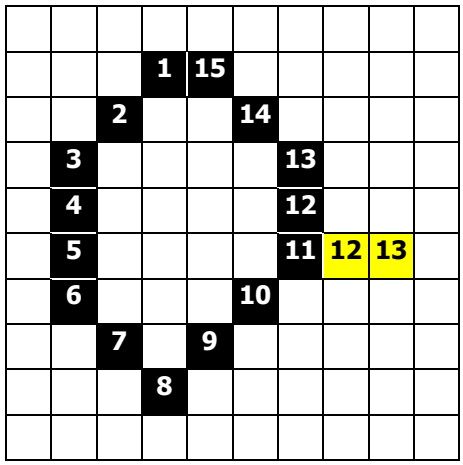

Fig. 39 – Fals contorn d'una figura

Extret el contorn tenim tots els punts en una llista, el següent pas consisteix en fer una representació adient d'aquest punts. La manera com expressem aquests punts ens donarà nom al mètode de Fourier.

4.3.2 Signatura de la Forma

La signatura es defineix com la manera utilitzada per fer la representació del contorn. Tot seguit presentem les signatures més habituals per expressar un contorn [13] [14]:

- Chord Length Signature

  Sense basar-se en un punt de referència, descriu els punts del contorn a partir de la distància **pp'**. Essent **p** el punt del contorn que volem representar i **p'** el punt perpendicular a la tangent de **p** que talla el contorn. En cas d'haver-hi més d'un punt d'intersecció **p'** es pot trobar com resoldre-ho a la referència [16].

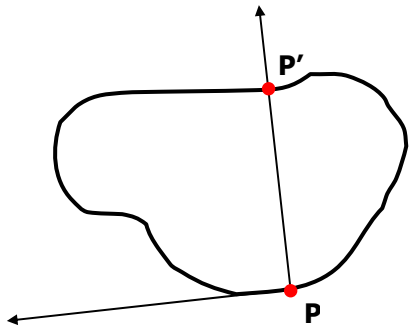

Fig. 40 – Representació de la recta pp' de la signatura Chord Length

- Cumulative Angular Function

  Per emmagatzemar la informació dels punts del contorn es guarda l'angle que descriu la recta tangent a cada punt al llarg del contorn.

Aquestes dues signatures explicades han estat descartades a l'hora de portar-les a la pràctica. El motiu que ha portat a prescindir d'aquestes representacions, ha estat bàsicament per eficiència i qualitat.

Les signatures escollides que a continuació es presenten, *coordenades complexes* i *distància al centre*, tenen la característica d'arxivar millor la informació. Amb aquest fet es vol dir que si per exemple per qüestions d'espai es decideix prescindir d'uns quants descriptors a l'hora de caracteritzar les imatges, cosa totalment plausible, els descriptors escollits mantenen una millor representació de la imatge que no pas els descartats [1]. Més endavant s'aclarirà aquest fet de la representació, però era convenient explicar en aquest punt els motius que van fer que no implementéssim les altres signatures.

4.3.2.1 Coordenades complexes

Aquesta signatura es basa en la representació de les coordenades de tots els punts del contorn. És indispensable que perquè els càlculs que es facin amb ells tinguin sentit, els punts del contorn han de ser extrets en sentit contrari a les agulles del rellotge tal i com mostra la Fig. 41.

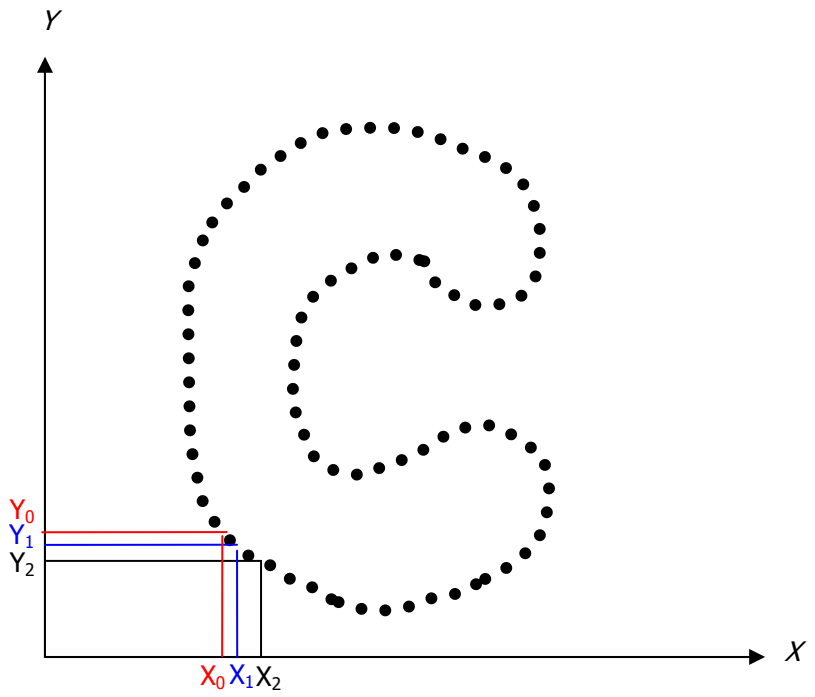

Fig. 41 – Punts del contorn agafats en sentit contrari a les agulles del rellotge

Partint d'un punt inicial arbitrari, s'obté la seqüència de coordenades que segueixen el contorn de la figura amb la restricció del sentit imposada:

$$\{(x_0, y_0), (x_1, y_1), \ldots, (x_{N-1}, y_{N-1})\}$$

Aquestes coordenades poden expressar-se de la forma $x(k)=x_k$ i $y(k)=y_k$, i a partir de cada parell de coordenades es pot construir un número complex amb la següent notació:

$$s(k) = x(k)+i\,y(k) \qquad \text{per } k=0, 1, 2, \ldots, N-1$$

Així, tractem l'eix X com l'eix real i l'eix Y com l'eix imaginari en la seqüència de números complexos; d'aquesta manera reduïm un problema de dos variables a un altre d'una sola variable.

Cal representar els punts respecte el centre de masses de la figura. Per fer-ho en fem prou restant a cada punt el centre de masses. Aquest pas és important perquè estem fent que la signatura sigui invariant a la translació de manera que no importi la posició on es trobi la figura dins la imatge.

Utilitzant aquesta signatura el nombre de valors que obtindrem al domini freqüencial, coincidirà amb el número de punts o de mostres del domini inicial. El fet que el total de valors coincideixi tant en un domini com en l'altre no vol pas dir que hi hagi una relació directe entre un punt de l'espai i un valor del domini freqüencial.

4.3.2.2 Distància amb el centre

Aquesta signatura és similar a l'anterior. També s'extreuen tots els píxels del contorn en sentit contrari al de les agulles del rellotge. La diferència rau en el fet que en comptes de guardar els dos valors, la component X i la component Y, en guardem el mòdul respecte el centre de masses (Cx, Cy), fent d'aquesta manera que la signatura sigui invariant a l'escalat:

$$\text{Mòdul} = \sqrt{(X - Cx)^2 + (Y - Cy)^2}$$ **Equació 4-5**

A la Fig. 42 es pot veure el perímetre d'un rectangle on s'hi ha indicat un eix de coordenades col·locat al centre de masses que és l'origen que servirà per representar els mòduls de la figura tal i com s'observa a la Fig. 43.

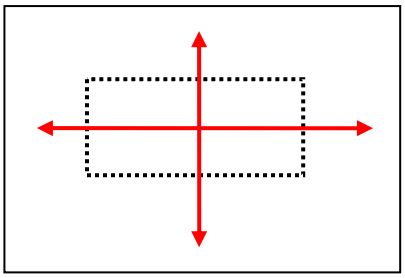

Fig. 42 – Perímetre d'un rectangle

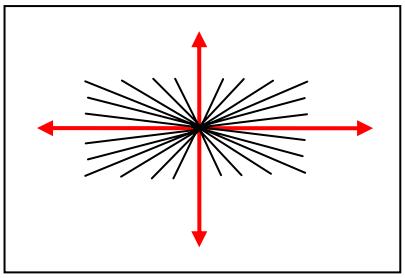

Fig. 43 – Mòduls de la Fig. 42 agafats com a signatura

Cal tenir present que un mòdul és un real i no pas un vector. No té sentit ni direcció. Amb aquesta aclaració pretenem fer notar que la figura original acaba essent descrita per un seguit de valors que no descriuen una corba tancada, sinó un seguit de distàncies. Si representem les distàncies gràficament s'obtenen resultats com el que mostrata la Fig. 44. On es pot veure com les distàncies ens dibuixen el contorn de la figura representat des del centre d'aquesta. Els quatre valors més alts de la figura representen les cantonades del rectangle. Això és així perquè és a les cantonades on la distància respecte el centre és major.

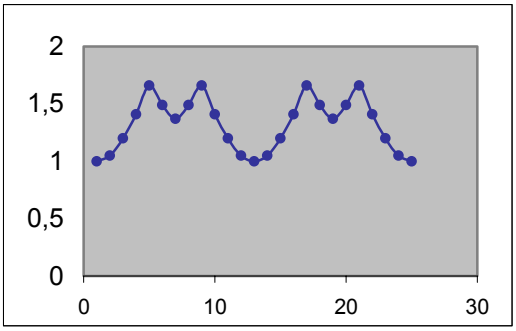

Fig. 44 – Representació de les distàncies respecte el centre pels punts escollits del contorn de la

Aquesta representació té l'inconvenient que ens podem trobar que dues imatges diferents tinguin la mateixa signatura [14]. A la Fig. 45 podem veure dues figures diferents que tenen la mateixa (veure Fig. 46). Evidenment aquest fet és un greu problema, però la gran majoria d'imatges de la natura no presenten les simetries que podrien donar peu a tenir dues imatges diferents amb la mateixa signatura. Podem considerar aquest problema com un fet anecdòtic.

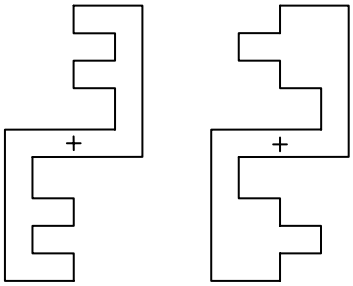

Fig. 45 – Contorn de dues imatges diferents

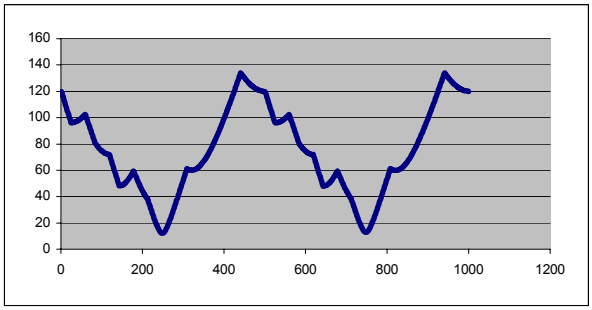

Fig. 46 – Representació de la distància respecte el centre de dues figures de la Fig. 45

D'altra banda, aquesta signatura té l'avantatge que quan passem la signatura al domini freqüencial, no caldrà que guardem tots els valors perquè amb la meitat en farem prou. Això és així perquè trobarem una simetria parell que farà que amb la meitat de valors guardem tota la informació interessant. Les avantatges que això suposa, són evidents, tant a nivell d'espai com en temps de càlcul a l'hora de buscar figures. A l'hora de fer cerques, aquesta representació freqüencial de la signatura ens permetrà dir si dues figures s'assemblen fent la meitat de comparacions.

Tot i l'avantatge d'espai i d'eficiència que aquesta signatura suposa, no serà fins que no fem resultats que no veurem si realment aquesta signatura ens és d'utilitat pel reconeixement de figures.

4.3.3 La Transformada de Fourier

La transformada de Fourier és l'operació que ens permet passar del domini temporal o espaial en el nostre cas, al domini freqüencial. Mitjançant l'antitransformada de Fourier, podem tornar al domini inicial.

La contribució de Fourier va ser dir que qualsevol funció periòdica podia ser expressada com la suma de sinus i/o cosinus de diferents freqüències, cada una multiplicada per un coeficient diferent. Avui en dia coneixem aquesta sèrie amb el nom de la Sèrie de Fourier.

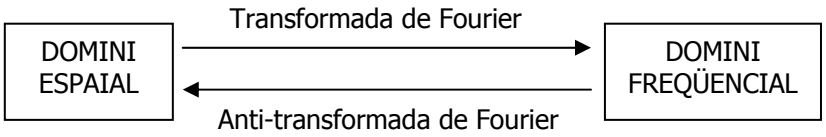

La *Transformada de Fourier* es defineix com:

$$F(w) = \int_{-\infty}^{\infty} f(x) \cdot e^{-i2\pi wx} dx \qquad \textbf{Equació 4-6}$$

On f(x) és la funció que volem representar freqüencialment. I F(w) és la funció resultant.

L'antitransformada de Fourier es defineix com:

$$f(x) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} F(w) \cdot e^{jw.x} dw \qquad \textbf{Equació 4-7}$$

On F(w) és una funció descrita al domini freqüencial.

Representant la transformada de Fourier en forma d'exponencial tenim:

$$F(w) = |F(w)| e^{i\Phi(w)} \qquad \textbf{Equació 4-8}$$

On

$$|F(w)| = \sqrt{R^2(w) + I^2(w)} \qquad \textbf{Equació 4-10}$$

$$\Phi(w) = -arctg\left(\frac{I(w)}{R(w)}\right) \qquad \textbf{Equació 4-9}$$

essent R(w) la part real i I(w) la part imaginària. Independenment de quina sigui la funció original, F(w) sol ser una funció complexe.

La funció |F(w)| s'anomena espectre de Fourier i $\Phi(w)$ és el seu angle de fase. La variable w se l'anomena variable de freqüència.

4.3.4 Transformada Discreta de Fourier (TFD)

La transformada de Fourier és d'utilitat en el cas que es tinguin funcions en el domini real. Aquest no és el nostre cas, i per tant no podrem treballar directament amb la transformada de Fourier.

La nostra funció d'entrada seran les diferents signatures que hem comentat (coordenada complexe i distància respecte el centre), que són discretes, pel fet d'estar formades per una llista finita de punts. Per tal de poder aplicar la transformada de Fourier i aprofitar les propietats del domini freqüencial haurem de treballar amb la transformada discreta de Fourier (TDF).

Per tal que les operacions amb la transformada tinguin sentit cal que les mostres obtingudes hagin estat preses en sentit contrari a les agulles del rellotge. Per aquest motiu a cada signatura s'especificava que calia que les mostres fossin extretes en aquesta direcció. I l'altre requisit que cal complir per poder aplicar la TDF, és que la seqüència {s(0), s(1), s(2),...,s(N-1)} essent N el total de mostres, contingui les mostres uniformement repartides o sigui equiespaiades.

Imposant aquestes dues premises a la funció inicial, podem definir el parell discret de transformades de Fourier com:

$$a(u) = \frac{1}{N}\sum_{n=0}^{N-1} s(k) e^{-j\frac{2\Pi uk}{N}}$$ per u=0, 1, 2,..., N-1 **Equació 4-11**

$$s(k) = \sum_{k=0}^{N-1} a(u) e^{j\frac{2\Pi nk}{N}}$$ per u=0, 1, 2,..., N-1 **Equació 4-12**

On a(u) és la funció resultant d'aplicar la Transformada Discreta de Fourier, essent s(k) la signatura de l'objecte que volem representar.
Els diferents valors de a(u) es coneixen amb el nom de coeficients de Fourier. Com es pot entendre, no només existeixen un valors possibles com a coeficents de Fourier, sinó que

tindrem tantes variants de descriptors de Fourier com signatures vàlides existeixin per representar un contorn.
La definició de l'espectre de Fourier continua essent vàlida quan parlem de la transformada discreta. La diferència rau en el fet que com també passa amb la signatura, serà una funció discreta.

Un anàlisis de l'algorisme de la TDF permet comprovar que calen N multiplicacions complexes i N sumes per cada una de les ratlles espectrals que permetin la representació en el domini de la freqüència, essent N el número de mostres. Com que hi ha N/2 components diferents, contant únicament les freqüències positives de l'espectre, el número total de multiplicacions és N^2.
Un algorisme d'ordre quadràtic és molt costós i per remediar-ho s'utilitza la transformada ràpida de Fourier (FFT). És un algorisme que aprofitant la simetria, la periodicitat de la sèrie i un procés de decimalització aconsegueix reduir el càlcul a $N \log_2 N$. Això vol dir que per 8 mostres la FFT realitza 24 productes complexes, mentres que la TDF en realitza 64.

Nosaltres a l'hora de realitzar la transformada discreta de Fourier hem implementat tant la TDF com la FFT, però per la rapidesa i pels millors resultats que dóna en qüestió de decimals s'ha optat per utilitzar exclusivament la FFT.

L'algorisme de la FFT té la petita restricció que per poder aprofitar les seves virtuds cal que el nombre de mostres sigui una potència de 2.

Com ja s'ha comentat cal que les mostres hagin estat preses de manera equidistant. Si agaféssim la signatura resultant de cada píxel del contorn ens trobaríem que les mostres no són equidistants respecte a res. El proper apartat aclareix quin tipus d'equidistància podem buscar i quina ens serà de més utilitat.

4.3.5 Equidistància

Una de les premises per tal de poder aplicar la transformada discreta de Fourier és que les mostres, o sigui els punts que es convertiran amb la signatura, siguin equiespaiades.

Assumint que K és el nombre de mostres, per tal de fer que les mostres siguin equiespaiades tenim tres opcions:

- Agafar les mostres equiespaiades un angle $\Theta = 2\pi / K$.

- Agafar les mostres equidistants al llarg del contorn. De manera que si el perímetre medeix L píxels s'agafen mostres cada L/K píxels.
- La tercera opció és similar a l'anterior però es té en compte el fet que el valor del perímetre és un real i les mostres escollides poden caure en mig de dos píxels (sub-píxel accuracy). A més a més, com ja hem comentat al capítol 3 quan hem parlat de l'extracció del perímetre, la distància entre píxels no és sempre igual. Aquesta consideració fa que agafant com a mostra el propi píxel estiguem agafant mostres que no són equidistants.

Una vegada més s'ha primat la qualitat i fent cas a la bibliografia [13] hem optat per l'opció que millors resultats dóna que és la tercera.

Un cop decidit que es vol equidistància respecte el perímetre, cal trobar la manera que una llista finita de punts no equiespaiats com són els píxels del perímetre, ens permeti que la convertim en una llista de punts equiespaiats. Per fer-ho hem optat per utilitzar tècniques d'interpolació. Per la senzillesa, l'eficiència i la proximitat entre píxels, s'ha considerat que un mètode d'interpolació per segments lineals estaria més que bé.

4.3.5.1 Interpolació per segments

Un cop es tenen tots els punts del contorn per tal de fer complir la condició d'equidistància respecte el contorn, s'ha buscat la manera d'aconseguir mostres entre píxels (sub-píxel accuracy) per tal d'obtenir mostres equiespaiades. Per fer-ho s'ha optat per fer interpolació per segments, també coneguda com interpolació per splines lineals.
Amb la interpolació amb splines lineals, es considera que les mostres estan unides per rectes. Tot seguit comentem com hem dissenyat l'algorisme que ens extreu les mostres.

Vam partir de la idea de què si el perímetre fos tot una recta i en volguéssim obtenir mostres equiespaiades, només hauríem d'indicar la distància o pas que hi ha d'haver entre cada mostra i anar agafant una mostra cada vegada que avancéssim un pas. La seva senzillesa rau en el fet de treballar només en una dimensió.
Si hem de treballar en el pla tenim dues dimensions, però podem fer la representació polar de cada píxel representant-lo respecte el píxel anterior Fig. 47. Amb un representació com la proposada aconseguim que es simplifiqui la feina de buscar mostres equiespaiades.

L'algorisme que fa possible que es puguin obtenir més mostres del contorn que no pas píxels tenim, treballa de la següent manera:

1. Obtenció de les coordenades de cada punt del contorn en forma cartesiana.
2. Buscar el pas al qual s'han de prendre les mostres, pas=perímetre / nº de mostres.
3. Expressar cada píxel respecte el seu predecessor és com tenir una línia que els uneix (mòdul). D'aquesta manera tenim una direcció i un sentit per recórrer la figura. L'altra avantatge que tenim és que el pas que hi ha d'haver entre mostres pot ser contat a sobre del mòdul de cada vector.
4. L'últim pas a realitzar és representar cada punt obtingut respecte el mateix origen.

