

**UNIVERSIDAD NACIONAL DE
TUCUMÁN**

*“Procesamiento Digital de Imágenes aplicado a la
Clasificación de Tejido Cerebral”*

M.Cs. Ing. Virginia Laura Ballarin

Director: Dr. Máximo Valentinuzzi

Co-Directora: Dra. Teresita Cuadrado

**Tesis para optar al Título de Doctor en Ciencias Biológicas
(orientación Bioingeniería)**



RINFI es desarrollado por la Biblioteca de la Facultad de Ingeniería de la Universidad Nacional de Mar del Plata.

Tiene como objetivo recopilar, organizar, gestionar, difundir y preservar documentos digitales en Ingeniería, Ciencia y Tecnología de Materiales y Ciencias Afines.

A través del Acceso Abierto, se pretende aumentar la visibilidad y el impacto de los resultados de la investigación, asumiendo las políticas y cumpliendo con los protocolos y estándares internacionales para la interoperabilidad entre repositorios



Esta obra está bajo una [Licencia Creative Commons Atribución- NoComercial-CompartirIgual 4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/).

**UNIVERSIDAD NACIONAL DE
TUCUMÁN**

***“Procesamiento Digital de Imágenes aplicado a la
Clasificación de Tejido Cerebral”***

M.Cs. Ing. Virginia Laura Ballarin

Director: Dr. Máximo Valentinuzzi

Co-Directora: Dra. Teresita Cuadrado

**Tesis para optar al Título de Doctor en Ciencias Biológicas
(orientación Bioingeniería)**

A la Universidad Pública, mi pequeño mundo, en el que todos podemos, con dedicación y esfuerzo, hacer realidad nuestros sueños y proyectos.

Porque a través de ella la transformación y la grandeza de un país es posible.

Agradecimientos

- A mi Director, Dr. Máximo E. Valentinuzzi, por confiar en mí, y acompañarme en este camino con toda su valiosa experiencia, su calidez humana y estímulo.
- A la Dra. Cuadrado, mi co-directora, por su incondicional apoyo.
- Al Dr. Felice y la Dra. Winik, miembros de la Comisión de Supervisión, por las ideas y sugerencias de gran valor para el desarrollo de esta tesis.
- A los miembros del Instituto Radiológico de Mar del Plata, al Dr. Carlos Bouzas, a Hugo Alvarez por estar siempre disponibles para atender mis dudas, y en especial, al Dr. Carlos Capiel (h) por las horas que pasó enseñándome a interpretar neuroimágenes.
- Al Dr. Andrés Capizzano por facilitarme, a través del Instituto FLENI, las imágenes sin las cuales esta tesis no hubiera sido posible, y por su aliento.
- Al Ing. Manuel González, mi director en la Universidad Nacional de Mar del Plata, por haberme permitido desarrollar esta Tesis y por su permanente interés.
- Al Dr. Luis Gentil y a la Dra. Susana Rosso por su incondicional apoyo, confianza e incentivo.
- A Emilce, por su alegría, calidez y energía con que me acompaña en todas los proyectos que hemos realizado juntas.
- A mis compañeros del Laboratorio: Eduardo, Juani, y especialmente a Guillermo por su invaluable colaboración.
- A Gustavo por su colaboración y por su música.
- A Sebastián y Marcel, porque a pesar de la distancia, estuvieron conmigo.
- A todos los miembros del Departamento de Bioingeniería por su afecto. En especial a Nilda, Rosana, Viviana, Ery, Julio, Rafael, Oly y Myriam, porque siempre me hicieron sentir que tengo en Tucumán un segundo hogar.
- A Estela Ruiz, por su amistad.
- A Mechi, por compartir cada paso en el quehacer cotidiano.
- A Andrea, mi mejor amiga, por su interés en la escucha.

- A mis queridos padres que me dieron alas para volar y creer que todo lo podía.
- A Pablo, por su amor, su paciencia y tolerancia y por acompañar con pasión mis proyectos por superarme.
- A Sebastián, afectuoso y seguro, y a Florencia, dulce e incondicional, que son el real motivo de todo lo que emprendo.
- A la Universidad Nacional de Mar del Plata y a la Universidad Nacional de Tucumán, por haber contribuido en el financiamiento de esta tesis.

ÍNDICE GENERAL

INDICE GENERAL	i-1.
I. INTRODUCCIÓN	1-1.
1.1. El problema	1-1.
1.1.1. La Enfermedad de Alzheimer	1-2.
1.1.1.1. Demencia	1-2.
1.1.1.2. Demencias Corticales	1-4.
1.1.1.3. Manifestaciones clínicas de la Enfermedad de Alzheimer	I-4
1.1.2. El rol de la Resonancia Magnética en la Enfermedad de Alzheimer.	
Antecedentes cercanos	1-6.
1.2. Propuesta de solución	1-8.
II. IMÁGENES DE RESONANCIA MAGNÉTICA	2-1.
2.1. Bases de la RMN	2-1.
2.1.1. Formación de la Imagen. Alineamiento Preparatorio	2-1.
2.1.2. Proceso de excitación	2-3.
2.2. Distintas secuencias de pulso	2-7.
2.2.1. Saturación - Recuperación	2-7.
2.2.2. Inversión - Recuperación	2-9.
2.2.3. Secuencia de pulso spin-eco	2-11.
2.3. El rol de la RMN en la enfermedad de Alzheimer	2-16.

III. ANÁLISIS DE TEXTURAS.....	3-1.
3.1. Definición del concepto de textura	3-1.
3.1.1. Descripción de la textura	3-3.
3.1.2. Resolución de textura	3-4.
3.1.3. Nivel de gris y textura	3-5.
3.1.4. Propiedades de las texturas	3-6.
3.2. Modelos para la clasificación de texturas	3-7.
3.3. Enfoque Geométrico	3-8.
3.4. Enfoque Estadístico	3-11.
3.4.1. Método de Histogramas	3-11.
3.4.2. Matriz de Co-ocurrencia de niveles de gris	3-12.
3.4.3. Método de Función Autocorrelación	3-16.
3.5. Enfoque Espectral	3-18.
3.5.1. Métodos frecuenciales	3-18.
3.6. Enfoque Morfológico	3-21.
3.6.1. Operaciones Morfológicas básicas: Dilatación y Erosión	3-22.
3.6.1.1. Erosión Binaria	3-22.
3.6.1.2. Dilatación Binaria	3-24.
3.6.1.3. Apertura y Cerradura Binarias	3-27.
3.6.2. Criterio de tamaños: Granulometría Binaria	3-30.
3.6.2.1. Axiomas de Matheron	3-30.
3.6.2.2 Criterio de Tamaños por Aperturas Morfológicas	3-31.

3.6.2.3. Granulometrías generadas por un elemento estructurante simple	3-33.
3.7. Algoritmos de Clasificación de Texturas: Reconocimiento de Patrones	3-36.
3.7.1. Clasificación y Distancia	3-37.
3.7.2. Clasificación No Supervisada	3-38.
3.7.3. Medidas de Similitud	3-39.
3.7.4 Distancia dentro de un Conjunto y distancia entre Conjuntos	3-41.
3.7.5. Algoritmos elegidos	3-44.
3.7.5.1. Clasificador de Mínima Distancia	3-45.
3.7.5.2. Algoritmo Maximin	3-46.
3.7.5.3. Algoritmo K-Medias	3-48.
IV. MATERIALES Y MÉTODOS.....	4-1.
4.1. Técnicas empleadas: Morfología Matemática	4-1.
4.1.1. Operaciones básicas en niveles de gris	4-2.
4.1.1.1. Erosión en niveles de gris	4-3.
4.1.1.2. Dilatación en niveles de gris	4-5.
4.1.1.3. Apertura y cerradura en niveles de gris	4-8.
4.1.1.4. Elementos Estructurantes	4-10.
4.1.1.5. Propiedades Algebraicas	4-14.
4.1.2. Segmentación de los ventrículos laterales	4-16.
4.1.3. Extensión de la Granulometría a niveles de gris	4-19.