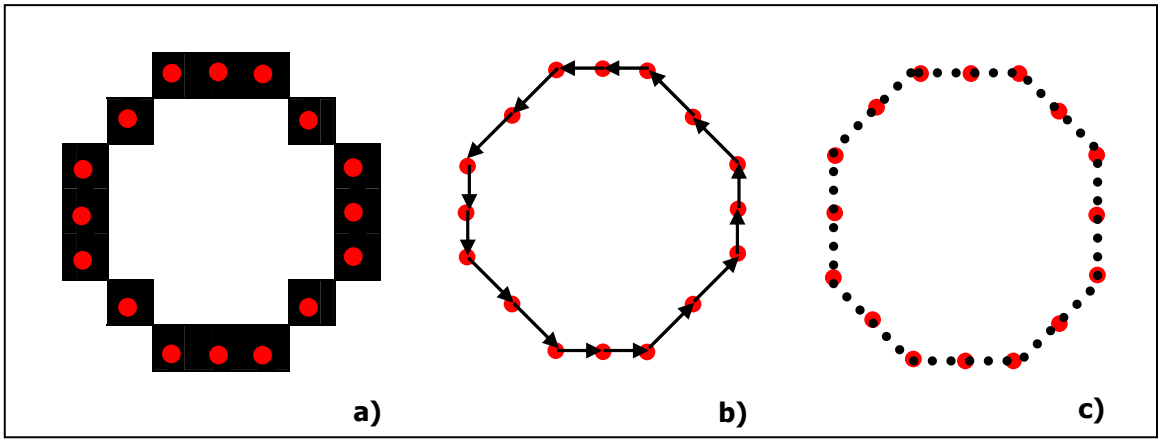

Fig. 47 – Modus operandis de la interplació per splines lineals
a) perímetre original b) representació de la figura utilitzant vectors c) obtenció de més mostres que píxels es tenen

Si ens fixem en el pas 2, quan es diu quina ha de ser la distància entre mostres, el pas, aquest es defineix a partir del total de mostres. El total de mostres que caldrà agafar d'una imatge vindrà determinat pel seu perímetre tal i com s'indica a la referència [11]. El número total de mostres és important perquè si n'agafem poques ens podem trobar que agafem una mala representació de la figura. Així és que fent cas a la bibliografia, agafarem la primera potència de 2 que sigui més gran que el perímetre de la figura.

Fent-ho així només utilitzem els píxels del perímetre per obtenir-ne més mostres. Les mostres que obtinguem seran equidistants respecte el perímetre i seran les mostres que les signatures utilitzaran per caracteritzar les figures.

Per tal de poder comparar diferents imatges mitjançant els seus descriptors de Fourier caldrà que el total de mostres extretes de cada imatge hagi estat el mateix. Per les restriccions imposades per la FFT i el fet d'haver de mostrejar la imatge correctament tindrem que el nombre total de mostres a agafar serà la primera potència de dos que sigui més gran que el perímetre de la imatge amb el perímetre més gran. Tot i així els valors obtinguts fins al moment encara no compleixen totes les invariances desitjades. Aplicant l'últim pas de normalització als valors obtinguts d'aplicar Fourier, aconseguirem tenir els descriptors de Fourier Normalitzat que ens serviran per caracteritzar una figura.

4.3.5.2 Normalització

Abans d'explicar com es normalitza la informació anem a explicar en quin punt ens trobem. Per fer-ho, res millor que una representació esquemàtica:

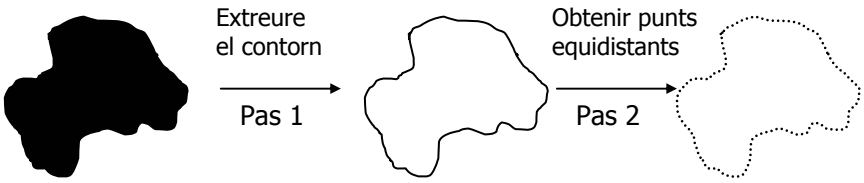

Fig. 48 – Pas 1 i pas 2 de l'otenció dels descriptors de Fourier

Els dos primers passos han consistit en extreure les mostres que ens serviran com a signatura de la figura. El primer pas obté els píxels del contorn i amb el segon pas el que es fa és obtenir punts equidistants del contorn. El tercer pas consisteix en escollir la signatura, en funció de si escollim coordenada complexe Fig. 49 o distància respecte el centre Fig. 50.

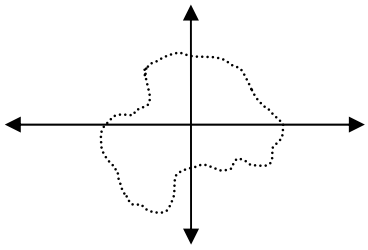

Fig. 49 – Signatura coordenada complexe

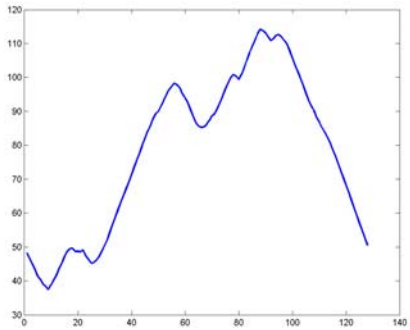

Fig. 50 – Signatura distància respecte el centre

I l'últim pas explicat fins al moment ha consistit en aplicar la Transformada discreta de Fourier, en concret la FFT, que ens ha retornat tants valors complexes com valors hem empleat per calcular la signatura. Hem dit que només ens interessava el mòdul, que si representem tots el mòduls podem observar com la representació freqüencial d'una mateixa figura té diferent resultat en funció de la signatura utilitzada, Fig. 51 i Fig. 52.

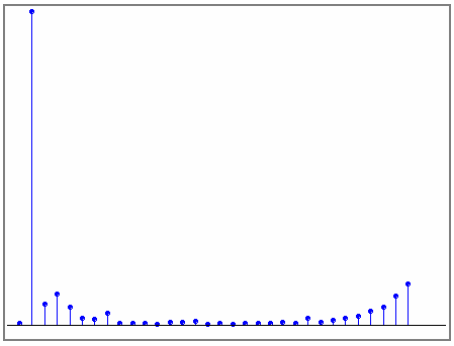

Fig. 51 – Espectre utilitzant signatura coordenada complexe

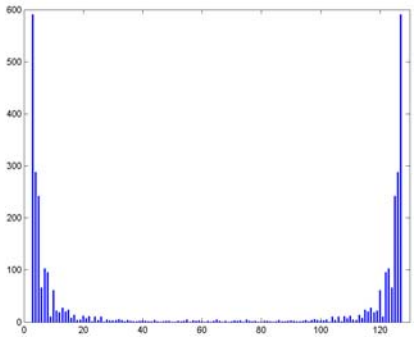

Fig. 52 – Espectre utilitzant signatura distància respecte centre

Com hem dit a l'apartat de la transformada discreta de Fourier, just després d'aplicar la FFT i abans de quedar-nos només amb el mòdul, si per algun motiu ens interessés recuperar la informació original, en el cas de la coordenada complexe la pròpia imatge i en el cas de la distància respecte el centre, les distàncies. Seria possible fer-ho, sense cap pèrdua d'informació. Fins i tot seria possible aplicar la transformada inversa utilitzant només els primers M coeficients essent M més petit que el total de descriptors obtinguts. Per fer-ho caldria considerar que desde M-1 fins al total de descriptors el seu valor és 0. El resultat seria una aproximació a la figura original. La transformada inversa, com la directa proporciona tants valors, com valors té la funció d'entrada, per aquest motiu cal considerar que tenim zeros als termes que despreciem. Sinó no obtindríem la representació d'una línia tancada com és el contorn. Fent-ho així recuperaríem exactament el mateix nombre de punts però s'utilitzaria menys informació per la reconstrucció de cada punt, donant com a resultat una aproximació de la figura. Com més petita fos la M, més inexacta seria la forma reconstruïda. L'explicació a aquest comportament és que les freqüències baixes determinen la forma genèrica de la figura i les components d'altes freqüències aporten els petits detalls. D'aquesta manera quan només agafem P descriptors el que fem és perdre detall de la figura, Fig. 53.

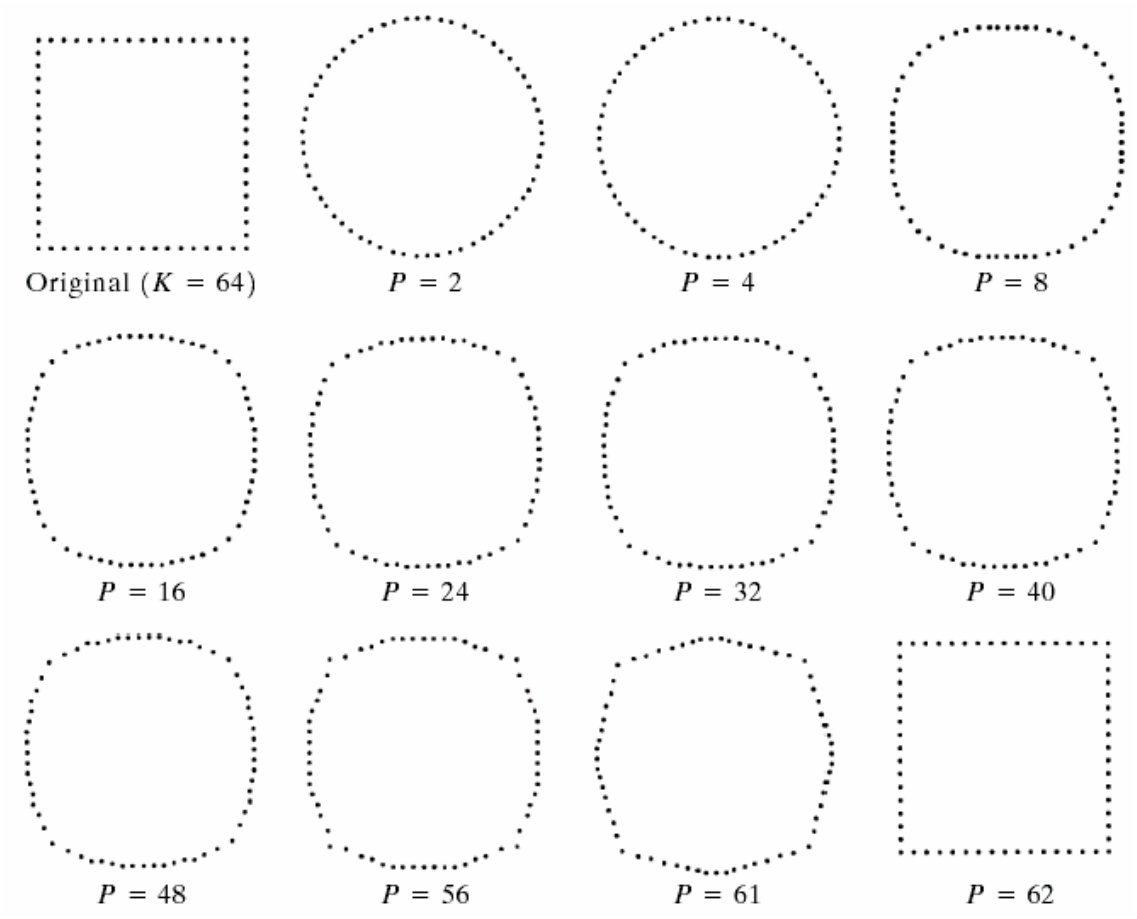

Fig. 53 – Reconstrucció d'un quadrat de K mostres utilitzant P descriptors

Com que el nostre propòsit no és recuperar imatges un cop fem la FFT ens quedem exclusivament l'espectre de freqüència format pels mòduls de cada valor complexe resultant d'aplicar la FFT. Fent-ho així, farem que totes les imatges que tinguin una mateixa forma, tinguin pràcticament els mateixos descriptors de Fourier.

Ara que ja hem recapitulat i posat en ordre les idees passem a explicar l'últim pas. La normalització dels descriptors. La normalització ens fa falta perquè imatges amb una altra rotació, o amb les mostres agafades amb un desfasament si són iguals han de tenir descriptors de Fourier coincidents. La normalització dependrà dels descriptors de Fourier Normalitzats que estiguem calculant. Si es vol calcular els descriptors de Fourier Normalitzats a partir de la signatura coordenada complexe s'hauran de seguir unes passes que seran diferents si volem calcular els descriptors de Fourier provinents de la signatura distància respecte el centre.

Tot i així la invariança a la rotació no l'haurem de buscar perquè ja la tenim tant si utilitzem una signatura com l'altra. Aquesta propietat dels descriptors de Fourier es justifica dient que la rotació d'un punt un angle Φ sobre l'origen del pla complex ve donat per la multiplicació de $e^{i\Phi}$. Fent això, la seqüència rotada de s(k) és s(k)$e^{i\Phi}$, que té com a descriptors de Fourier:

$$a_r(u) = \frac{1}{N}\sum_{k=0}^{N-1} s(k)\cdot e^{i\Phi}\cdot e^{\frac{i2\pi uk}{N}} = a(u)e^{i\Phi}$$ per u= 0, 1, 2, ..., N-1 **Equació 4-13**

La rotació no s'aprecia a l'espectre de Fourier, ja que:

$$\left|a(u)e^{i\Phi}\right| = \left|a(u)\right|\cdot\left|e^{i\Phi}\right| = \left|a(u)\right|$$

La rotació només s'aprecia a la fase, però aquest valor no és utilitzat per la representació dels descriptors de Fourier. A continuació detallem com aconseguir la invariança respecte l'escalat ja que la invariança respecte la posició ja la tenim pel fet d'haver restat el centre de masses quan definiem cada signatura.

Coordenada complexe

El vector de valors resultant d'aplicar la FFT l'anomenarem f'. I a cada descriptor de Fourier que el composa l'anomenarem FD_X, essent x la posició que ocupa en el vector de N elements.

$$f' = [|FD_1|,|FD_2|, \ldots ,|FD_{N-1}|]$$

Per normalitzar f' considerarem 0 el FD_0 ja que és el descriptor que conté la informació relacionada amb la posició d'on es troba l'objecte. Com que aquesta informació ja havia estat prèviament normalitzada restant el centre de masses a cada punt, si es volgués podríem tenir en compte perquès serà el mateix per qualsevol figura.

El pas que sí que és necessari per tal d'aconseguir invariança a l'escalat consisteix en dividir cada FD per FD_1. Fent-ho així obtenim els descriptors de Fourier normalitzats. Com es pot veure a continuació, el primer valor és 0 per imposició i el següent és 1 per ser el resultat de dividir $\frac{|FD_1|}{|FD_1|}$.

$$f = \left[0,1,\frac{|FD_2|}{|FD_1|},\frac{|FD_3|}{|FD_1|},\ldots,\frac{|FD_{N-1}|}{|FD_1|}\right]$$

Distància respecte el centre

Utilitzant aquesta signatura tindrem la meitat de Descriptors de Fourier que de mostres. Aquest fet és causat per la simetria de valors que pateix l'espectre que fa que guardant només la meitat dels valors resultants d'aplicar la FFT, en fem prou per indexar la forma.

El procés de normalització consisteix en dividir els diferents FD, per FD_0. Com que només ens quedarem amb la meitat de valors per la simetria de l'espectre definim els descriptors de Fourier Normalitzats com f, on f és:

$$f = \left[\frac{|FD_1|}{|FD_0|}, \frac{|FD_2|}{|FD_0|}, \ldots, \frac{|FD_{N/2}|}{|FD_0|} \right]$$

I fins aquí hem aconseguit caracteritzar figures basant-nos en dues signatures. A l'hora de reconèixer figures caldrà comparar el total de descriptors que tinguem de manera que si tenim un total de N descriptors tindrem un temps lineal per la comparació de cada figura. Seria molt interessant poder caracteritzar el contorn d'una figura per un únic valor que ens permetés discriminar les diferents formes.

4.3.5.1 Descriptor Únic (FF)

Amb la idea de tenir caracteritzada la forma d'una figura amb un únic valor, apareix el concepte de descriptor únic. S'obté a partir del total de descriptors de Fourier normalitzats calculats per una figura utilitzant la signatura de coordena complexe. És una funció que pondera la importància que té cada descriptor depenent de la informació que aporti. Aquest fet és possible perquè les components de baixes freqüències aporten més informació que no pas components d'altes freqüències.

En la nostra representació A(n), n = 0, 1, ... , N-1, són el total de descriptors normalitzats. Essent N una potència de 2 pel fet de considerar que s'ha utilitzat l'algorisme de FFT. Es té que:

NFD(k), k = -N/2+1, ... , N/2.

$$NFD(k) = \begin{cases} 0; & k = 0 \\ A(k); & k = 1, 2, \ldots, N/2 \\ A(k+N) & k = -1, -2, \ldots, -N/2+1 \end{cases}$$

Aprofitant que l'espectre de Fourier és una funció periòdica. La funció NFD talla l'espectre pel tall que més li convé. Com que el tall que s'agafa continua essent un període, no té cap

efecte sobre el resultat final, excepte que l'expressió FF del descriptor únic, és de més bon escriure.

$$FF = \frac{\sum_{k=-N/2+1}^{N/2} \frac{\| NFD(k) \|}{|k|}}{\sum_{k=-N/2+1}^{N/2} \| NFD(k) \|}$$

La interpretació de la fórmula de FF, és la següent. Amb la divisió per |k|, el que es fa és emfatitzar les components de baixa freqüència, fet que significa que FF donarà un valor més petit si més energia és distribuïda en la part de les altes freqüències, (cosa certa en figures que el seu contorn pateix bastants canvis de direcció). El denominador realitza la normalització fent que el rang de valors possibles varii, entre 0 i 1.
A grans trets podem dir que com més irregular sigui una figura més petit serà el seu descriptor únic i al revés.

Un cop vista l'ultima opció de caracterització de formes basant-nos en el domini freqüencial, expressarem la manera com es fa la comparació d'imatges. La comparació d'imatges, tant si només es té un valor com és el cas del descriptor únic FF, com si es té un vector de valors com és el cas de la coordenada complexe i la distància al centre, s'expressarà de la mateixa manera. S'utilitzarà la distància euclidiana ja presentada al capítol 4 quan hem definit la comparació si s'utilitzaven els descriptors de Chang.

4.3.6 Resultats i Conclusions

En aquest capitol hem vist com es pot utilitzar la transformada de fourier per tal de descriure formes. S'ha presentat l'esquema consistent en extreure un conjunt de punts del contorn per tal de caractreritzar-ne la figura. Depenent de la signatura s'ha vist que els descriptors de de Fourier que obteniem no sempre coincidien amb el nombre de mostres accentuant d'aquesta manera encara més el fet que la relació que hi ha entre les mostres del domini espaial i els descriptors de Fourier no és directa.

5CBIR I CLASSIFICACIÓ

5.1 INTRODUCCIÓ

Per tal de testejar els mètodes d'extracció de característiques de forma explicats en els capítols anteriors, s'han desenvolupat dos tipus de sistemes: (i) un sistema CBIR* que permetrà fer cerques d'imatges en una base de dades basant-se en el contingut de la imatge. (ii) un sistema de Classificació que permetrà reconèixer els objectes presents a les imatges segons les seves característiques de forma. L'objectiu és poder determinar quines característiques de forma (descriptors), són més útils per cada tasca.

A continuació, s'explica amb més detall en què consisteix cada un d'aquests sistemes, i com n'hem pensat el disseny.

5.2 SISTEMA CBIR

Per tal de realitzar una cerca basada en el contingut, cal pensar en com s'han d'estructurar les diferents característiques extretes de la mamografia, o més concretament, de la lesió present a la imatge mamogràfica. Posteriorment, caldrà estudiar mesures de similitud entre aquestes estructures per tal de poder recuperar les lesions que més s'assemblin a les que l'usuari consulti.

En tots els sistemes CBIR (Content Based Image Retrieval) el que es pretén és recuperar imatges semblants a una que l'usuari dona com a entrada. En aquests sistemes, generalment una imatge ve representada per un conjunt de característiques on cada una d'elles pot prendre un rang de valors afitat, o no. Quan es volen establir mesures de similitud entre imatges, s'organitzen les diferents característiques en vectors de parelles del tipus atribut-valor. D'aquesta manera, cada imatge tindrà associat un vector que la definirà. La similitud entre imatges s'obtindrà a partir de la similitud del vector que té associat cada una d'elles. Per buscar la similitud es comparen els valors de cada atribut, normalment a partir de tècniques basades en mesurar distàncies. La similitud entre dues imatges s'obté del resultat de sumar les diferències entre els valors de cada atribut individualment.

Quan es volen recuperar imatges d'una base de dades en funció del seu contingut, cal establir una mesura per mesurar la similitud entre imatges. S'estableixen mesures de similitud entre el vector de característiques d'una imatge que es dóna com entrada i els

* Content Based Image Retrival

vectors de característiques de les imatges de la base de dades. La Fig. 54, mostra com donada una imatge amb el seu corresponent vector de valors numèrics es poden recuperar imatges semblants segons uns criteris de similitud.