4.1.3.1. Textura y distribución granulométrica de tamaño local	4-20.
4.1.3.2. Elección del elemento estructurante	4-23.
4.1.3.3. Extensión a niveles de gris	4-23.
4.1.3.4. Implementación práctica	4-26.
4.1.4. Algoritmo de K-medias ponderado	4-29.
4.2. Imágenes utilizadas	4-30.
V. RESULTADOS.....	5-1.
5.1. Segmentación de los ventrículos laterales	5-1.
5.1.1. Segmentación de los ventrículos laterales con técnicas standard	5-1.
5.1.1.1. Técnicas de umbralamiento	5-1.
5.1.1.2. Técnicas de seguimiento de contornos	5-4.
5.1.2. Segmentación de los ventrículos laterales utilizando Morfología Matemática	5-5.
5.2. Extensión de la Granulometría a niveles de gris	5-8.
5.2.1. Extracción del cráneo y meninges mediante Snakes	5-8.
5.2.2. Matriz Co-ocurrencia de niveles de gris	5-9.
5.2.3. Métodos Frecuenciales	5-11.
5.2.4. Granulometría en niveles de gris	5-12.
5.3. Algoritmo de K-medias Ponderado	5-19.
VI. DISCUSIÓN.....	6-1.

VII. CONCLUSIONES..... 7-1.

VIII. REFERENCIAS BIBLIOGRÁFICAS..... 8-1.

Capítulo I

INTRODUCCIÓN

1.1 El problema

La enfermedad de Alzheimer es un trastorno neurológico que provoca la muerte de las células nerviosas del cerebro. Por lo general, comienza paulatinamente y sus primeros síntomas pueden atribuirse a la vejez o al olvido común. A medida en que avanza la enfermedad, se van deteriorando las capacidades cognitivas, entre ellas la capacidad para tomar decisiones y llevar a cabo las tareas cotidianas; pueden también surgir modificaciones de la personalidad, así como conductas problemáticas. En sus etapas avanzadas, la enfermedad de Alzheimer conduce a la demencia y finalmente a la muerte.

La enfermedad de Alzheimer es la causa más común de demencia, entre el 1 y el 6% de las personas mayores de 65 años padecen esta enfermedad, e incluso personas más jóvenes. Este desorden es realmente muy difícil de diagnosticar y por ahora su causa es desconocida. A los pacientes se los diagnostica como “probable enfermedad de Alzheimer” y la confirmación del diagnóstico sólo puede ser realizada, por ahora, post-mortem a través de un análisis histológico de la materia gris. Los signos histológicos de la enfermedad consisten en adelgazamiento de la materia gris y la presencia de placas amiloides.

Es de esperar que la Resonancia Magnética Nuclear (RMN) posibilite, en un futuro, el diagnóstico temprano de esta enfermedad. Los signos de demencia, en una RMN, no son detectados a simple vista hasta que otros síntomas físicos tales como pérdida de memoria, son suficientemente severos como para reconocer el mal. Sin embargo la enfermedad de Alzheimer provoca una disminución en el tamaño del cerebro, especialmente alrededor de los lóbulos temporales y el área del hipocampo. Como contrapartida la fisura sucal y los ventrículos aumentan su tamaño.

Teniendo en cuenta que las neuronas destruidas no pueden ser reemplazadas, la detección precoz de los primeros cambios en el cerebro que produce la enfermedad de Alzheimer es fundamental. En este sentido, el Procesamiento Digital de Imágenes (PDI) resulta una herramienta muy útil pues puede ser utilizado para distinguir sutiles variaciones

entre las texturas que componen una imagen de RMN y de esta manera contribuir a discernir entre una condición normal y una anormal que escapan a la percepción del ojo humano.

La textura en una imagen es una característica importante en el diagnóstico y es totalmente inherente al ojo humano. Sin embargo, la habilidad humana de distinguir sutiles variaciones en las diferentes texturas es bastante limitada. Es aquí donde el Procesamiento Digital de Imágenes (PDI) tiene un amplio campo de aplicación.

Las técnicas de PDI se utilizan para analizar, realzar, restaurar, modificar o cuantificar imágenes digitales para múltiples aplicaciones (González, R., 1992). Se desarrollan algoritmos apropiados para obtener los resultados deseados donde se aplican diversos modelos matemáticos. A éstas aplicaciones se les da el nombre de "técnicas" en el glosario de PDI. El análisis por computadora de las diferentes texturas en imágenes es una herramienta poderosa y la alta calidad de las imágenes RMN las hacen apropiadas para este tipo de aplicación donde se requieren segmentar estructuras anatómicas y/o zonas de interés (Castleman, R., 1979; Ballard, D. & Brown, C., 1992). En imágenes médicas éste es un proceso complejo ya que dichas estructuras anatómicas no se encuentran perfectamente delimitadas.