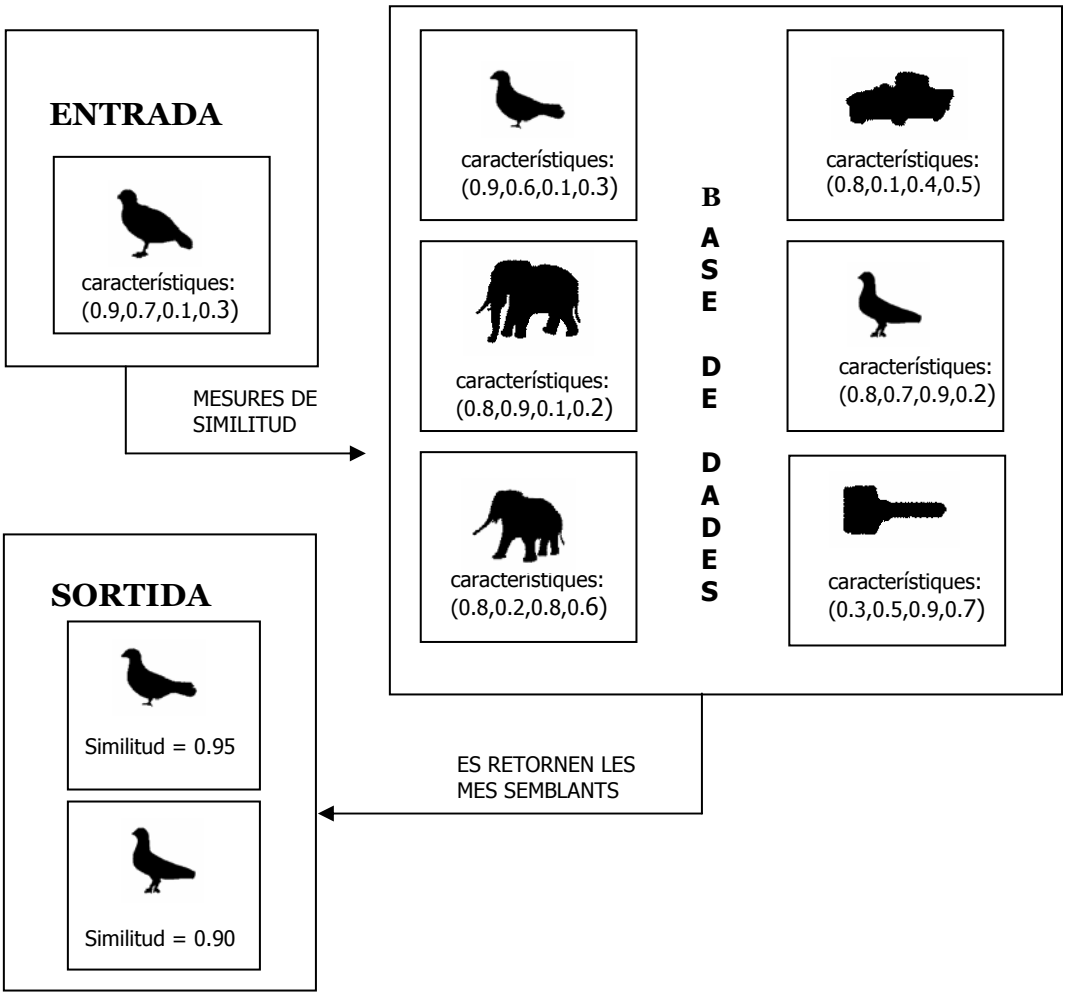

Fig. 54 – Esquema d'un sistema CBIR. Recuperació d'imatges basat en el seu contingut

Si ens fixem en els vectors de característiques, es pot observar que tots ells tenen la mateixa dimensió. Per totes les imatges s'extreu el mateix nombre de característiques i les mesures de similitud que s'utilitzen es comparen característica a característica, valor a valor.

Així doncs, per tal d'afrontar la tasca de realitzar una cerca basada en el contingut sobre una base de dades d'imatges, s'ha de tenir en compte:

Característiques de la imatge – En el nostre cas s'han utilitzat els descriptors de forma comentats anteriorment. Aquests descriptors s'extreuen dels objectes presents a les imatges, ja siguin les lesions contingudes en una mamografia, com qualsevol altre tipus

d'objecte (triangle, cotxe, tortuga). L'aplicació permet que l'usuari seleccioni amb quines de les característiques vol fer la cerca. L'usuari forçosament ha de fer les consultes basant-se amb alguns dels descriptors avançats proposats, però té l'opció d'escollir quins descriptors bàsics vol fer servir.

Representació de la imatge – Cal pensar en com es codifiquen les característiques de la imatge. En el cas actual, els descriptors es codifiquen en forma de vectors, atribut-valor. Això es possible ja que per totes les imatges s'obtenen el mateix nombre de característiques.

Mesura de Similitud – S'ha utilitzat com a mesura de similitud la Distància Euclidiana, la fórmula de la qual es pot veure a l'Equació 5-1, on f_m i f_d són els diferents vectors atribut-valor.

$$d = \left(\sum_{i=0}^{N} \left| f_m^i - f_d^i \right|^2 \right)^{\frac{1}{2}}$$ **Equació 5-1**

Cal tenir en compte però, que no totes les dades amb les que es treballa tenen el mateix rang de valors, ni té perquè ser un rang afitat. Amb aquesta puntualització volem fer notar que si féssim la distància euclidiana tal i com es proposa a l'Equació 5-1, els resultats que tindríem no tindríem sentit. Aquesta falta de sentit en els resultats seria deguda, a què les característiques com l'àrea poden donar diferències molt grans que farien menystenibles els resultats dels descriptors avançats. Per ponderar cada característica en funció del seu rang es calcula la distància euclidiana ponderada, definim que es defineix:

$$d = \left(\sum_{i=0}^{N} \frac{\left| f_m^i - f_d^i \right|^2}{\sigma_i} \right)^{\frac{1}{2}}$$ **Equació 5-2**

On és la desviació estàndard.

Per obtenir la desviació estàndard es mira per cada grup d'imatges quina és la desviació per cada característica.

5.3 CLASSIFICACIÓ

Un sistema de classificació, és aquell que donada una imatge permet determinar de quin tipus és. És a dir, si l'usuari dóna com a entrada al sistema una imatge que conté un ocell, el sistema ha de ser capaç de dir que la imatge conté l'objecte ocell. És evident doncs, que per tal que el sistema pugui reconèixer objectes, cal un pas previ d'aprenentatge dels objectes.

Per tal d'afrontar la tasca de realitzar un sistema de classificació les passes a seguir són les següents:

Selecció de les imatges – Cal seleccionar quines són les imatges que es faran servir per entrenar el sistema, per tal que pugui aprendre i quines són les imatges que s'utilitzaran per verificar aquest aprenentatge. Així doncs es tindran dos grups d'imatges, les imatges de test i les imatges de prova.

Aprenentatge – L'entrada al sistema serà una imatge i una etiqueta especificant quin objecte conté aquesta imatge. Tot seguit el sistema extreu les característiques de forma d'aquest objecte. Per tal de deixar constància d'aquest aprenentatge, es guarden els vectors de característiques juntament amb l'etiqueta de l'objecte en una base de dades. La Fig. 55, mostra com es faria l'aprenentatge per dos tipus d'objectes qualsevol.

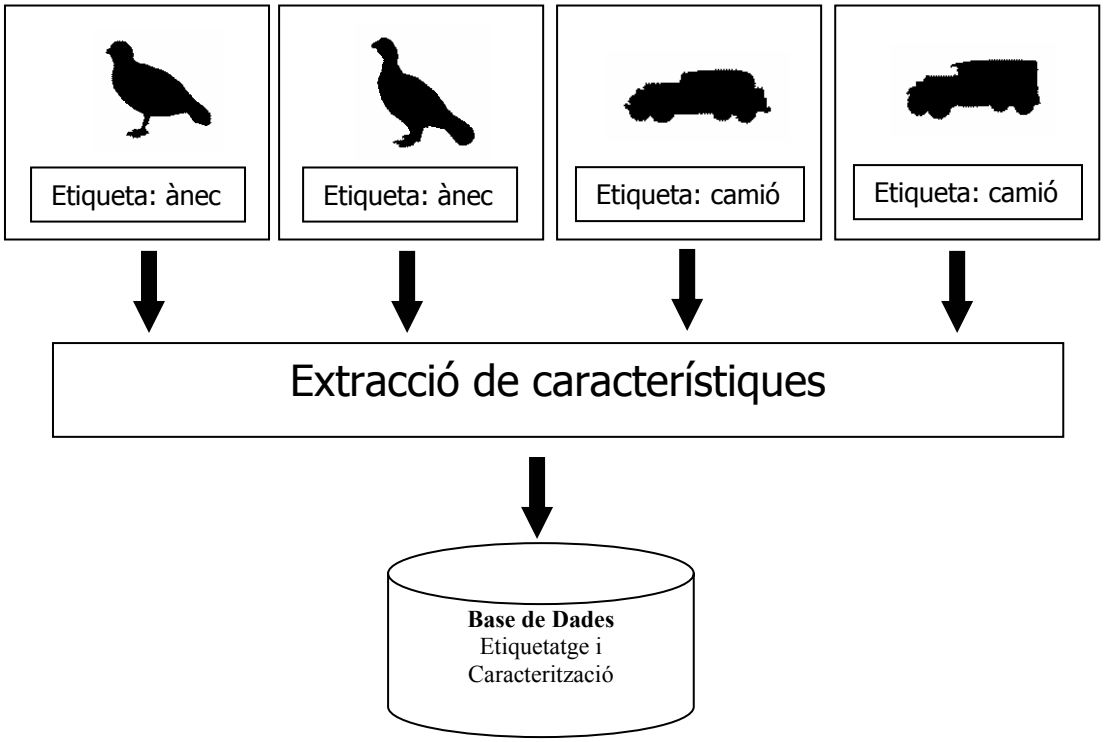

Fig. 55 – Sistema de Classificació. Fase d'aprenentatge

Reconeixement – Donada una imatge el sistema ha d'identificar quin objecte conté, per fer-ho primer cal extreure les característiques de l'objecte que serà el que es buscarà i compararà amb els valors de la base de dades.

Per tal de fer reconeixement només s'utilitzen els descriptors avançats, i serà l'usuari qui triarà quins vol fer servir. Per tal de realitzar el reconeixement, és evident que cal establir unes mesures de similitud. En aquest cas es disposa de molts vectors de característiques associats a cada objecte, a cada etiqueta. Si es fa la mitjana dels atributs d'aquests vectors, s'obtindrà un vector de característiques per cada objecte. Tot seguit s'aplica com a mesura de similitud la distància euclidiana normalitzada (veure Equació 5-2) entre els vectors de les mitjanes de cada objecte i les característiques extretes de l'objecte de la imatge consultada per l'usuari. Un objecte pertanyerà a una classe quan la diferència entre les característiques de la imatge i les de la classe sigui la diferència més petita d'entre totes les classes. La Fig. 56 mostra de forma esquemàtica el sistema de reconeixement d'un sistema de classificació.

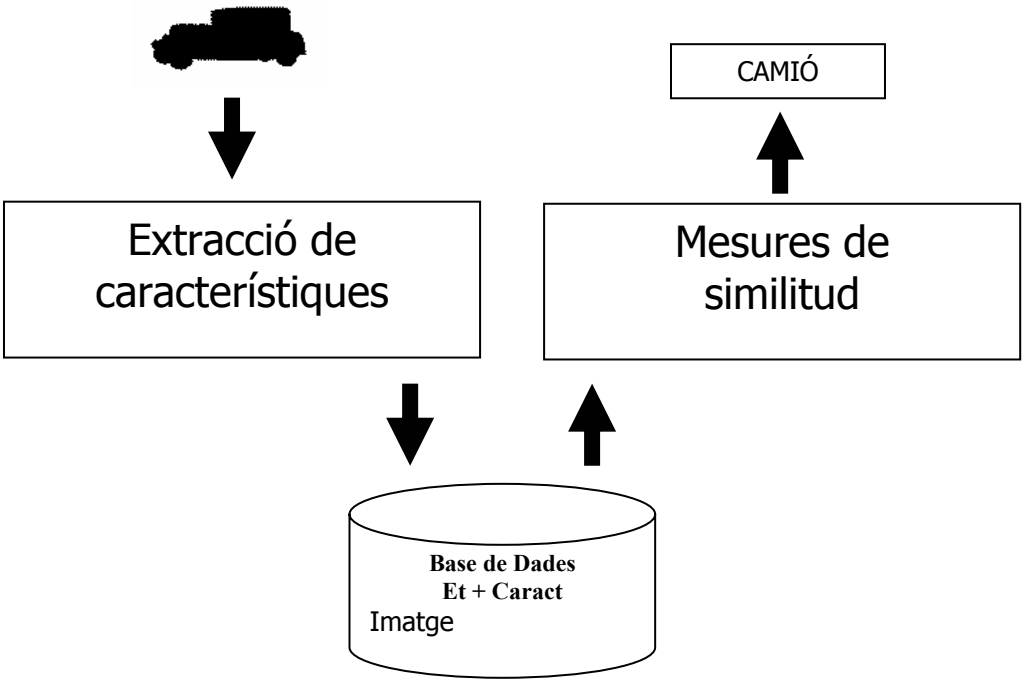

Fig. 56 – Sistema de classificació. Fase de reconeixement

6 DISSENY

6.1 INTRODUCCIÓ

En aquest capítol es presentarà el disseny de la base de dades, amb l'ajuda del model entitat relació i el model relacional. A continuació es detallaran els diagrames de flux que expliquen de manera esquemàtica la forma de procedir per les diferents opcions de càlcul de l'aplicació.

6.2 BASE DE DADES

En aquest apartat s'exposa el disseny de la base de dades que hem creat per avaluar els resultats. Per tal de realitzar aquesta tasca s'ha desenvolupat el model entitat relació i el model relacional que es mostren en els dos apartats següents.

6.2.1 Model Entitat Relació

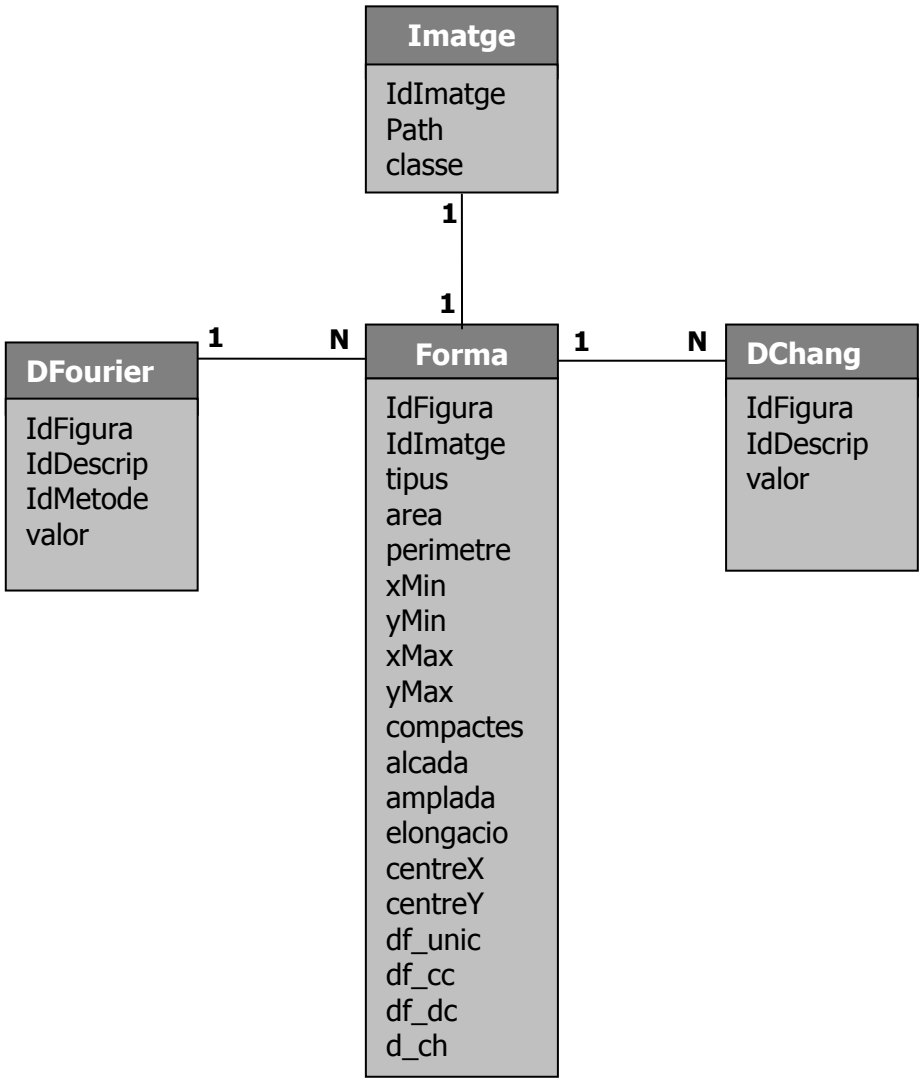

6.2.2Model Relacional

Imatge	IdImatge, Path, classe
Forma	IdFigura, IdImatge, tipus, area, perimetre, xMin, yMin, xMax, yMax, compactes, alcada, amplada, elongacio, centreX, centreY, df_unic, df_cc, df_dc, d_ch
DFourier	IdDescrip, IdFigura, IdMetode, valor
DChang	IdDescrip, IdFigura, valor

La informació s'ha agrupat en taules diferenciant les diferents entitats del sistema. La taula Imatge conté la informació referent a la imatge, com és la ruta de la imatge i de quina classe és (sintètica, geomètrica, mamogràfica).
La taula Forma conté la informació relacionada amb la figura de la imatge com són els descriptors bàsics.
I finalment tenim dues taules, la DFourier i la DChang que contenen els descriptors de Fourier i de Chang per cada figura respectivament.

6.3 APLICACIÓ

A continuació presentem en forma de diagrames el fil d'execució que segueix l'aplicació depenent del procediment que apliquem.

6.3.1 DESCRIPTORS BÀSICS

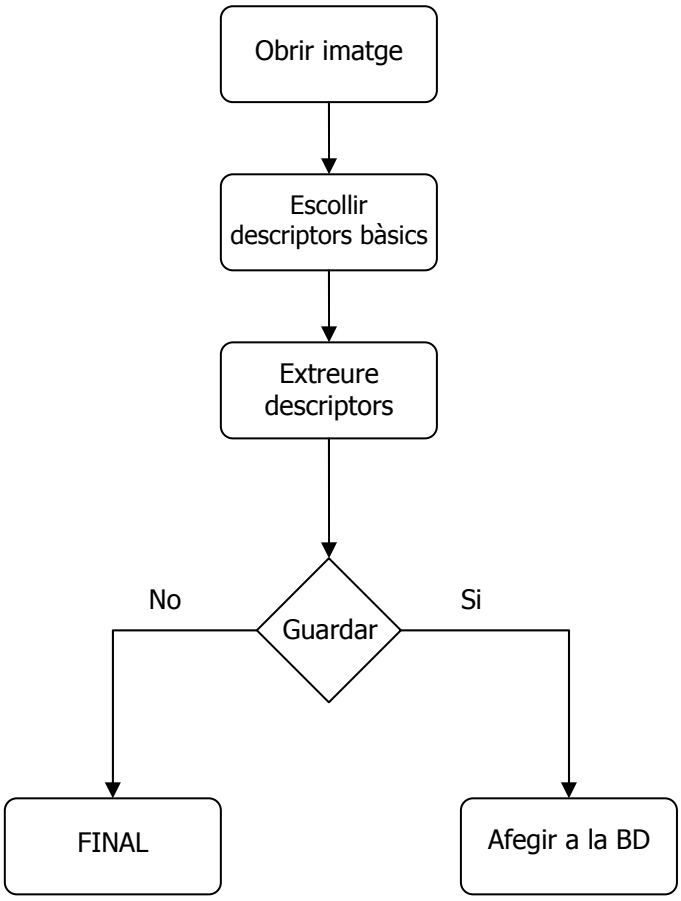

El diagrama dels descriptors bàsics consisteix en obrir la imatge i escollir-ne els descriptors que es volen calcular. El pas següent serà calcular-los i descidir què es vol fer amb ells. Les dues opcions de què disposem és afer-los a la base de dades o no fer res.