En este trabajo se propone un nuevo enfoque para la segmentación de los ventrículos laterales y la corteza cerebral utilizando las herramientas de la Morfología Matemática. La medición del aumento relativo del área de los ventrículos laterales y su comparación con la disminución relativa de la corteza cerebral serán un primer paso hacia el diagnóstico temprano de la atrofia cerebral que produce esta enfermedad.

1.1.1 La Enfermedad de Alzheimer

1.1.1.1. Demencia

La demencia puede definirse como un trastorno adquirido de las funciones intelectuales que compromete, por los menos, tres de las siguientes esferas de la actividad mental: lenguaje, memoria, capacidad visoespacial, emoción o personalidad y cognición (abstracción, cálculo, juicio, etc.). En un aspecto más amplio, también puede decirse que la

capacidad intelectual se pierde en suficiente medida como para interferir con las funciones ocupacionales y sociales. La demencia no es una enfermedad sino un síndrome que puede ser producido por múltiples patologías diferentes: algunas progresivas e intratables y otras pasibles de tratamiento efectivo, y por lo tanto, reversibles.

Las demencias pueden ser clasificadas de varias formas por ejemplo: de acuerdo con la edad, las distintas etiologías, si son o no tratables. Desde el punto de vista diagnóstico es útil clasificarlas sobre la base de la localización predominante del proceso patológico responsable, ya que de ella dependen los síntomas y signos iniciales, los cuales permiten un reconocimiento y categorización temprana, que a su vez conduce a adecuados enfoques diagnósticos, terapéuticos y de pronóstico. Así, las demencias pueden clasificarse en corticales y subcorticales. En las demencias corticales, además de las alteraciones de la funciones cognitivas¹ y amnésicas y los trastornos de los afectos, se encuentran manifestaciones secundarias a la difusión de áreas de asociación cortical.

El concepto de demencia subcortical es relativamente reciente. Los signos cardinales son la lentitud y dilapidación de la cognición y alteraciones del afecto en ausencia de trastornos resultantes de difusión de las áreas de acción cortical. Además, se acompaña de trastornos motores tempranos tales como hipocinesia² o bradicinesia³, rigidez, movimientos involuntarios anormales, etc.

Cuando el proceso patológico en su evolución afecta progresivamente estructuras corticales y subcorticales esta clasificación pierde valor y se emplea el término de demencia global. Así mismo existen categorías mixtas que comprometen estructuras corticales y subcorticales (tales como demencia por infartos múltiples como así también infecciones por virus lentos). Aunque diversas críticas surgen del análisis de esta clasificación, su utilidad diagnóstica justifica su uso.

La demencia debe ser diferenciada de la seudodemencia que acompaña a la depresión y a otras enfermedades psiquiátricas primarias y de los estados confusionales agudos (delirio). En ocasiones también ciertos síndromes cerebrales focales pueden ser

¹ Cognitivas: relativo al conocimiento, a la cognición.

² Hipocinesia: poco movimiento.

³ Bradicinesia: lento movimiento.

confundidos con demencia. Las enfermedades psiquiátricas que pueden simular demencia son: la depresión, la hipomanía, la esquizofrenia, la paranoia, la histeria, los estados compulsivos obsesivos, la psicosis epiléptica y la neurosis. Cabe recordar que la depresión puede acompañar a la demencia sobre todo en el comienzo de esta. Igualmente difícil puede resultar el diagnóstico diferencial entre los estadios tempranos de una demencia y los cambios cognitivos del envejecimiento normal. En estos casos, en general se observan trastornos leves no progresivos de la memoria, que se acompaña de otros efectos cognitivos.

1.1.1.2 Demencias Corticales

Las demencias corticales más importantes son la enfermedad de Alzheimer y la enfermedad de Pick. Desde que en 1906 el psiquiatra alemán Alois Alzheimer presentó un caso clínico donde se describía la patología de una paciente de 56 años, bajo su atención en el Asilo de Francfort, con claros síntomas cognitivos, conductuales y funcionales en los últimos 5 años de su vida; la aparición de información sobre estados demenciales no se detuvo. Sin embargo la cantidad de reportes no siempre tuvo su correlato con la calidad de los mismos. La enfermedad de Alzheimer es responsable aproximadamente del 50% de los casos de demencias, mientras la enfermedad de Pick sólo de un 4% los mismos.

1.1.1.3 Manifestaciones clínicas de la Enfermedad de Alzheimer

La enfermedad de Alzheimer y la demencia senil constituyen una única enfermedad. Hasta hace pocos años existía la tendencia de dividir las demencias en dos grandes categorías: presenil y senil, según se presentara antes o después de los 65 años. La enfermedad de Alzheimer estaba exclusivamente dentro del grupo de las demencias preseniles. Las manifestaciones clínicas y los cambios patológicos en la demencia de tipo Alzheimer, ya sea que comience antes o después de los 65 años, no muestran suficiente variabilidad como para justificar la distribución entre las formas seniles y preseniles.

La enfermedad de Alzheimer comienza generalmente a los 60 o 70 años de vida y

se manifiesta como demencia progresiva asociada a trastornos corticales específicos afasia⁴, apraxia⁵, agnosia⁶. Los pacientes tienen trastornos amnésicos, dificultad en aprender y retener información nueva más que en recordar hechos pasados, y desarrollan alteraciones progresivas en la capacidad de juicio, abstracción y cálculo. Las alteraciones del lenguaje son frecuentes. Los cambios de personalidad que se presentan como desinhibición e indiferencia, desorientación temporoespacial, a veces reacciones catastróficas, comportamiento sexual inapropiado o agresivo y trastornos del ciclo sueño-vigilia. La mayoría de los pacientes, a medida que avanza la enfermedad, presentan anormalidades motoras, trastornos del modo muscular y de la marcha y en ocasiones signos “parkinsonianos” leves. Los pacientes declinan gradualmente en su adaptación social y funcional, aparece incontinencia fecal y urinaria, y llegan a un estado de disolución total de la personalidad y a una completa dependencia. La muerte ocurre por lo general entre los 6 y 12 años del comienzo, aunque en oportunidades la duración de la enfermedad puede ser breve o muy prolongada (Snell, R., 1999).

Otra manera de presentarse es como una declinación lenta y gradualmente progresiva de las funciones intelectuales a partir del final de la séptima década o inclusive más tardíamente. Algunos pacientes pueden tener manifestaciones focales distintivas, tales como afasia, síndrome parietal o mioclonía, sin otros trastornos de las funciones mentales superiores, durante períodos prolongados al comienzo de la enfermedad.

Cualquiera de los modelos anteriores puede aparecer en un contexto familiar y en ocasiones manifestarse en forma autosómica dominante.

La alteración bioquímica más importante es la disminución de la actividad de la enzima colina-acetiltransferasa, que sintetiza la acetilcolina, en amplias zonas corticales, con preservación de los receptores muscarínicos⁷. La mayor parte de la innervación

⁴ Afasia: perturbación del lenguaje, independiente de un trastorno en la ideación o en la articulación, y debida a una lesión de los centros cerebrales.

⁵ Apraxia: pérdida de la facultad de reproducir movimientos coordinados habituales, tales como peinarse, encender un cigarrillo, saludar, etc.

Pérdida de la facultad de reconocer los usos de un objeto.

⁶ Agnosia: imposibilidad de comprender el significado de las cosas y no valorarlas justamente, como en algunos casos de demencia.

⁷ Muscarínicos: relativo a la muscarina. Muscarina: sustancia tóxica contenida en la seta *Amanita muscaria*, que produce intoxicación aguda y grave del sistema nervioso.

colinérgica cortical proviene de células localizadas en el núcleo basal de Meynert, reducidas en la enfermedad de Alzheimer. También el número de neuronas en el locus coeruleus puede estar considerablemente reducido. El sistema serotoninérgico está alterado; la concentración de ácido 5-hidroxiindolacético en el LCR es menor en los pacientes con enfermedad de Alzheimer que en los controles. También hay una pérdida predominante de grandes neuronas en las áreas de asociación de la corteza cerebral. Por otro lado, la somatostatina que está presente en las células grandes y en las interneuronas, se encuentra reducida.

La etiología de la enfermedad de Alzheimer se desconoce. Hasta hace poco tiempo se la consideraba abiotrofia, es decir el resultado de un envejecimiento prematuro.