6.3.2MÈTODE DE CHANG

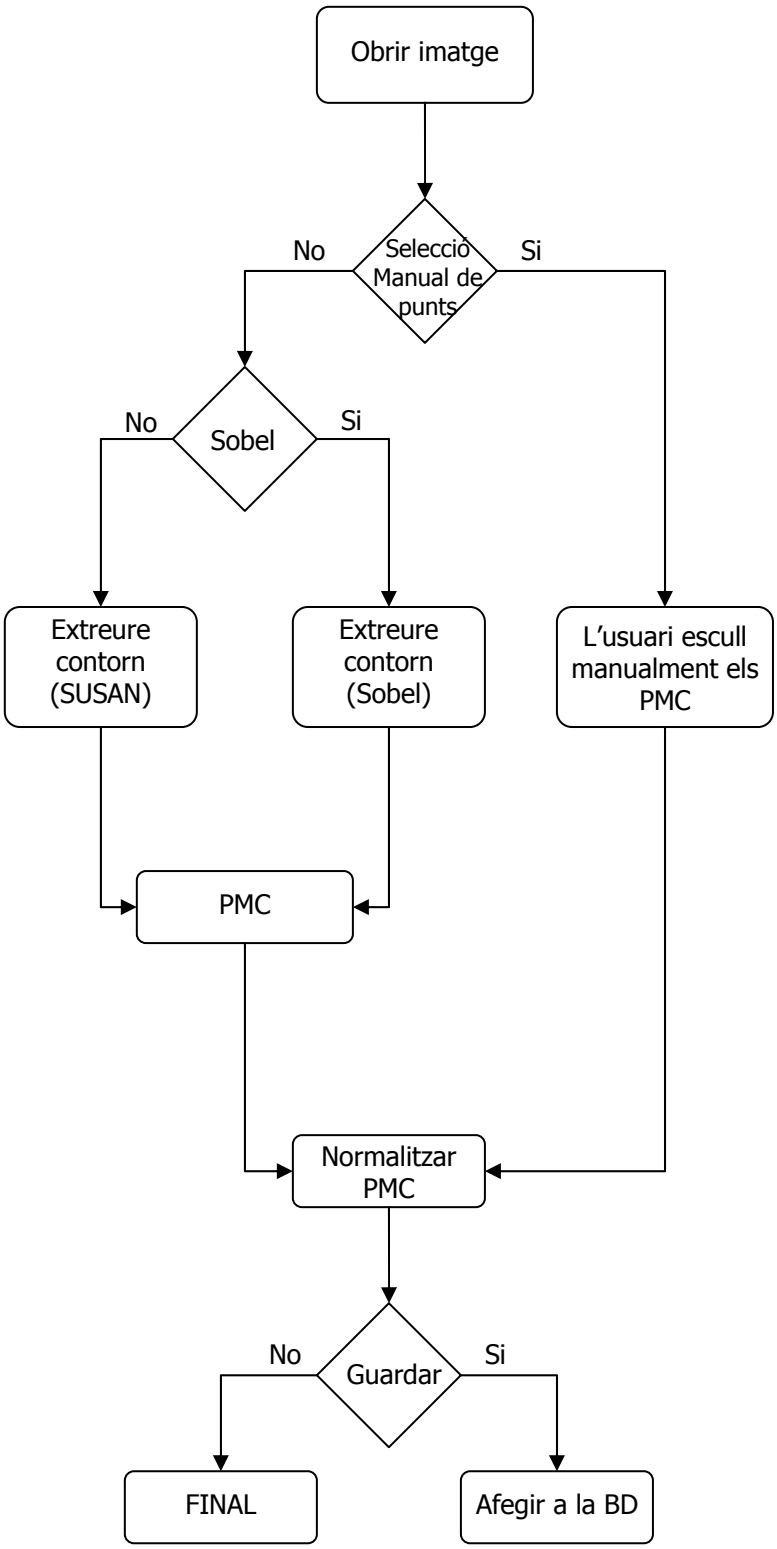

6.3.3MÈTODE DE FOURIER

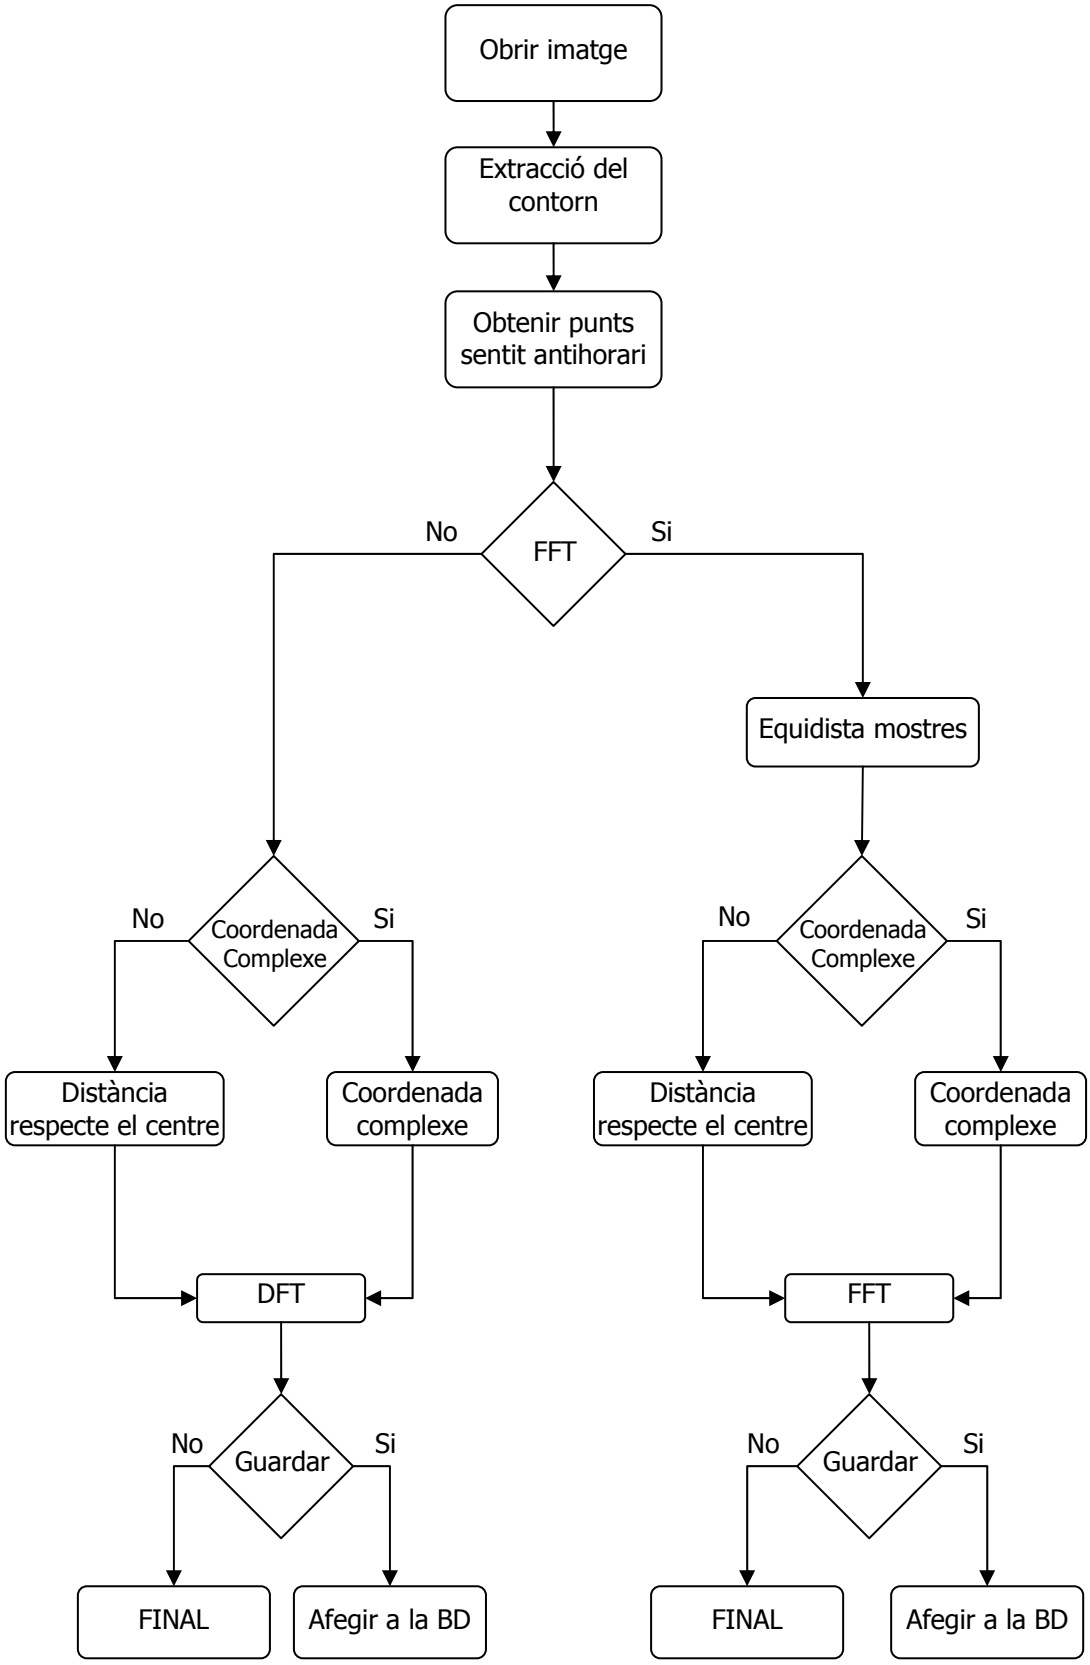

6.3.4 Sistemes de classificació i CBIR

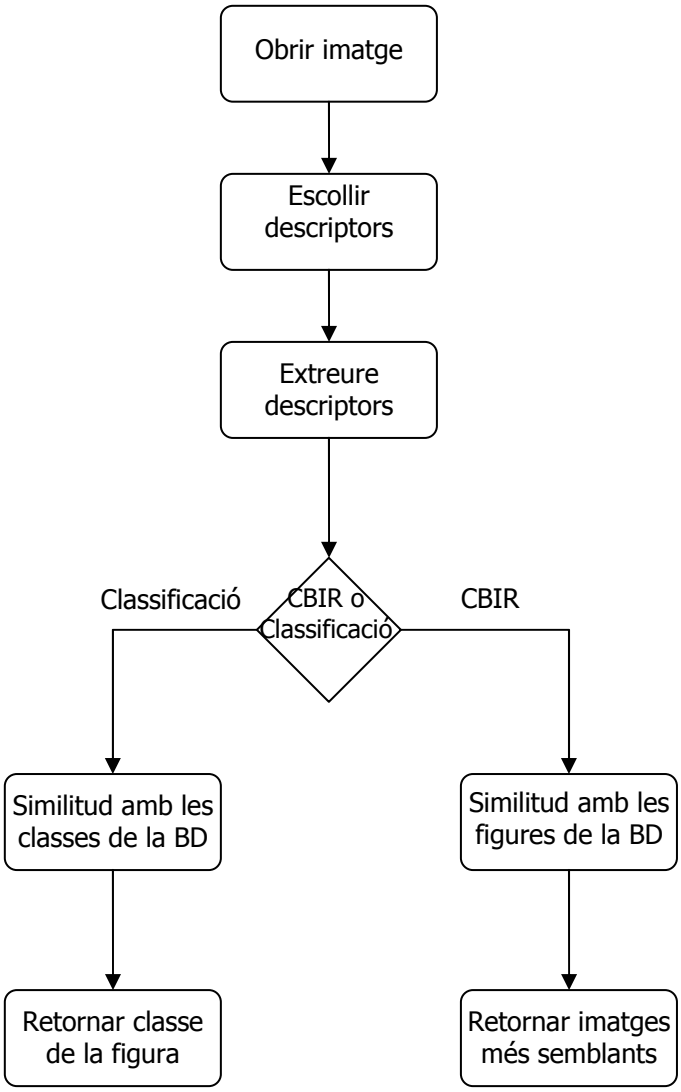

Els esquemes de CBIR i classificació segueixen un procediment paral·lel. La diferència rau en el fet que com que fent Classificació volem tornar la classe i fent CBIR volem tornar els objectes més propers, la comparació serà el canviarà.

7RESULTATS

7.1 INTRODUCCIÓ

Per tal d'avaluar i comparar entre sí els diferents mètodes d'extracció de descriptors de forma s'han fet un seguit de proves utilitzant l'aplicació que hem dissenyat amb aquest propòsits. Tot i que l'objectiu principal del projecte és la recuperació d'imatges mamogràfiques, hem treballat amb 2 grups més d'imatges per comprovar quinés l'abast i la robustesa dels mètodes implementats.

Les tres classes d'imatges utilitzats són:

- Figures geomètriques
- Imatges sintètiques
- Imatges mamogràfiques

Hem decidit fer-ho així per veure si els problemes que hi poguéssin haver a l'hora de fer reconeixement o classificació, eren culpa del mètode o de les imatges. Les classes que no són mamografies en principi presenten formes més senzilles i fàcils de classificar, per aquest motiu creiem que també poden ser d'utilitat els resultats que d'elles se'n desprenguin. A més, aquestes proves ens han de servir per observar si els mètodes implementats poden tenir aplicació en altres camps de la visió per computador.

El mètode de Chang només ha estat testejat amb la classe de les imatges geomètriques perquè com expliquen els resultats del propi capítol. No és proper a donar bons resultats amb imatges arrodonides.
Encanvi per avaluar els mètodes de Fourier: coordenada complexe, distància al centre i descriptor únic, s'han utilitzat les tres classes d'imatges pel fet de ser mètodes més robusts.

7.2 IMATGES UTILITZADES

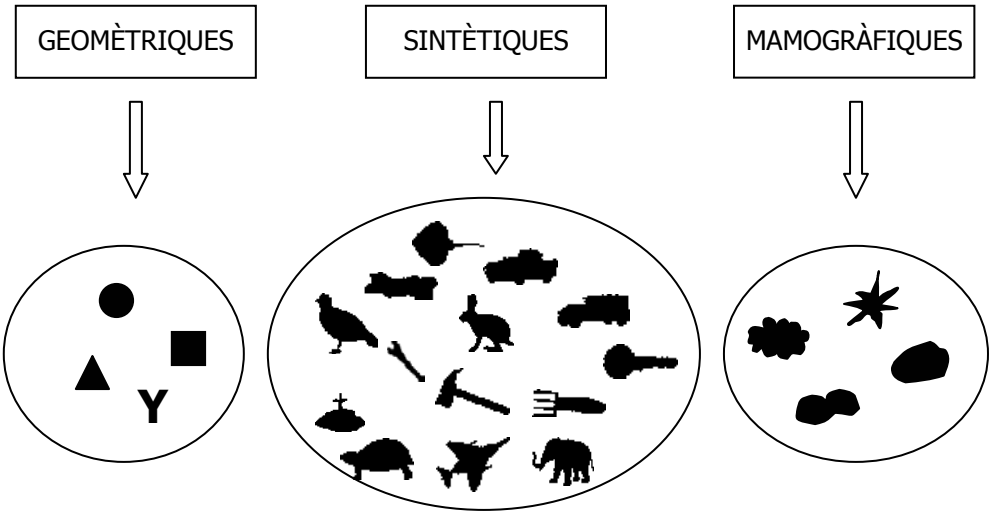

Fig. 57 – Representació esquemàtica dels tipus d'imatges de cada classes que hem utilitzat per fer resultats

Per cada una de les tres classes d'imatges a dalt presentats, tenim diferents tipus d'imatges com a continuació es mostrarà. Les nostres proves havien de diferenciar entre els diferents tipus d'imatges, i no pas entre les classes geomètriques, sintètiques i mamogràfiques.

Les imatges geomètriques són les que presenten de manera més accentuada canvis d'escalra, de posició i d'orientació. Les sintètiques encanvi, presenten diferents vistes o versions d'un objecte o animal. I per últim les mamogràfiques que són imatges reals.

7.2.1 Imatges geomètriques

Les 40 imatges geomètriques introduïdes a la base de dades es calssificaven en 4 grups de 10 imatges que són:

- Triangles ▲
- Cercles ●
- Rectangles ■
- Lletres Y

Per tal que la classificació no resultés tant senzilla s'ha fet passar algun decàgon per rodona, i algun trapezi com a quadrat. Ho hem fet per veure com eren tolerats dins el sistema i si els resultats eren bons tot i no tenir imatges perfectes.

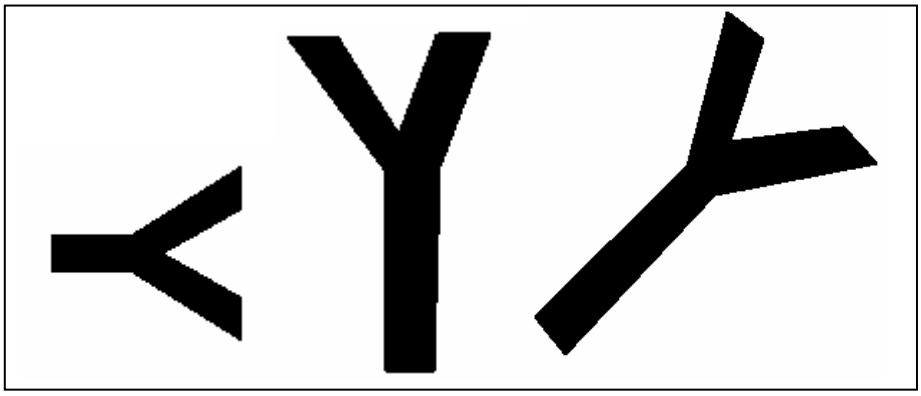

Fig. 58 – Exemples d'imatges del tipus Y de la classe de les imatges geomètriques

A la Fig. 58 podem observar algunes de les imatges del tipus cercles presents a la classe geomètriques. Com es pot observar, a part de cercles també hi trobem ovals i el·lipses.

7.2.2 Imatges Sintètiques

El grup de les imatges sintètiques es divideix en 14 classes formades per 10 imatges cadascuna:

- Ocells
- Rajoles
- Tortugues
- Cotxes antics
- Claus angleses
- Claus de pany
- Cotxes moderns
- Forquilles
- Martells
- Avions
- Conills
- Rajades
- Elefants
- Creus

Com es pot veure és una classe més complexe tot i ser imatges sintètiques. La dificultat radica en què hi ha imatges molt semblants entre sí i que a priori podem esperar que el sistema es pugui confondre.

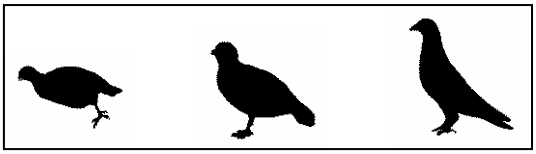

Fig. 59 – Exemples d'imatges del tipus ocells de la classe sintètiques

A més a més tal i com es pot veure a la Fig. 59, un mateix tipus d'imatges pot presentar figures força diferents entre sí, dificultant encara més la classificació.

7.2.3 Imatges Mamogràfiques

Les imatges mamogràfiques, abans de ser tractades han patit un procés d'escalat per tal de poder treballar a nivell de píxel. S'ha optat per aquesta via per la major abstracció que suposa respecte la imatge real que s'estigui tractant. El procés d'escalat ha consistit en fer un estudi previ de quina era la imatge que presentava un contorn més gran. Aquesta imatge, o més concretament aquesta figura ha estat escalada fins que ha estat possible fer-li un mostreig de 1024 mostres amb garanties.

El fet d'escollir 1024 ha estat per poder utilitzar la FFT (havia de ser una potència de 2), i perquè el temps de càlcul que suposa i el tamany de les imatges era raonable.
A continuació s'han escalat proporcionalment la resta d'imatges de manera que com que totes eren més petites, totes quedaven ben mostrejades.

Les imatges mamogràfiques, les hem dividit en quatre categories:

- Espiculars (15)
- Lobulades (12)
- Microlobulades (20)
- Ovalades (18)

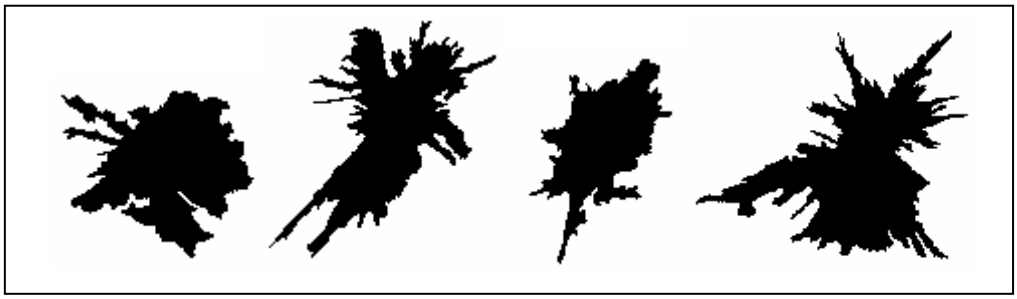

Fig. 60 – Exemples de masses espiculars

7.3 OBTENCIÓ DE RESULTATS

S'han fet resultats tant per reconeixement com per CBIR, i s'ha procurat que els resultats fossin d'allò més entenedors. Per aquest motiu s'ha decidit fer gràfiques sempre que es pogués i prescindir de les feixugues taules de valors.
Evidenment hi ha hagut resultats que no hi ha hagut més remei que expressar-los amb taules amb valors. S'han simbolitzat els diferents tipus d'imatge mitjançant icones que ja hem presentat quan hem explicat els diferents tipus d'imatges. Creiem que d'aquesta manera és més ràpida i dinàmica la lectura de les taules.

A l'hora de fer resultats, s'ha avaluat, el comportament general dels descriptors per cada classe d'imatges (geomètriques, sintètiques, mamogràfiques), però també s'ha volgut mostrar de manera particular com de bé funcionaven els descriptors avançats per reconèixer un tipus determinat d'imatges. Amb aquestes dues visions ens volem assegurar que si un mètode presenta bons resultats de manera global, no ens estigui amagant alguna deficiència com pot ser que li costi molt reconèixer o diferenciar un tipus determinat d'imatges.