1.1.2 El rol de la Resonancia Magnética en la Enfermedad de Alzheimer. Antecedentes cercanos

El estudio a través de imágenes de los cambios estructurales del cerebro pueden proveer información útil para el diagnóstico y el manejo clínico de los pacientes con demencia. Las imágenes de Resonancia Magnética pueden mostrar anomalías que no son visibles en la Tomografía Computada. Así mismo tienen el potencial de detectar señales de anomalía permitiendo un diagnóstico diferencial entre la enfermedad de Alzheimer y la demencia vascular. La atrofia temporal severa y las hiperintensidades en el hipocampo o la corteza insular, que caracterizan la demencia producida por la Enfermedad de Alzheimer, pueden ser medidas a partir de las imágenes de RMN.

Mientras que en las demencias vasculares, la observación directa de las imágenes de RMN permite un inmediato diagnóstico, el análisis estructural de este mismo tipo de imágenes en la enfermedad de Alzheimer tiene un rol muy importante y más complejo porque permite evaluar cambios tales como la atrofia cortical o la leucocariosis asociada. Las imágenes de algunos pacientes con la enfermedad de Alzheimer pueden tener hiperintensidades en la corteza sylviana o del hipocampo. Esta señal posiblemente tiene un correlato patológico con el aumento del contenido de agua debido a la pérdida neuronal, la

gliosis y otros cambios histológicos propios de la enfermedad (Pantano P., Caramia F. & Pierallini A, 1999).

Aunque la Enfermedad de Alzheimer está caracterizada a nivel histopatológico por placas seniles, degeneración neurofibrilar, degeneración vacuolar celular y inclusiones celulares, éstas son anormalidades que también pueden ocurrir en los ancianos normales, sin embargo, estas características son mucho más conspicuas en la Enfermedad de Alzheimer. La degeneración neurofibrilar de Alzheimer aparece además mucho más extendida en áreas relacionadas con la memoria tales como el hipocampo y los lóbulos temporales. Mientras esta manifestación celular de la enfermedad no puede ser estudiada *in vivo*, la atrofia que produce puede ser observada en las imágenes de Resonancia Magnética cerebral y cuantificada a partir del Procesamiento Digital de Imágenes.

La mayoría de los trabajos previos, miden la atrofia cerebral en la enfermedad de Alzheimer, basándose en segmentaciones que combinan el umbralamiento, el seguimiento de contornos obteniendo de esa forma los bordes de las regiones que les interesa cuantificar (Mizuno K., Wakai M., Takeda A. & Sobue G., 2000; Chaves M., Ilha D., Maia A., Motta E. Lehmen R. & Oliveira L., 1999). Tanabe et al. realizan la segmentación de manera semiautomática, es decir eligiendo píxeles bien representativos de los diferentes tejidos y utilizándolos como muestras para entrenar un posterior análisis discriminativo (Tanabe J., Amend D., Schuff N. et al., 1997; Friedlinger M., Schad L., Blüml S. et al., 1995). Estos métodos requieren intervención del usuario, ya sea eligiendo el umbral a través del histograma o los píxeles semilla para el seguimiento de contornos. Estas intervenciones varían según las diferentes imágenes a procesar lo que hace a estas segmentaciones tradicionales operador-dependientes.

Fox y Freeborough (Fox N. & Freeborough P. , 1997) utilizan una herramienta matemática que llaman la integral de desplazamiento de bordes del *cerebro* (*Brain boundary shift integral*). Esta técnica permite obtener el volumen total a través del desplazamiento de todos los bordes de una estructura. La registración exacta de una serie de resonancias permite determinar el volumen directamente por los niveles de gris de sus voxels. Esta técnica sirve fundamentalmente para determinar la variación del volumen total

del cerebro y se complica cuando se quiere determinar el volumen de la corteza y sobre todo discriminar determinadas estructuras en particular.

Burril (Burril, J., 2000) hace un interesante análisis y describe diferentes característicos de textura para analizar imágenes de RMN, si bien su análisis se ve limitado a un pequeño número de imágenes.

Un método de medición lo más automatizado posible eliminaría fácilmente la molestia de trazar manualmente un gran número de imágenes para evaluar las estructuras y sus posibles cambios frente a un efecto terapéutico. La detección de esos efectos sobre los porcentajes de atrofia dependen fundamentalmente de la precisión, exactitud y reproducibilidad de las mediciones usadas (Manes, F., 2000).