La manera com s'han fet les proves ha estat la mateixa per tots les classes d'imatges. Hem agafat les tres classes d'imatges (mamogràfiques, sintètiques i geomètriques) i per cada classe hem preguntat per tres imatges del mateix tipus no contingudes al grup inicial. O sigui en el cas de les mamografies s'han consultat tres imatges espicluars, tres imatges microlobulades, tres imatges lobulades i tres d'ovalades.

A partir d'aquí en funció de si avaluàvem el Reconeixement o avaluàvem CBIR hem operat de manera diferent.

7.3.1 Reconeixement

Els resultats de la classificació els hem representat utilitzant taules o matrius de confusió. A les files s'hi representa la imatge per la qual es pregunta i a les columnes s'indica quina és la resposta que ha retornat el sistema. Com a continuació s'observarà l'ideal és que només estigués plena la diagonal perquè voldria dir que el sistema sempre ha reconegut la imatge, però la realitat és que hi poden haver confusions (d'aquí ve el nom) o que fins i tot no sigui possible dir a quina figura s'assembla.

En comptes de fer les matrius de confusió amb valors absoluts s'han representat els percentatges obtinguts de fer les mitjanes de les tres consultes per un mateix tipus d'imatges. D'aquesta manera s'obté una representació percentual que presenta una visió més genèrica de l'eficiència del sistema.

Per tal d'analitzar el sistema de classificació, s'ha seguit el mateix procediment per tots els grups d'imatges. S'han consultat 3 imatges de cada tipus de cada classe. Amb els resultats que hem obtingut n'hem fet la mitjana i ho hem representat mitjançant matrius de confusió. D'aquesta manera podem observar com de bé classifica cada tipus d'imatges basant-nos en el resultat de fer 3 proves.
Les taules de confusió s'han de llegir per files, o sigui. Cada fila és la figura per la qual hem preguntat, i a la columna es mostra què ha dit que era. Si el sistema fos perfecte obtindríem una diagonal plena amb el número cent volent dir que sempre ha reconegut la imatge amb un 100% d'efectivitat. Com més divergeixin els resultats de la diagonal, pitjor ha funcionat el reconeixement.
Per tal d'obtenir un resultat global de com de bé funciona el reconeixement definirem l'eficiència com la mitjana d'encerts.

7.3.1.2 Figures Geomètriques

Serà la primera classe d'imatges que analitzarem. És d'esperar que s'hi donin els millors resultat per ser la classe més senzilla de totes tres.

MÈTODE: Chang
PMC: SUSAN

%	●	■	▲	Y
●	0	0	0	0
■		100		
▲			100	
Y				100

eficiència = 75 %

MÈTODE: Fourier
SIGNATURA: Coordenada Complexe
1024 mostres → 1024 descriptors

%	●	■	▲	Y
●	100			
■		100		
▲			100	
Y				100

eficiència = 100 %

MÈTODE: Fourier
SIGNATURA: Coordenada complexe
Descriptor únic de 1024 mostres

%	●	■	▲	Y
●	100			
■	33.3	66.6		
▲			100	
Y				100

eficiència = 91,5 %

MÈTODE: Fourier
SIGNATURA: Distància al centre
1024 mostres → 512 descriptors

%	●	■	▲	Y
●	100			
■		100		
▲			100	
Y				100

eficiència = 100 %

El mètode de Chang presenta uns molt bons resultats com era d'esperar. El fet que no tingui un 100 % d'eficiència és degut a què les figures arrodonides se li resisteixen i no hi ha hagut maneres que en reconegués cap. Aquest fet és degut a què ha trobat un número diferent de PMC a cada cercle i cap ha coincidit amb el total de punts que tenien els cercles de la base de dades.

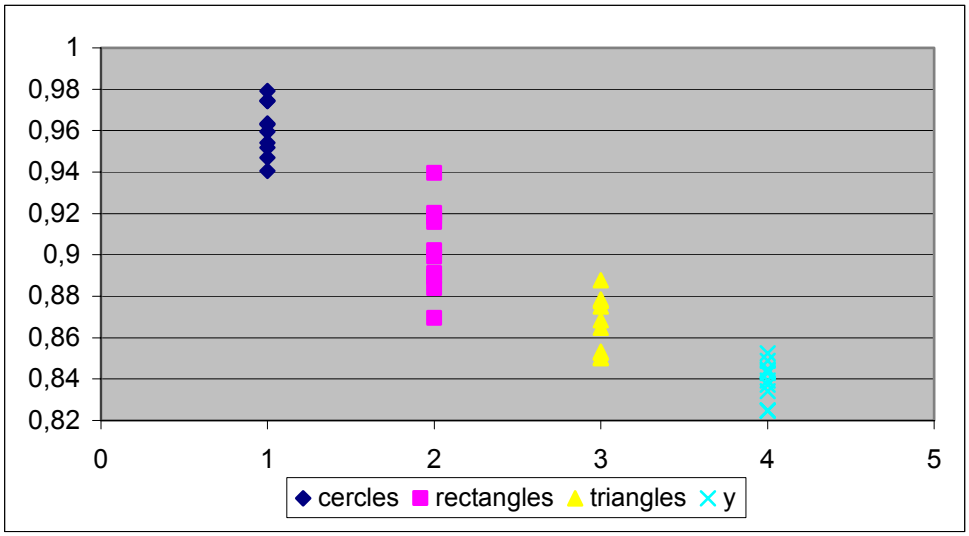

Fig. 61 – Representació del descriptor únic FF a l'eix Y per cada tipus d'imatge geomètrica

Els mètodes de Fourier com són la coordenada complexe i la distància al centre presenten uns resultats excel·lents amb una capacitat d'encert del 100 %. En canvi el descriptor únic no dóna uns resultats tant bons. Per intentar esbrinar el perquè hem decidit representar els

valors de tots els descriptors únics presents a la base de dades, intentant trobar alguna explicació al problema. El resultat es pot observar a la Fig. 61.

De la figura Fig. 61 se'n desprèn que els valors del descriptor únic es sobreposen per determinats grups d'imatges. Aquest fet pot provocar que a l'hora de reconèixer figures ens equivoquem. Concretament el problema que ens hem trobat, és que s'ha confós un quadrat per un cercle. Tal i com s'observa a la gràfica els valors del descriptor únic pels cercles i pels rectangles se sobreposen per molt poc. És lògic que hi pugui haver confusió. El que seria totalment incoherent és que es confongués un cercle amb un triangle o amb la lletra Y. Els seus valors de descriptor únic estan clarament separats i el reconeixement ha de ser perfecte.

7.3.1.3 Imatges Sintètiques

A continuació es pot observar quins han estat els resultats de fer reconeixement per les imatges sintètiques, en funció del mètode utilitzat (coordenada complexe amb 512 descriptors, coordenada complexe amb 1 sol descriptor i distància al centre).

MÈTODE: Fourier

SIGNATURA: Coordenada Complexe

512 mostres → 512 descriptors

%														
	66,6											33,3		
		100												
			100											
				100										
					100									
						100								
							66,6					33,3		
								100						
									66,6				33,3	
										100				
											66,6	33,3		
												33,3		66,6
													100	
														100

Eficiència = 85,7 %

MÈTODE: Fourier

SIGNATURA: Coordenada Complexe

Descriptor únic resultant d'agafar 512 mostres

%														
						100								
		66,6	33,3											
					100									
		100												
					100									
						66,6	33,3							
							33,3			66,6				
							33,3	66,6						
					33,3				33,3					33,3
							66,6	33,3						
							33,3		33,3					33,3
	33,3										33,3			33,3
		66,6		33,3										
									66,6					33,3

Eficiència = 28,57 %

MÈTODE: Fourier

SIGNATURA: Distància al Centre

512 mostres → 256 descriptors

%														
	66,6											33,3		
		100												
			100											
				66,6									33,3	
					100									
						100								
							100							
								100						
									100					
										100				
											66,6	33,3		
							66,6							33,3
													100	
														100

Eficiència = 85,7 %

Com es pot observar el descriptor únic és la pitjor manera de reconèixer figures. El seu percentatge d'eficiència és baixíssim 28,57 % i a més a més presenta el problema que confon moltes imatges. Un cop més hem decidit representar la gràfica (veure Fig. 62) de tots els valors presents a la base de dades per trobar-hi explicació tot i que a priori ja podem imaginar quin serà el resultat.

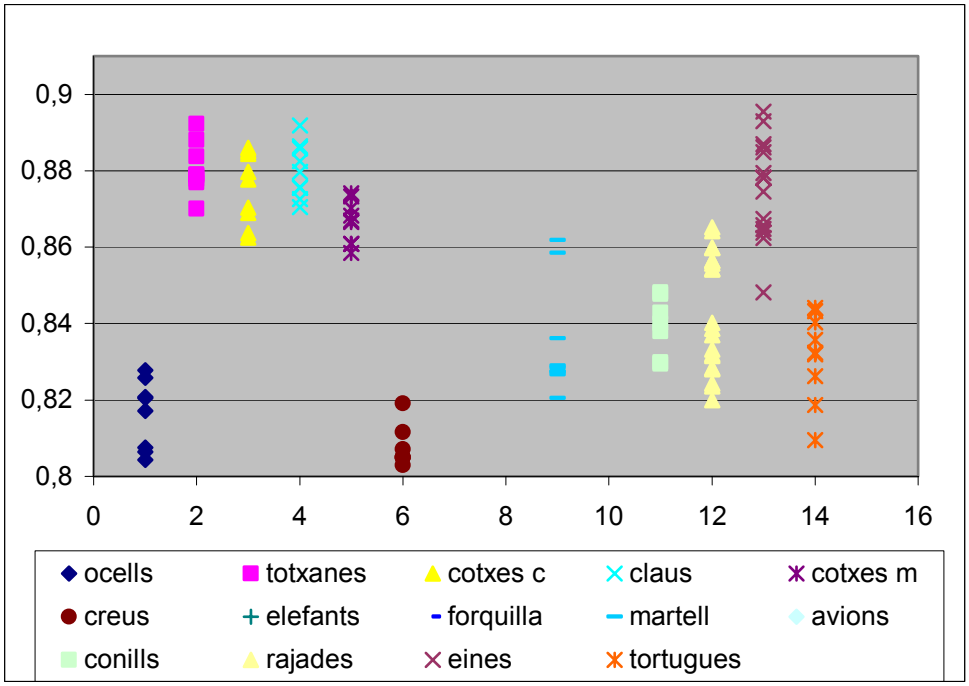

Fig. 62 – Representació del descriptor únic FF a l'eix Y per cada tipus d'imatge sintètica

Com era d'esperar el problema és que el fet de tenir tants tipus d'imatges fa que n'hi hagi molts que es sobreposin creant tanta confusió al sistema que fa el mètode del tot ineficient. És a dir diferents objectes obtenen el mateix descriptor únic. Fent aquesta mena de representacions tenim potser una millor manera de veure a priori com pot funcionar el descriptor únic que no pas evaluant-lo fent taules de confusió. Fent-ho així si veiem que les imatges queden prou separades podem pràcticament assegurar que el mètode funcionarà correctament. En aquest cas concret si en comptes de tenir tants tipus d'imatges només en tinguéssim 3, com són les totxanes ,les creus i els conills també obtindríem uns resultats molt i molt bons pel fet de no coincidir els rangs de valors.

Perquè el descriptor únic doni bons resultats cal tenir pocs tipus d'imatges i a més a més que aquests grups siguin molt diferents entres si. Cal també, que cada grup contingui imatges força similars.

Per entendre el problema imaginem que tenim una figura que és una estrella. Si totes les estrelles presenten el mateix número de punxes els valors del descriptor únic seran molt propers entre sí. Però en canvi si podem tenir estrelles de 3, 5, 8 punxes, és quan els valors es dispersen. Nosaltres considerem que tot són estrelles, però des d'un punt de vista estrictament geomètric són figures diferents i per aquest motiu tenim tant dispersió de valors.

7.3.1.4 Imatges mamogràfiques

Aquestes són les imatges d'interès en el nostre estudi, i abans d'entrar en els resultats obtinguts cal tenir en compte que tant el reconeixement com la classificació d'aquestes imatges representa un problema realment difícil. És tant difícil que la seva classificació fins i tot es fa difícil per una persona que no sigui un expert com un oncòleg. L'altre inconvenient que presenten és que la segmentació ens ha proporcionat unes imatges amb uns contorns molt irregulars. Un cop assenyalada la dificultat que presenten aquest tipus d'imatges anem a veuren els resultats:

MÈTODE: Fourier
SIGNATURA: Coordenada Complexe
1024 mostres → 1024 descriptors

	100			
		66,6	33,3	
		33,3	33,3	33,3
		33,3		66,6

eficiència = 66,6 %

MÈTODE: Fourier
SIGNATURA: Coordenada Complexe
Descriptor únic de 1024 mostres

	100			
		66,6		33
		33,3	66,6	
		66,6		33,3

eficiència = 66.6 %

MÈTODE: Fourier
SIGNATURA: Distància al centre
1024 mostres → 512 descriptors

	100			
		66,6	33,3	
		66,6		33,3
		33,3		66,6

Eficiència = 58,3 %

Seguint la mateixa dinàmica, el descriptor únic és el que pitjors resultats dóna. En aquest cas és degut al fet que tot i tenir poques imatges a classificar les irregularitats del contorn fan que totes les imatges es vegin com figures molt irregulars sense una forma dominant.

El principal problema el tenim amb les imatges microlobulades. Aquestes tot i presentar formes arrodonides, tenen protuberàncies que surten de la massa. Aquesta terrible combinació fa que estiguin entre mig de tots els tipus. Tant de les arrodonides com poden ser les lobulades o ovalades, com de les espiculars.

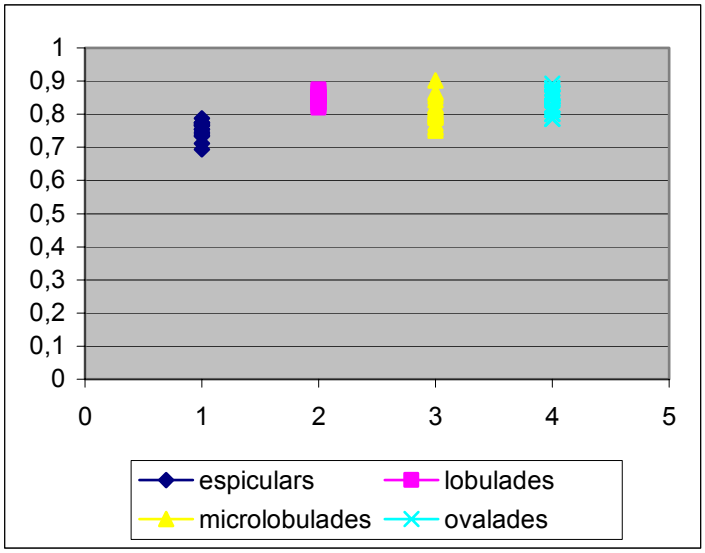

Fig. 63 – Representació del descriptor únic FF a l'eix Y per cada tipus d'imatge mamogràfica

Els altres dos mètodes coordenada complexe i distància al centre presenten la mateixa eficiència. No tenen cap problema per reconèixer lesions espiculars, però en canvi, com era d'esperar tenen el problema que confonen els tres grups de masses més o menys arrodonides.

Si amb aquests resultats haguéssim d'optar per un mètode optaríem pel mètode de Fourier basat en la distància al centre. Tot i tenir un percentatge d'encerts igual, té l'avantatge que els descriptors ocupen menys espai i com que la velocitat és proporcional al totals de descriptors utilitzat, també guanyem velocitat.

7.3.2 CBIR

Per fer la classificació basada en el contingut hem utilitzat dues mesures àmpliament esteses com són la precision i el recall. D'aquesta manera podem representar els resultats gràficament fent-los més amens a l'hora de ser analitzats.

- La precision P es defineix com el total d'imatges correctament retornades respecte un total N d'imatges.
- El recall R es defineix com el total d'imatges correctament retornades respecte el total d'imatges que hi ha d'aquell tipus a la base de dades.

La precision s'expressa a l'eix Y, i el recall a l'eix X. Fent-ho així podem saber amb quina precisió el nostre sistema és capaç de retornar 1, 2,... N imatges correctes. L'ideal seria que quan es pregunta per una imatge en concret, el sistema retornés com a primers resultats totes les imatges del mateix tipus, i a continuació les que s'assemblen menys. Això faria que sempre tinguéssim una precisió del 100%. La realitat però, és que com més imatges semblants a la nostra volem, pitjors són els resultats, fet que provoca que la precisió disminueixi. Per tal que aquestes mesures puguin ser avaluades de manera objectiva, s'expressen els resultats en forma de percentatge.

A continuació mostrem quins han estat els resultats pels diferents grups d'imatges utilitzant els descriptors avançats de manera exclusiva. La manera com mostrarem els resultats, serà la mateixa per cada classe d'imatges. Primer presentem com es comporta la classificació per cada tipus d'imatges en funció de si fem coordenada complexe, distància al centre, o descriptor únic. I finalment fem una gràfica per cada classe on es mostra com funcien els tres mètodes per cada classe.

7.3.2.5 Imatges Geomètriques

A partir dels resultats obtinguts podem respresentar quatre gràfiques que seran les que anirem representant per cada classe d'imatges.

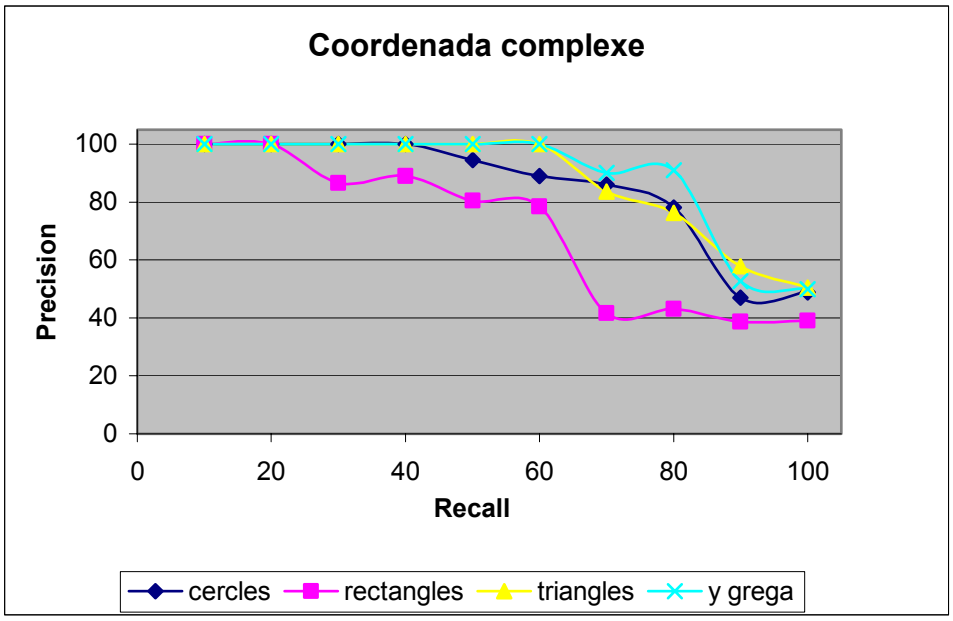

Fig. 64 – Resultats obtinguts d'aplicar Fourier utilitzant coordenada complexe a partir d'un total de 512 descriptors de Fourier

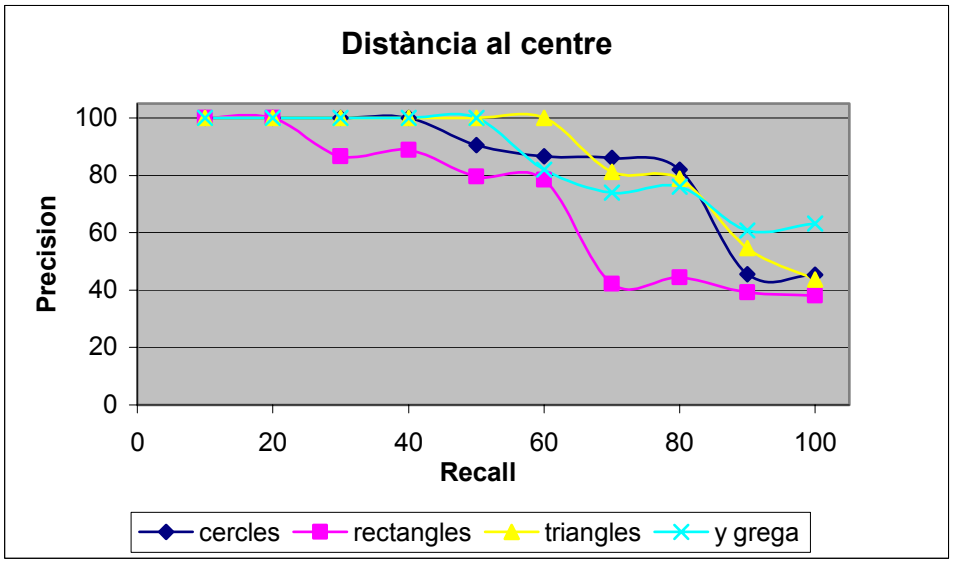

Fig. 65 – Resultats obtinguts d'aplicar Fourier utilitzant distància respecte el centre a partir d'un total de 256 descriptors de Fourier

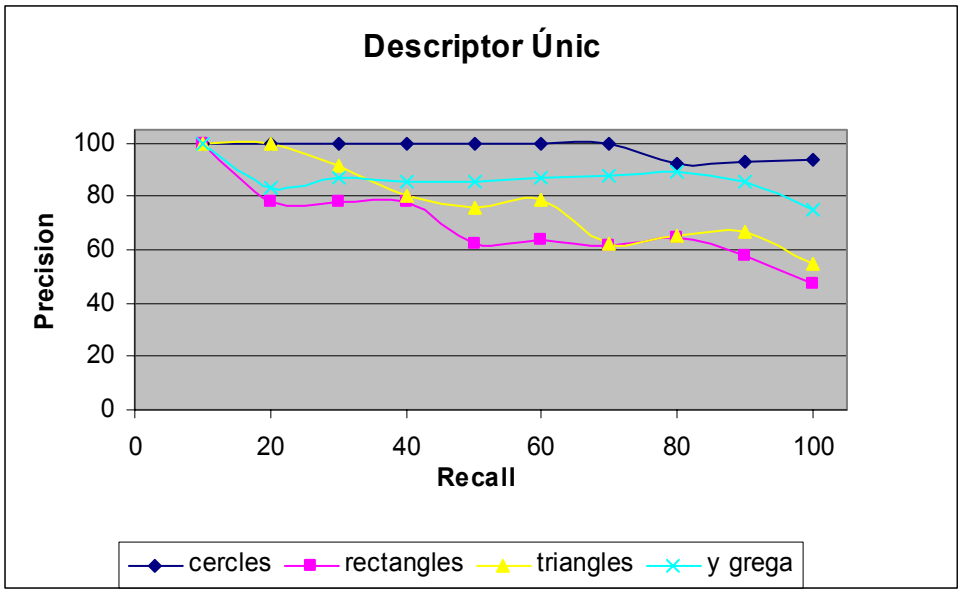

Fig. 66 – Resultats obtinguts a partir del descriptor únic calculat utilitzant 512 descriptors de Fourier

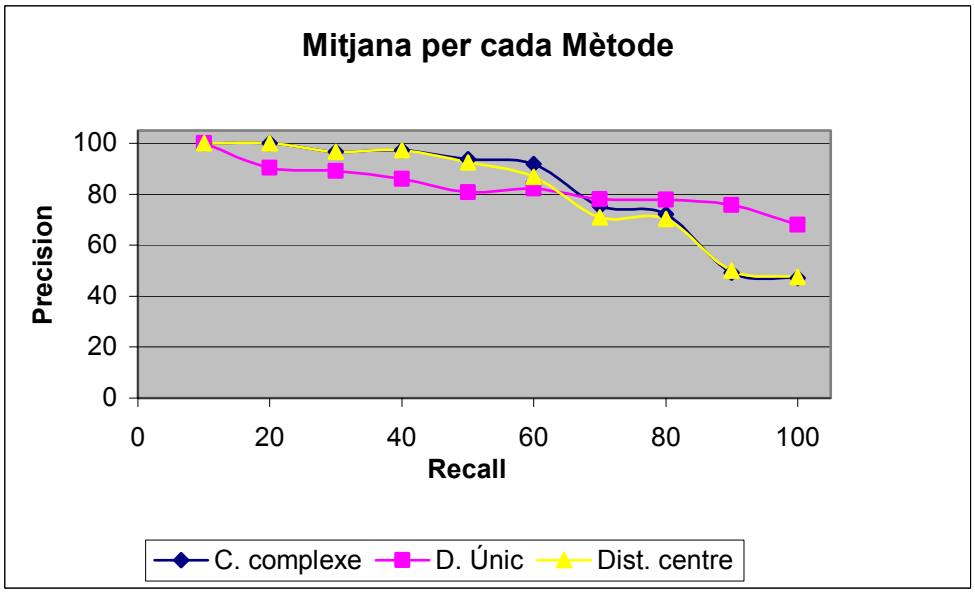

Fig. 67 – Resultat que dóna cada mètode per la classe d'imatges geomètriques

Tal i com es pot observar a les Fig. 64, Fig. 65 i Fig. 66 els rectangles són les figures que més costen de classificar. Tot i així fins al 60 % d'imatges els resultats són similars amb els tres mètodes. També és destacable el fet que les lletres Y siguin les figures que tot i no tenir sempre la millor precisió, siguin les figures a les quals la precisió decreix més lentament a les tres variants.

Curiosament a partir del recall del 60% la precisió del descriptor únic és més constant i millor que no pas utilitzant els altres mètodes, tal i com es pot veure a la Fig. 67. A la mateixa figura podem observar que globalment tant la coordenada complexe com la distància al centre presenten resultats molt similars, potser una mica millors utilitzant

coordenada complexe. En canvi el que queda clar és que el descriptor únic és pitjor que els altres dos fins el 70% de les imatges. A partir d'aquest punt el descriptor únic manté una precisió constant en detriment dels altres dos.

7.3.2.6 Imatges Sintètiques

En aquest cas les gràfiques surten més enrabessades per la quantita d'elements que presenta la classe, tot i així en podem extreure conclusions de manera més ràpida que no pas utilitzant directament les taules de valors que ens les han proporcionat.

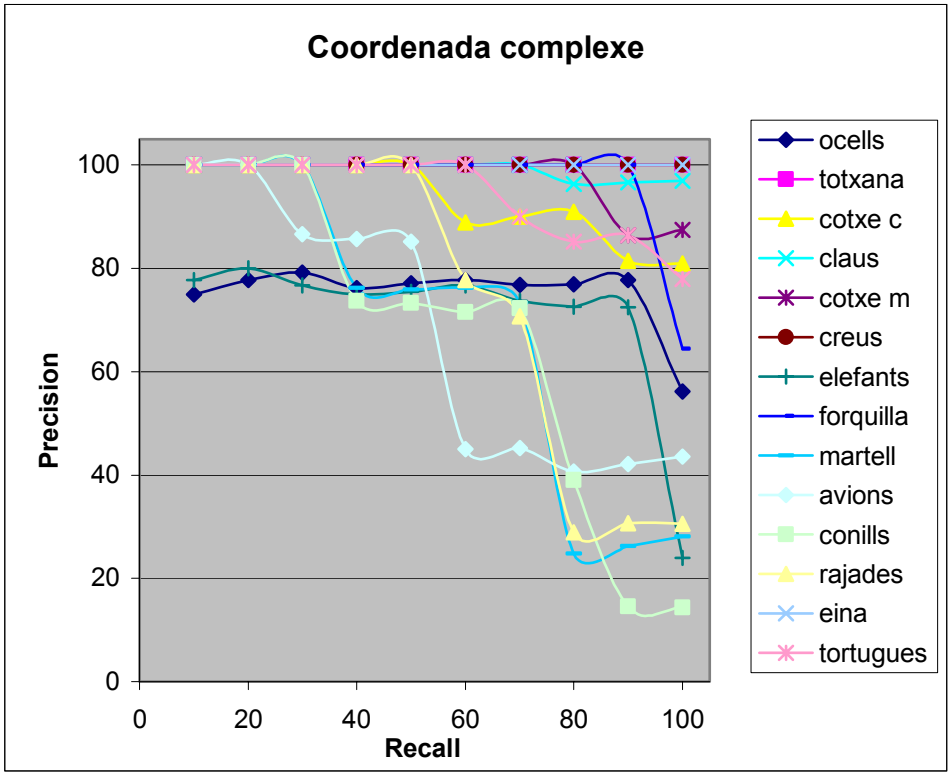

Fig. 68 – Resultats obtinguts d'aplicar coordenada complexe utilitzant 512 descriptors de Fourier

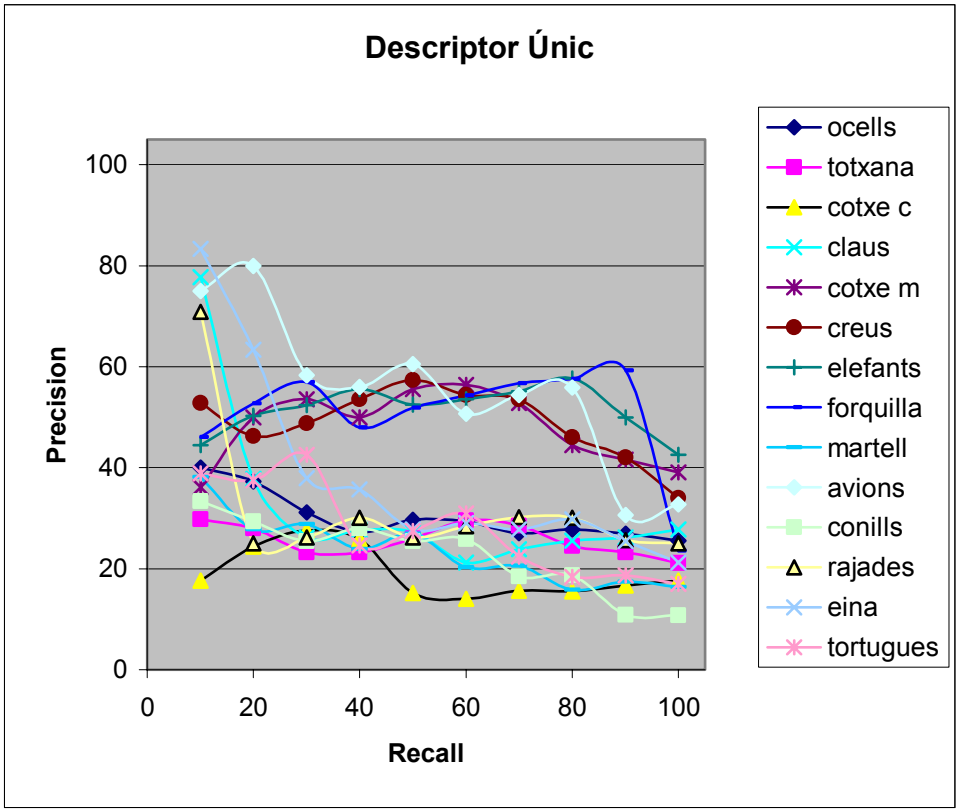

Fig. 69 – Resultats obtinguts a partir del descriptor únic calculat a partir de 512 mostres

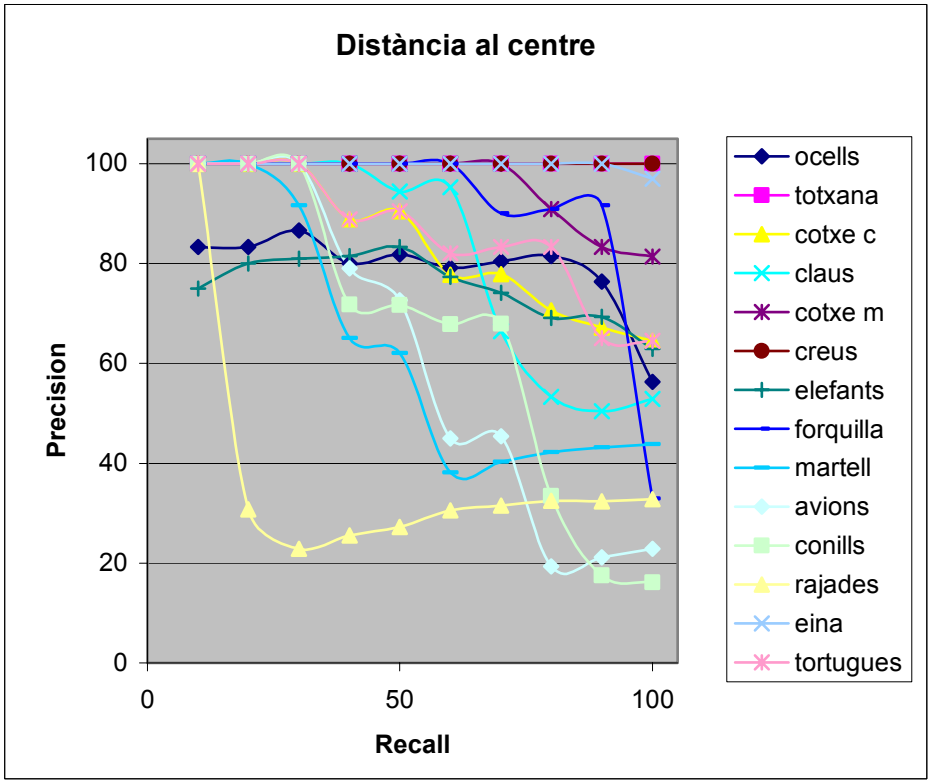

Fig. 70 – Resultats obtinguts de calcular 256 descriptors utilizant distància al centre

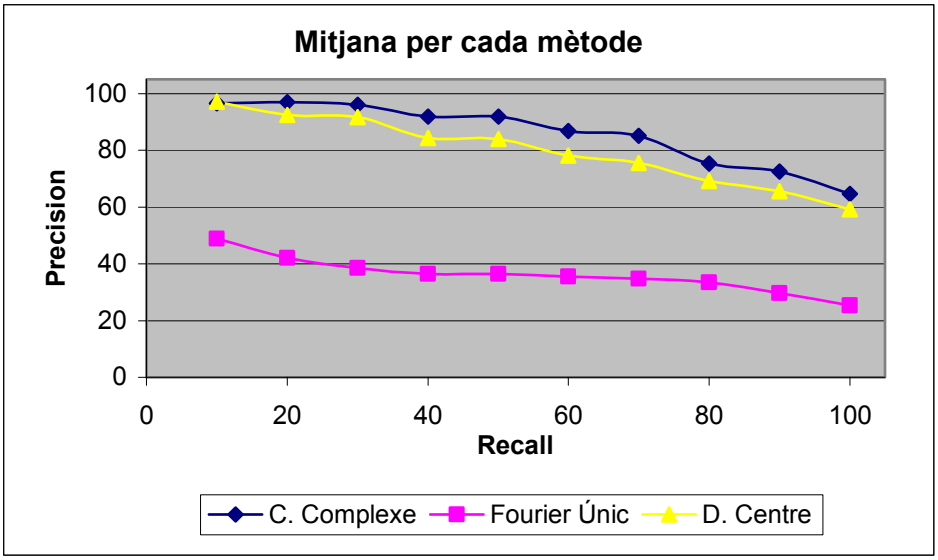

Fig. 71 – Resultat que dóna cada mètode per la classe d'imatges sintètiques

Tot i la gran quantitat de valors que presenten les gràfiques de cada mètode els resultats globals són molt clars. El millor mètode és fer Fourier utilitzant Coordenada complexe. El descriptor únic dóna uns resultats molt dolents en què la precisió comença essent del 50% i va disminuint fins arribar a ser pràcticament del 20 %. Menció especial es mereix el grup d'imatges que són rajades. Aquestes figures són molt mal classificades utilitzant coordenada complexe. En cas que aquest grup no existís els resultats probablement serien equiparables tant amb coordenada complexe com amb distància respecte el centre.

7.3.2.7 Imatges Mamogràfiques

Ja hem vist que els resultats que hem obtingut a l'hora de fer reconeixement no eren massa esperançadors, itentarem veure quins són els resultats que obtenim de fer CBIR:

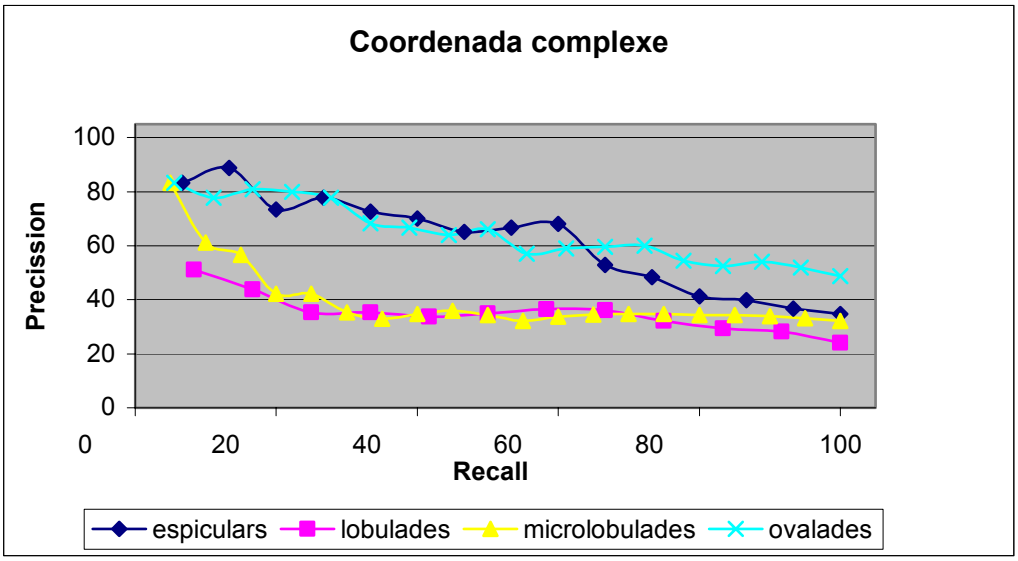

Fig. 72 – Resultats obtinguts utilitzant signatura de coordenada complexe i un total de 1024 descriptors de Fourier

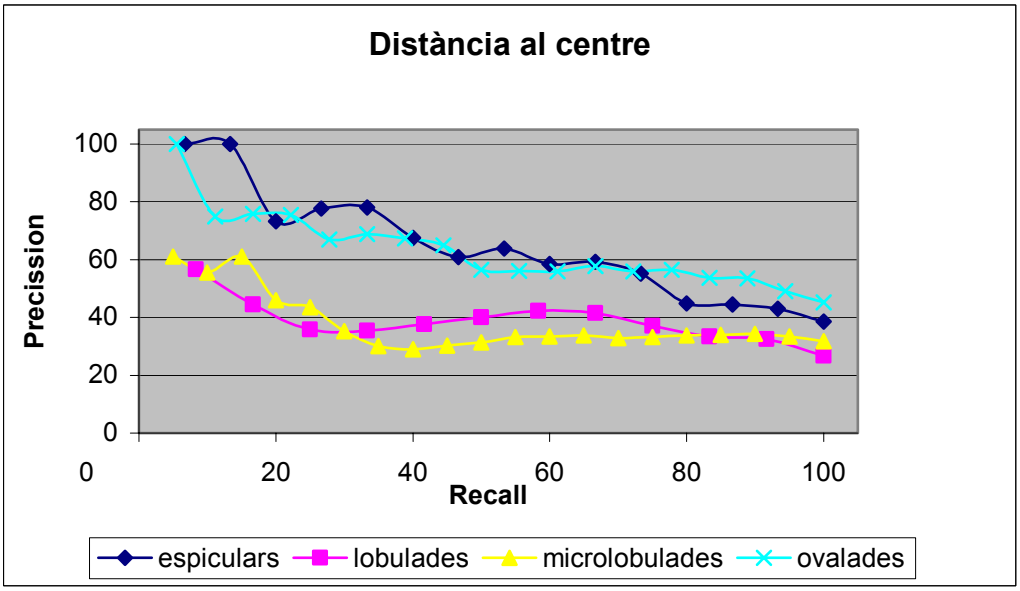

Fig. 73 – Resultats obtinguts utilitzant signatura respecte distància al centre i un total de 512 descriptors de Fourier

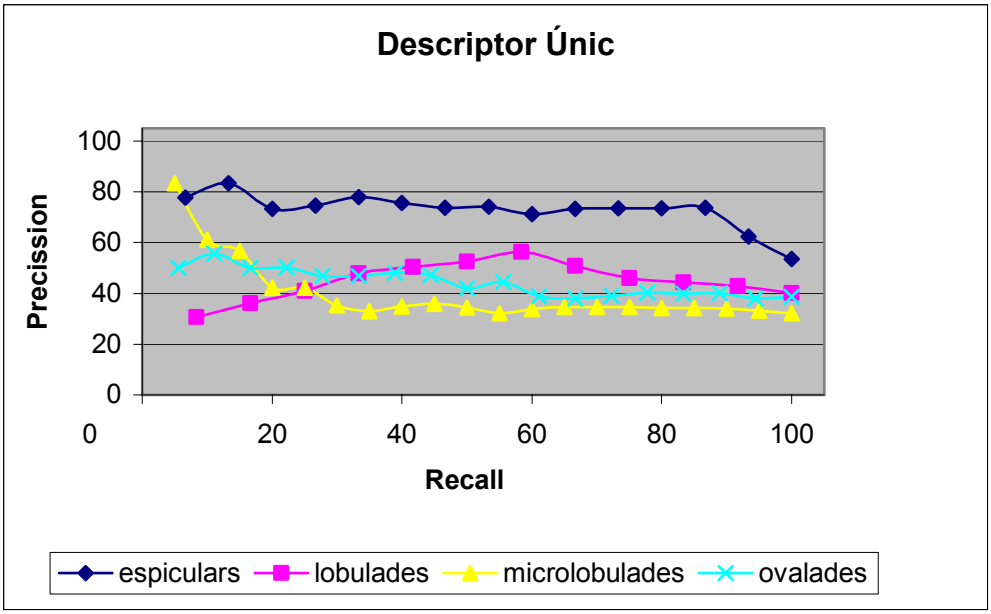

Fig. 74 – Resultats obtinguts a partir del descriptor únic calculat a partir de 1024 mostres

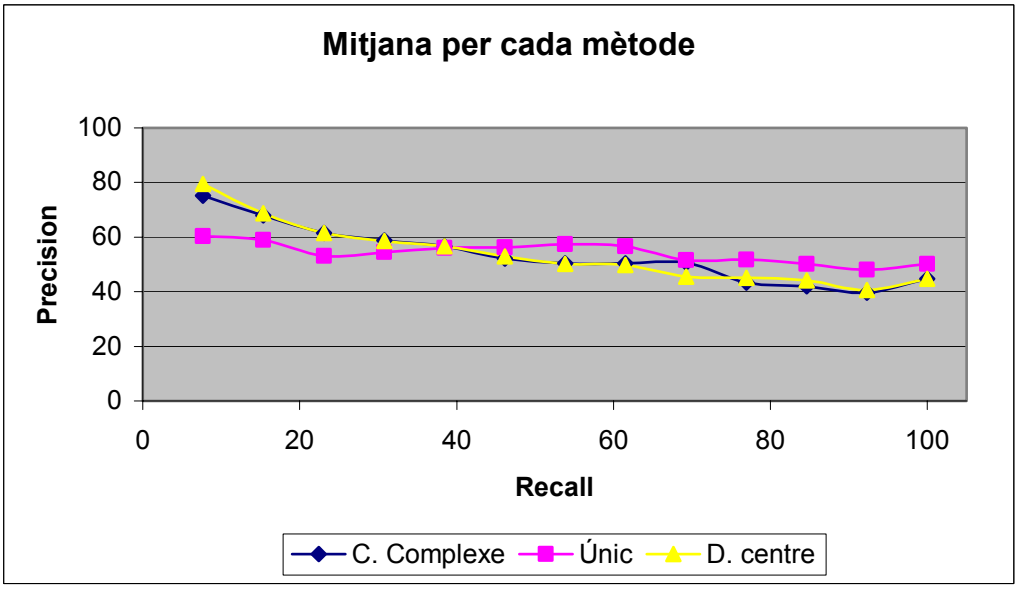

Fig. 75 – Resultats que dóna cada mètode per la classe d'imatges mamogràfiques

Malauradament aquesta classe d'imatges és la que uns resultats més indecisos ens dóna pel fet que no es pronostica un mètode clarament millor que els altres de manera general. A la Fig. 75, podem observar que fins i tot el descriptor únic proporciona uns resultats similars als altres dos mètodes, que a mesura que augmenta el recall van esdevenint millors que els altres.

Si ens fixem amb les gràfica de coordenada complexe i distància al centre a les Fig. 72 i Fig. 73 respectivament, les millors precisions s'obtenen quan es reconeixen imatges espiculars i imatges ovalades. Aquest resultats són lògics per ser les imatge amb una

classificació més clara. Encanvi les lobulades i microlobulades que són un entremig entre les espiculars i les lobulades són més difícils de reconèixer per aquests mètodes.
Sorprenentment al que era d'esperar, acaba essent el descriptor únic el que millor reconeix els diferents tipus de masses, mantenint una precisió casi constant.

En aquest cas en vistes de l'èxit que ha tingut el descriptor únic i com que els altres dos mètodes donen pràcticament els resultats, proposaria que la millor manera de reconèixer figures podria ser utilitzar una combinació entre el descriptor únic obtingut a partir de la signatura de la coordenada complexe, i de la distància al centre. Per dir aquesta afirmació apart dels resultats em baso amb termes d'eficiència ja que utilitzant distància respecte el centre sempre obtenim la meitat de descriptors que no pas utilitzant coordenada complexe amb el mateix nombre de mostres. I a partir del 40% donaria més importància al descriptor únic que a més a més té la virtud que ens dóna els resultat ràpidament perquè per comparar dues figures només compara dos valors per adjudicar un veredicte. Evidenment és imprescindible testejar amb un conjunt més ampli d'imatges.Tot i així estaria molt bé testejar amb més imatges i més probes la base de dades per assegurar que els resultats obtinguts són realment correctes.

8 CONCLUSIONS I TREBALLS FUTURS

8.1 CONCLUSIONS

Durant aquest projecte s'ha desenvolupat una aplicació específica per analitzar descriptors de forma. S'ha desenvolupat una aplicació on la integració de nous mètodes d'extracció de característiques (ja siguin de forma o textura), es pogués realitzar de forma senzilla.

S'han implementat diferents propostes per tal de acomplir amb els objectius. En primer lloc s'han considerat diferents descriptors bàsics de forma, i seguidament s'han implementat descriptors invariants a translació rotació i escalat. Concretment, s'han considerat 4 mètodes que compleixen aquestes propietats (i) Mètode de chang, (ii) mètode de fourier amb coordenades complexes, (iii) mètode de fourier amb distàncies al centre (iv) mètode del descriptor únic de fourier.

Tots aquests mèodes s'han testejat tenint en compte diferents tipus de figures, ja siguin figures de lesions mamogràfiques, figures sintètiques i figures geomètriques, tot i que l'objectiu principal era analitzar-ne el comportament per les lesions que poden apareixer en imatges mamogràfiques. Per tal d'avaluar els mètodes s'han desenvolupat dos sistemes:

- un sistema CBIR que permet donada una imatge amb una determinada figura, recuperar altres imatges que continguin figures similiars.
- un sistema de classificació que permet classificar una imatge que conté un objecte.

Cal notar que no hi ha un mètode clarament millor. De manera general els millors resultats s'obtenen aplicant distància al centre. Tot i així la distància al centre té uns resultat aproximats i té l'aventatge que treballa amb la meitat d'infomració. Potser seria interessant treballar amb distància al centre per l'eficiència en velocitat que això suposaria. Tot i la millora que poguéssim obtenir també és cert que els resultats de fer-ho amb distància al centre han estat pràcticament idèntics per les mamografies, donant molt bons resultat el descriptor únic, que fins llavors no havia funcionat gaire bé.

Finalment doncs, podem dir que els objectius marcats a l'inici del PFC han estat complerts. I més que proporcionar un mètode millor que els altres seria interessant afegir a HRIMAC la combinació del descriptor únic amb la coordenada complexe per ser els més ràpids i que millors resultats donen.

8.2 TREBALLS FUTURS

Són moltes i diverses les preguntes que ens hem anat fent mentres desenvolupavem aquest projecte. A algunes les hi hem pogut trobar resposta i d'altres han quedat al tinter, els treballs futurs podrien ser

- Molts dels descriptors bàsics utilitzen la informació extreta a partir del mínim rectangle envolvent. Aquest, presenta el problema que no s'adapta a la figura analitzada. Si es pogués extreure el mínim rectangle tal i com mostre la fiugra, segurament podríem obtenir millors resultats quan utilitzéssim els descriptors bàsics.

- Es podria intentar millorar el mètode de Chang extreient els PMC utilitzant altres mètodes. Tot i que l'algorisme SUSAN dóna resultats força acceptables potser si treballéssim amb un fitre de Sobel que la seva màscara fos més gran obtindríem millors resultats. Quan es diu sobel també volem dir Prewit..., bàsicament filtres basats en el gradient.

- A nivell de descriptors de Fourier podríem provar d'extreure els descriptors tal i com ho fem ara però a l'hora de guardar-los, no ser tant exigent i només quedar-nos amb els N primers descriptors. Com ja s'ha dit perdríem detalls de la figura, però potser ens aportarien una millor aproximació de la imatge pel fet de prescindir d'informació que tot i aportar-nos detalls, són detalls que són diferents a cada imatge. Encanvi la forma genèrica, segurament ja seria captada amb els N primers descriptors. En cas de decidir tirar aquesta opció endavant cadria estudiar quin seria el valor correcte de N per cada imatge.

- Buscar altres signatures que permetin agrupar els descriptors en un descriptor únic, intentant buscar un altre valor de descriptor únic millor que el que ara tenim.

- Per fer tant reconeixement com CBIR podríem testejar més el funcionament de les diferents signatures dels descriptors de fourier per buscar quina seria la millor combinació de resultats entre descriptors.

- Afegir nous descriptors de forma amb la mateixa finalitat que els actuals o amb altres finalitats com pot ser poder reconèixer un mateix objecte independenment de la perspectiva o de si està parcialment ocult.

- Dotar l'aplicació de la possibilitat de poder treballar amb imatges que continguin múltiples figures. En l'àmbit mèdic podria ser interessant per fer classificació de microcalcificacions.

- Permetre que no sempre calgui tenir el mateix nombre de descriptors de Fourier per comparar dues imatges. Es podria fer que mentres la imatges estigués correctament mostrejada, quan es volguéssin comparar imatges amb diferent nombre de descriptors de fourier es busquéssin les mostres que falten amb alguna tècnica d'interpolació.

- Dotar l'aplicació de la possibilitat de treballar amb imatges tinguent en compte la resolució d'aquesta. No caldria escalar les imatges.

- Mètode d'aprenentatge automàtic, imposant un llindar a partir del qual es pot considerar que una imatge no s'assembla a res i per tant és nova i si es volgués que es pogués afegir a la base de dades per reconèixer-la en cas que es preguntés per imatges semblants.

9 REFERÈNCIES

[1] B. Aguirre. *Screening mamario.* Revista Chilena de Radiología. Volum 5 (4)

[2] D. Raba. *Interfície web per HRIMAC (Herramienta de Recuperación de Imágenes Mamográficas por Análisis de Contenido) basat en tècniques de relevance feedback.* PFC 2003. Enginyeria Informàtica. UdG.

[3] A. Bosch. *Anàlisi disseny i implementació d'algorismes de caracterització i similitud per HRIMAC (Herramienta de Recuperación de Imágenes Mamográficas por Análisis de Contenido).* PFC 2003. Enginyeria Informàtica.UdG.

[4] J. Espunya. *Segmentació d'imatges mamogràfiques.* PFC 2003. Enginyeria Tècnica en Informàtica de Sistemes. UdG.

[5] P. Planiol. *Desenvolupament d'un sistema d'anàlisi d'imatges mamogràfiques mitjançant tècniques de visió per computador*. Enginyeria Informàtica. PFC 2000. UdG

[6] M. Blanch. *Detecció automàtica de microcalcificacions i grups de microcalcificacions a partir de l'anàlisi de les imatges mamogràfiques.* PFC 2004. UdG

[7] Lori Mann Bruce, Reza R. Adhami, *Classifying Mammographic Mass Shapes Using the Wavelet Transform Modulus-Maxima Method*. IEEE Transactions on medical imaging, vol. 18, no. 12, December 1999

[8] S. A. Feig and R. McLelland, *Breast Carcinoma: Current Diagnosis and Treatment*. New York: Masson, 1983.

[9] L. V. Ackerman and E. E. Gose, *Breast lesion classification by computer and xeroradiograph*, *Cancer*, vol. 30, no. 10, pp. 1025–1035, 1971.

[10] C. C. Chang, S. M. Hwang and D. J. Buehrer, *A shape recognition scheme based on relative distances of feature points from the centroid*, Pattern Recognition 24, 1053-1063. 1991

[11] Liang Shen, Rangaraj M. Rangayyan, and J. El Leo Desautels, *Applicatioin of Shape Analysis to Mammographic Calcifications*. IEEE Transactions on medica imagint, vol. 13, no. 2, June 1994

[12] Dengsheng Zhang, Guojun Lu, *A comparison of shape retrieval using fourier descriptors and short-time fourier descriptors*, In Proc. of The Second IEEE Pacific-Rim Conference on Multimedia (PCM01), pp.855-860, Beijing, China, October, 2001

[13] Dengsheng Zhang, Guojun Lu, *A comparative Study on Shape Retrieval Using Fourier Descriptors with Different Shape Signatures*, In Proc. of International Conference on Intelligent Multimedia and Distance Education (ICIMADE01), pp.1-9, Fargo, ND, USA, June 2001.

[14] Peter J. Van Otterloo. *A contour-Oriented Approach to Shape Analysis*. Prentice Hall International (UK) Ltd. C1991

[15] S.M. Smith and J.M. Brady. *SUSAN - a new approach to low level image processing*. International Journal of Computer Vision, 23(1):45-78, May 1997.

[16] Dengsheng Zhang and Guojun Lu, *A Comparative Study of Fourier Descriptors for Shape Representation and Retrieval*, In Proc. of the Fifth Asian Conference on Computer Vision (ACCV02), pp.646-651, Melbourne, Australia, January , 2002

ANNEX A

L'APLICACIÓ

Amb l'aplicació podem realitzar les següents funcions:

- Calcular els descriptors Bàsics
- Calcular els descriptors de Chang
- Calcular els descriptors de Fourier per Coordenada complexe
- Calcular els descriptors de Fourier per Distància al centre
- Calcular el descriptor Únic
- Extreure contorns
- Binaritzar imatges

L'aspecte de l'aplicació és el que mostra la Fig. 76. Com es pot veure, el programa es divideix en 4 seccions:

1) Sortida de resultats

Es mostren els resultats d'aplicar un mètode en concret.

2) Zona de treball

L'aplicació permet obrir vàries imatges al mateix temps, totes les imatges que s'obren apareixen en aquesta zona de l'aplicació.

3) Menús i barres d'eines

Conté tots els menús desplegables amb els quals podem realitzar totes les funcions de què s'ha dotat l'aplicació. A sota hi trobem les barres d'eines, que conté les funcions més utilitzades per tal de tenir-hi un ràpid accés. A la Fig. 77 es mostren els diferents menús de l'aplicació i es detalla quines funcions realitza cada botó.

4) Barra d'estat

En aquesta barra s'hi reflecteix el que està fent l'aplicació. Sempre és d'utilitat saber què està passant o què s'està fent mentre l'aplicació no dóna cap mena de resposta o senyal.

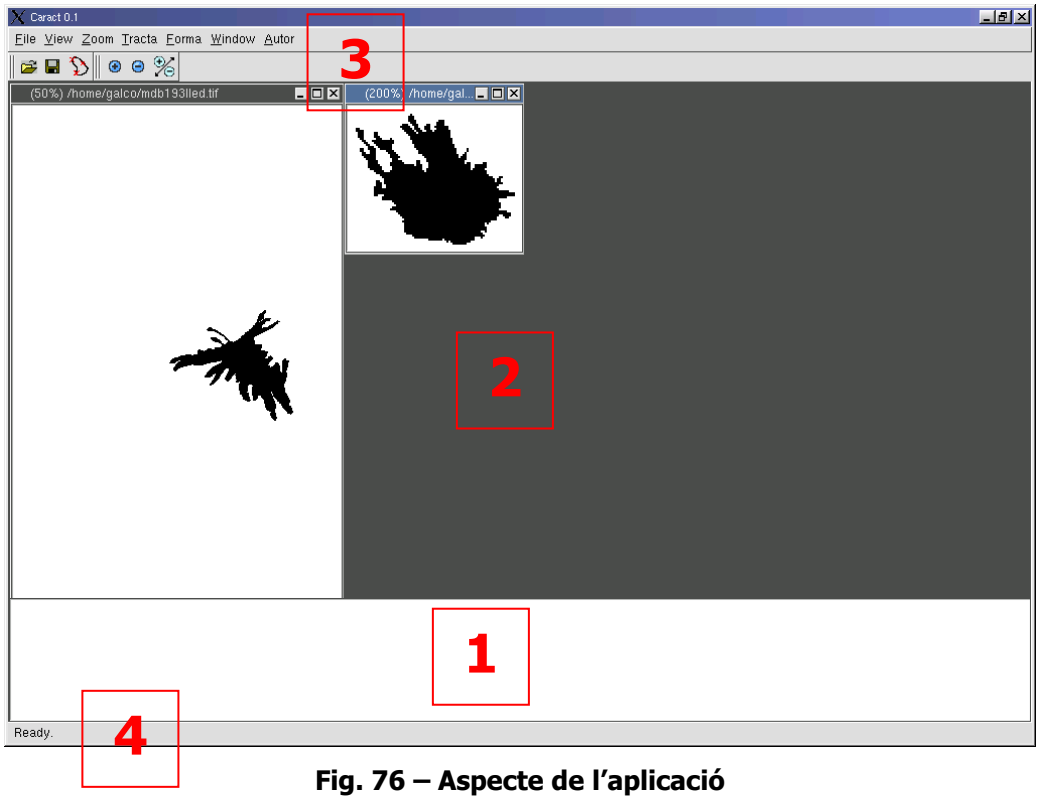

Fig. 76 – Aspecte de l'aplicació
1 – Sortida de resultats, 2 – Zona de treball
3 – Barres d'eines i menús del programa, 4 – Barra d'estat

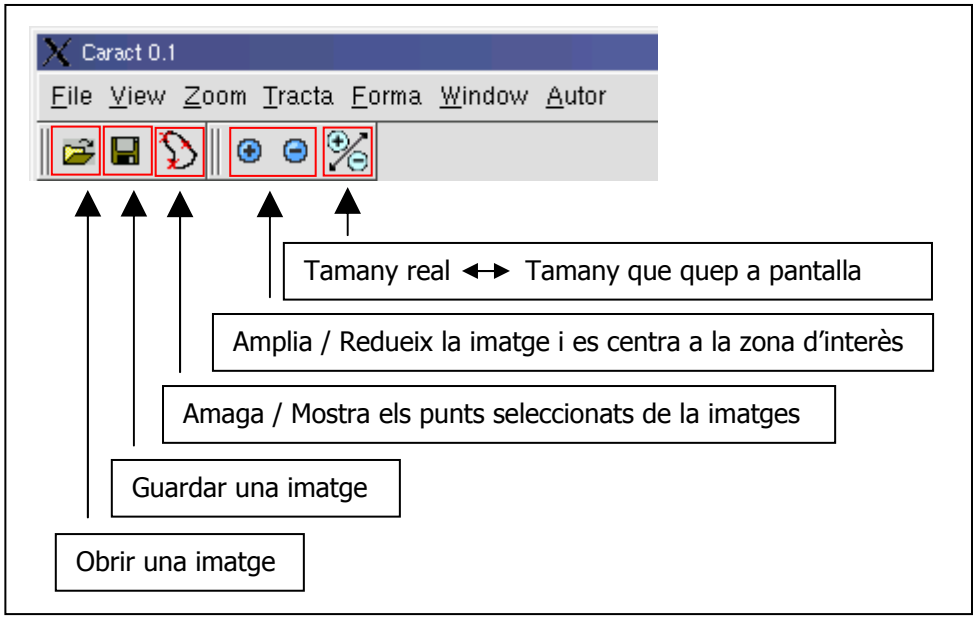

Fig. 77 – Detall dels menús i botons del programa

A continuació s'expliquen els diferents menús posant especial èmfasi en el menú Tracta i el menú Forma que contenen la part important relacionada amb l'extracció de forma. La manera de treballar d'aquests menús és aplicant les accions a la imatge activa. D'aquesta manera si en tenim vàries d'obertes els càlculs només es realitzarien sobre la imatge activa.

File

Totes les operacions relacionades amb el fitxer, obrir una imatge (.raw, .tif, .tiff, .dcm, .pgm, .dcm, .png i .bmp), guardar-la (.pgm), o bé sortir de l'aplicació.

View

Permet mostrar o amagar, la barra d'estat, la barra d'eines i la del zoom.

Zoom

Operacions que permeten ampliar o reduir la imatge, també accessibles des de la barra de menús. Quan s'utilitza el zoom, de manera trasnparent a l'usuari es va a buscar la zona d'interès on es trobi l'objecte i s'amplia exclusivament aquella zona.

Tracta

Conté opcions que en algun moment del procés, són utilitzades per obtenir alguna de les variants de descriptors. Són operacions que poden resultar interessants i s'ha decidit donar-hi un accés directe. Amb aquest menú podem, binaritzar imatges i extreure contorns d'imatges binaritzades que poden ser guardades per si més endavant ens interessen.

Forma

Per tal de calcular i consultar els diferents descriptors que podem extreur d'una imatge, hem construit dos diàlegs. Són el diàleg de Chang i el diàleg de Fourier. Des d'aquí es poden calcular els diferents descriptors d'una imatge. Els resultats obtinguts pels diàlegs són mostrats a la finestra de text situada a la part inferior de la pantalla. Passem a detallar les opcions dels dos diàlegs:

Diàleg de Chang

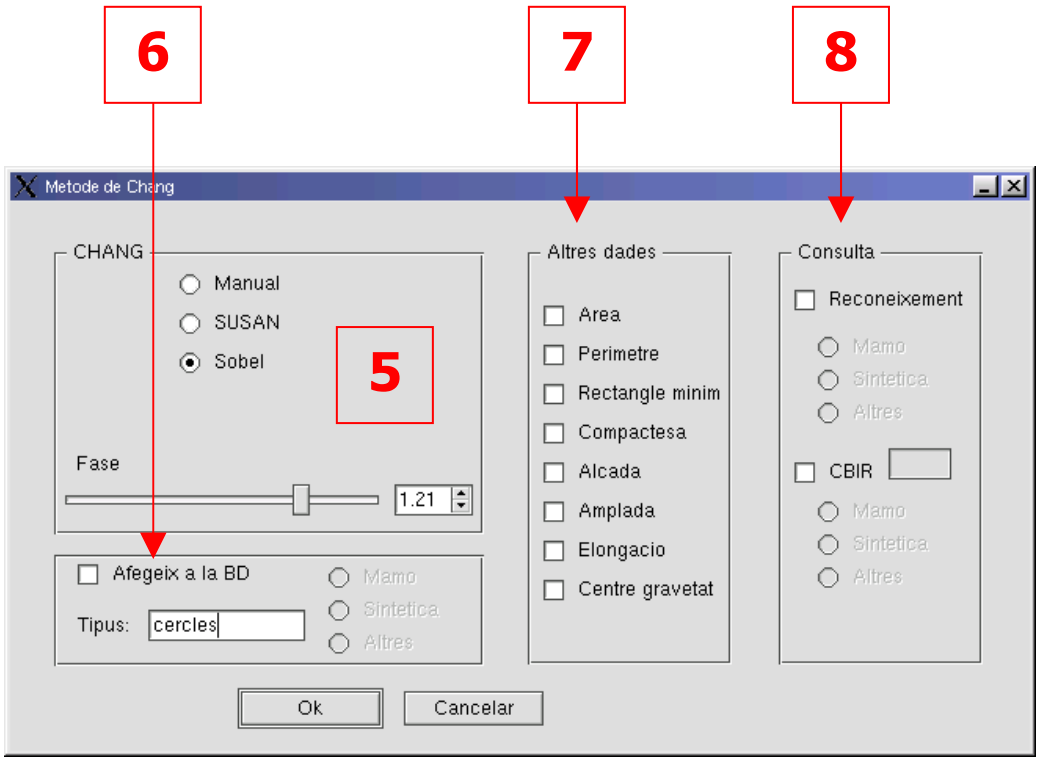

Fig. 78 – Aspecte del diàleg de Chang

Tal com s'indica a la Fig. 78, el diàleg de Chang s'estructura en quatre parts:

5) Chang

Conté les opcions per indicar com s'han de calcular els descriptors de Chang. Essencialment s'intervé en la forma de trobar els PMC. Es pot escollir entre fer-ho de forma manual, utilitzar l'algorisme SUSAN, o bé utilitzar el filtre de Sobel tot indicant el llindar a partir del qual es determinaran els PMC. Per seleccionar el llindar es disposa d'una barra de desplaçament que quan es mou selecciona els punts a la imatge instantàniament de manera que l'usuari pot veure quin és el llindar amb el qual el filtre dóna millors resultats. Per acabar de concretar es pot precisar amb l'incrementador de la dreta de la barra que permet augmentar o disminuir el llindar, amb augments de 10^{-2}.

6) Afegeix a la base de dades

Disposa de les opcions necessàries per tal d'afegir la figura tractada a la base de dades. L'usuari només ha d'explicitar de quin tipus de figura es tracta i també determinar quina classe d'imatge és. Les classes disponibles són mamografia, sintètiques o altres. I el

tipus classifica la imatge dins la classe. En el cas d'una mamografia els tipus possibles, són espicular, microlobulada, lobulada i oval.

Per defecte quan s'afegeix alguna imatge a la base de dades es calculen i s'afegeixen també, tots els descriptors bàsics, àrea, perímetre, rectangle mínim, compactesa, alçada, amplada, elongació i centre de gravetat.

Únicament es poden afegir a la base de dades els descriptors de Chang calculats a partir de SUSAN, per ser aquest mètode el que millors resultats dóna.

7) Altres dades

Permet que l'usuari seleccioni quins són els descriptors bàsics que es volen calcular.

8) Consulta

Conté les opcions relacionades amb les consultes a la base de dades. Es pot consultar de quin tipus és una imatge (Reconeixement), o bé es pot consultar quines són les imatges que més s'hi assemblen (CBIR). Tant per una opció com per l'altra cal indicar-li si es tracta d'una imatge sintètica, mamogràfica, o altres. Les consultes per CBIR, poden ser fetes seleccionant a més a més els descriptors bàsics que es cregui convenient.

Diàleg de fourier

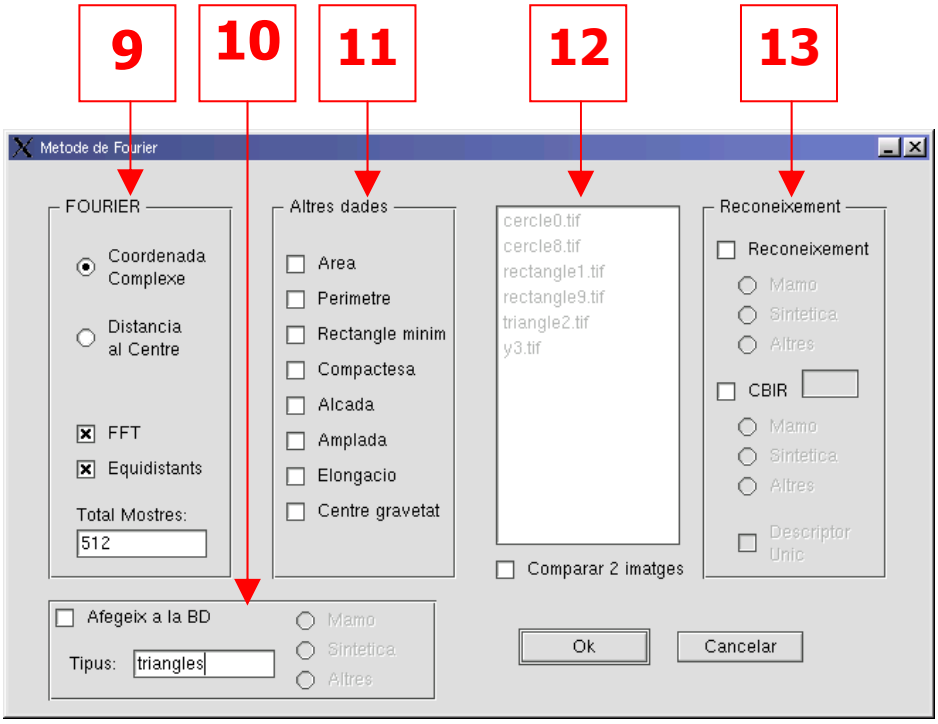

Fig. 79 – Diàleg de Fourier

El diàleg de Fourier es composa de 5 grups d'opcions, ressaltats en vermell a la Fig. 79:

9) Fourier

S'escull la signatura a partir de la qual es calcularan els descriptors de Fourier. Podem escollir entre coordenades complexes o distància respecte el centre, que només utilitza el mòdul.

Independentment de la signatura escollida per fer Fourier es pot optar per fer la transformada ràpida (FFT) o la transformada discreta de Fourier. Sempre que es faci la FFT cal entrar un nombre de mostres potència de 2 que seran les que s'extreuran de la imatge. Per defecte el programa calcula el mostreig al qual és recomenable calcular els descriptors de Fourier.

També hi ha l'opció de calcular la transformada sense considerar els punts equidistants, de manera que el que es faria seria calcular la transformada agafant com a input cada píxel del contorn.

10) Afegeix a la base de dades

Serveix per introduir els càlculs a la base de dades. Quan s'escull aquesta opció el programa només et deixa triar la signatura i el nombre de descriptors que es volen obtenir, tot i que per defecte ja et suggereix el nombre adequat de mostres que s'hauria d'agafar. L'el·lecció de la signatura només afecta a la sortida de pantalla, ja que quan introduïm dades es calculen i s'afegeixen les tres opcions possibles, coordenada complexe, distància al centre i descriptor únic, a més a més de tots els descriptors bàsics.

Per tal d'obtenir els millors resultats possibles únicament es poden entrar imatges mostrejades de manera equidistant i amb un número de mostres potència de dos que pugui ser computat per la FFT.

També cal escollir el tipus d'imatge i a quina classe pertany (sintètica, mamografia, altres). Per defecte crea el tipus a partir de la inicial del nom del fitxer, però és una cadena de caràcters que l'usuari pot canviar sempre i quan posi el mateix nom per totes les imatges d'un mateix tipus

11) Altres dades

Aquí s'escullen els descriptors bàsics (àrea, perímetre, mínim rectangle, compactesa, amplada, alçada, elongació i centre de gravetat) que es volen calcular. Per defecte no se'n calcula cap, a no ser que l'usuari indiqui el contrari.

12) Comparar 2 imatges

Aquest diàleg està pensat per veure com s'assemblen dues imatges. Com més proper a 0 sigui el resultat més s'assemblen. Per tal de fer comparacions cal seleccionar el checkbox i escollir a la llista que es mostra, les dues imatges que es volen comparar. Per pdoer comparar és imprescindible tenir el mateix nombre de descriptors tant d'una imatge com de l'altre, però no ens hem de preocupar d'aquest punt perquè es fa de forma automàtica, tot i que si es vol es pot canviar el nombre de mostres a agafar.

13) Reconeixement:

Aquest és l'apartat de fer consultes. Igual que amb Chang es poden fer tant consultes per contingut (CBIR), com reconeixement d'imatges. La filosofia de treball, és la de sempre, la imatge consultada serà la que estava activa quan s'ha obert el diàleg.

Per fer reconeixement s'utilitzen exclusivament els descriptors de Fourier (coordenada complexe, distància al centre, descriptor únic), però per fer CBIR és possible enriquir la cerca utilitzant els descriptors bàsics.

ANNEX B

IMATGES GEOMÈTRIQUES

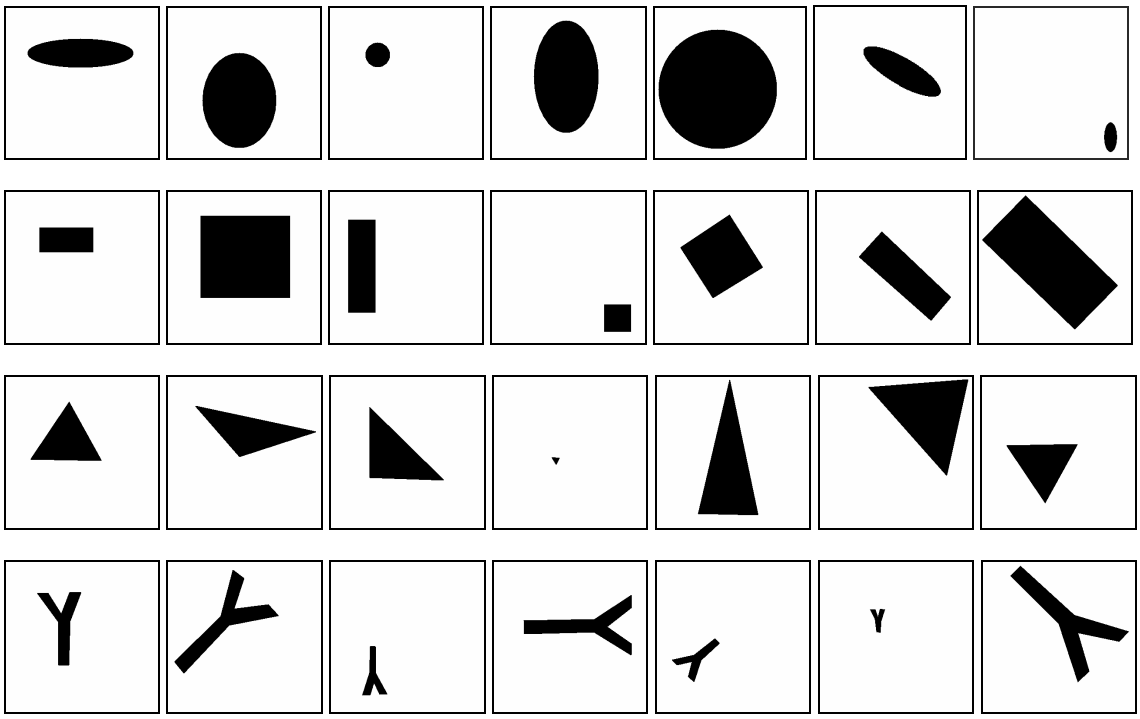

IMATGES SINTÈTIQUES

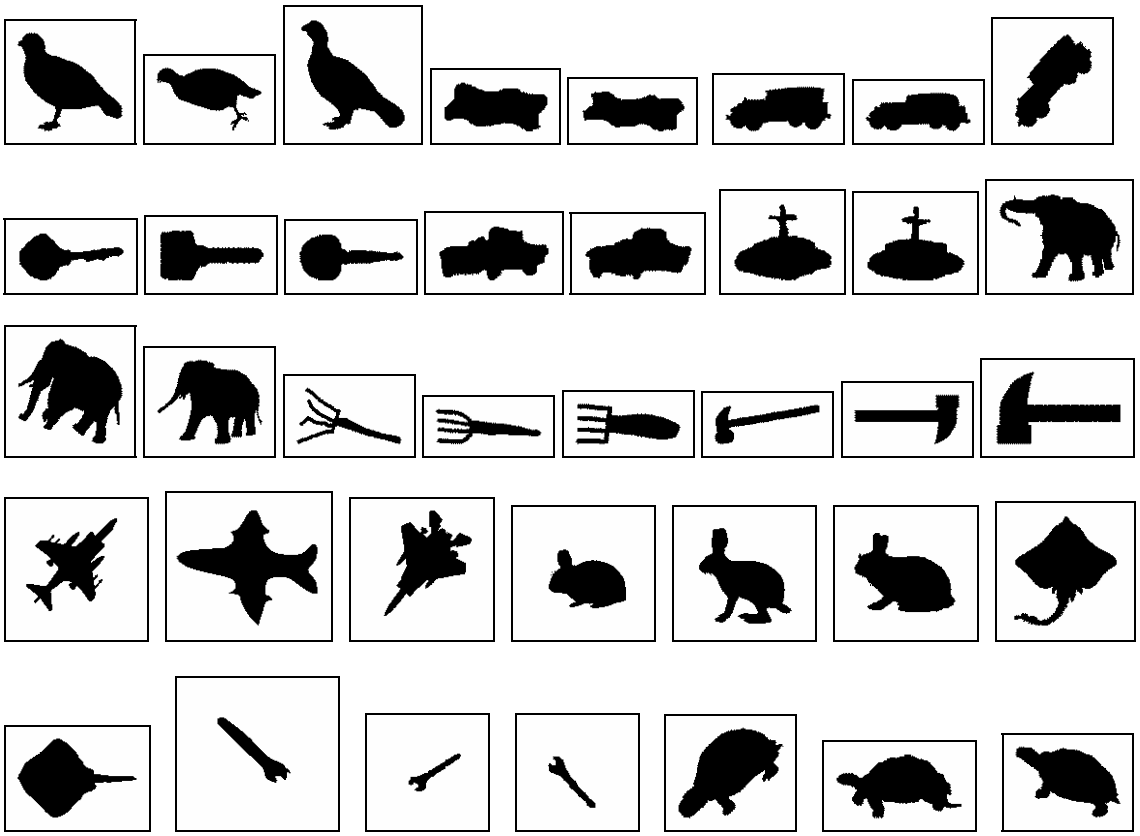
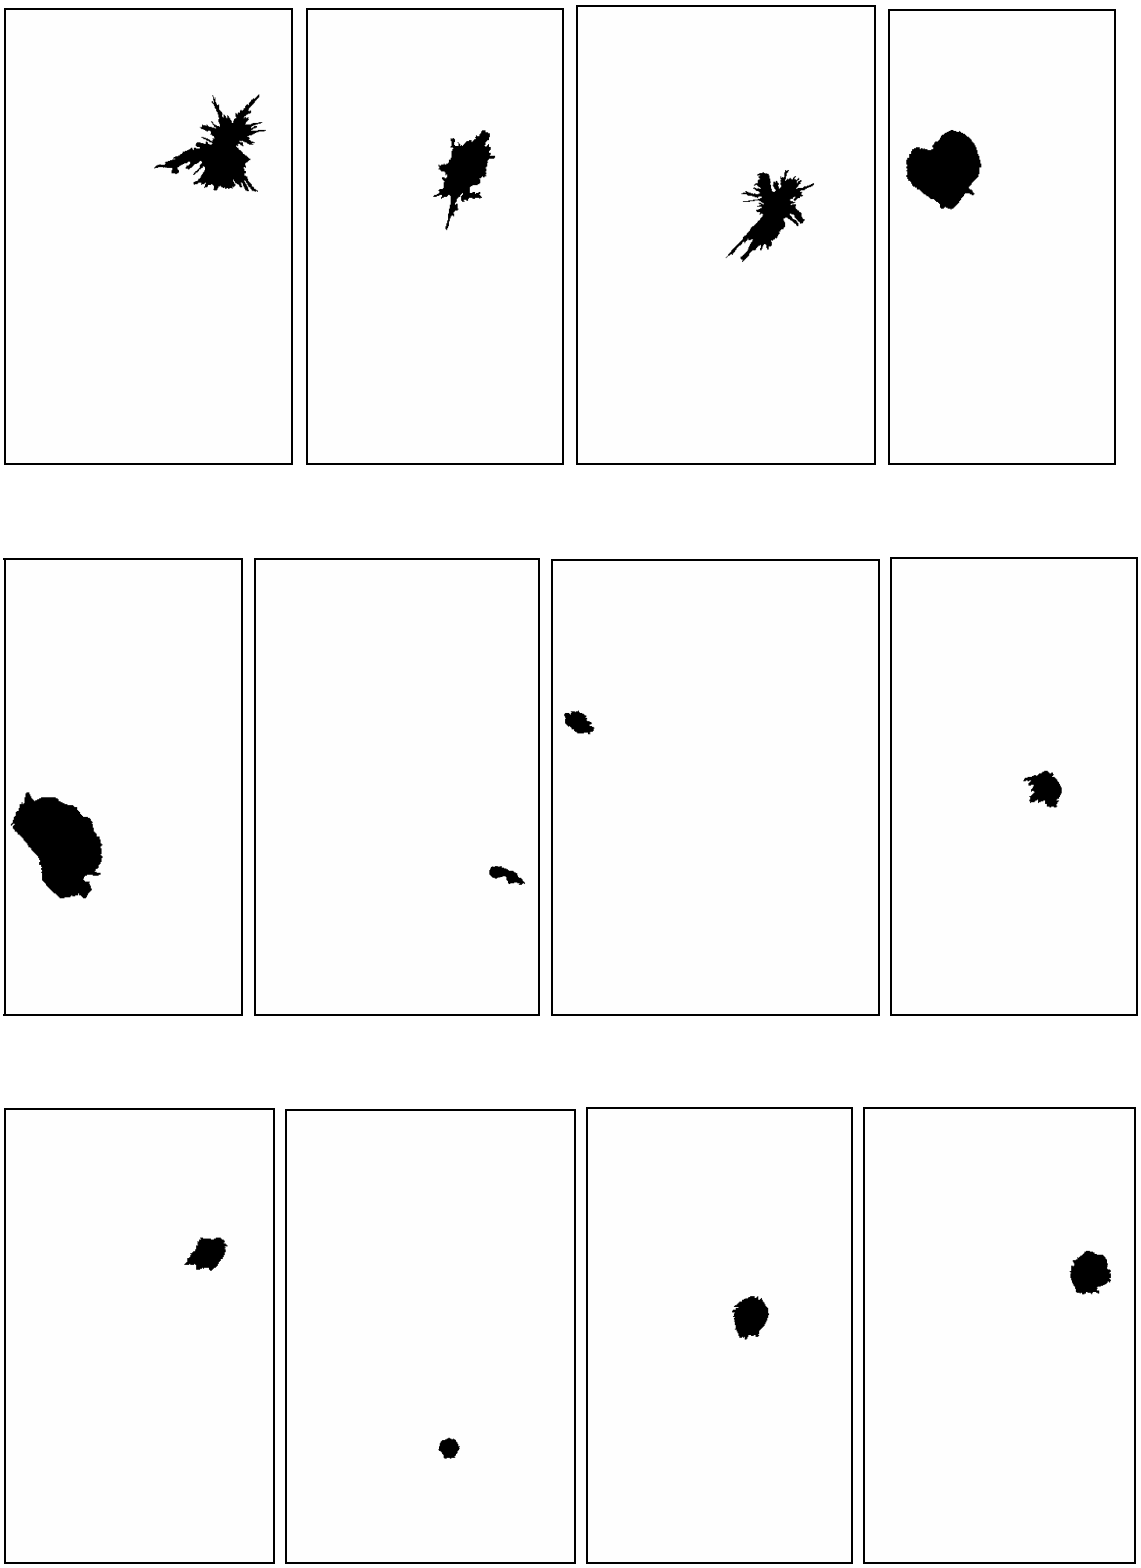
IMATGES DE QUISTS