1.2 Propuesta de solución

La propuesta de esta tesis es aplicar Morfología Matemática para obtener la segmentación de las diferentes texturas en las imágenes de RMN de cerebro. Más específicamente, crear un vector de característicos para cada pixel a través de operaciones morfológicas, que indiquen una medida de textura presente en dicho punto. Se plantea obtener las características asociadas a cada pixel al aplicar el Criterio de Tamaños de Aperturas Sucesivas sobre una máscara centrada en un pixel (Serra, J., 1982; Serra, J., 1988). Estos algoritmos normalmente se utilizan para imágenes binarias (Dougherty, E., 1992; Dougherty, E. and Sand, F. 1995).

Otro objetivo del presente trabajo es extender el uso de la granulometría para imágenes con niveles de gris permitiendo una segmentación más independiente del usuario, y, por lo tanto, más precisa, reproducible y con la mayor exactitud posible en la medición de los volúmenes de los tejidos cerebrales.

La estructura de la Tesis es la siguiente:

Capítulo II: Imágenes de Resonancia Magnética. Se explican los conceptos de básicos de la Resonancia Magnética Nuclear para comprender las características de las imágenes multispectrales que se utilizarán a lo largo del trabajo.

Capítulo III: Análisis de Texturas. Se explican los fundamentos del concepto de textura y los diversos modelos desde los que se puede abordar el análisis de texturas. Se presenta una compilación propia para esta Tesis sobre las principales conceptos de Morfología Matemática y Granulometría Binaria que se utilizan a lo largo de este trabajo. Además se enuncian los conceptos necesarios de Reconocimiento de Patrones como etapa posterior al análisis e indispensable para la segmentación de texturas propuesta.

Capítulo IV: Materiales y Métodos. Se describe de manera detallada las técnicas propuestas: la segmentación de los ventrículos laterales a través de la operaciones morfológicas, la extensión de la granulometría a grises y por último la variante propuesta del algoritmo de reconocimiento de patrones el algoritmo K-Medias ponderado.

Capítulo V: Resultados. Se muestran los resultados de la etapa de segmentación de los ventrículos laterales. Se muestran los resultados obtenidos a través de los diferentes enfoques del análisis de texturas estudiados: estadístico (matrices de co-ocurrencia), espectral (Transformada de Fourier) y el propuesto enfoque Morfológico para esta tesis: Granulometría de Grises. Se comparan los resultados obtenidos a través de imágenes y tasas de reconocimiento. También se muestran los resultados de la clasificación realizada con los parámetros obtenidos a través de la granulometría utilizando dos diferentes algoritmos standard y el propuesto, K-medias ponderado. Se comparan finalmente los resultados a través de matrices confusión y de las propias imágenes clasificadas.

El **Capítulo VI** presenta la **Discusión** correspondiente y en el **Capítulo VII** se enuncian las **Conclusiones**.

Las **Referencias Bibliográficas** correspondientes a toda la Tesis se presentan en el **Capítulo IX**.

Capítulo II

IMÁGENES DE RESONANCIA MAGNÉTICA

Si bien la imagen de resonancia magnética (RM) está basada en principios físicos totalmente diferentes de los de la tomografía computada (TC); ambas coinciden en que una energía es radiada dentro del paciente y luego, parte de esa energía se detecta al emerger del paciente. En el caso de la RM la energía radiada son ondas de radiofrecuencia en lugar de rayos X, como ocurre en la TC. En las dos técnicas, la energía detectada a la salida se correlaciona con varios parámetros característicos del tejido.

Lo más importante de la RM es que permite discriminar diferencias mucho menores de contraste entre las distintas componentes estructurales de los tejidos analizados que en la TC. La RM significa una mejora significativa en este aspecto.

2.1 Bases de la RMN

2.1.1 Formación de la Imagen. Alineamiento Preparatorio

La materia está compuesta de moléculas y átomos; los átomos a su vez contienen núcleos con diferente número de protones y neutrones. Cuando las partículas cargadas giran o se mueven, generan alrededor de ellas un campo o momento magnético asociado, como resultado de las propiedades de giro (*spin*) de sus nucleones. Incluso los neutrones, que no tienen carga neta, contribuyen al *spin*.

La intensidad del campo magnético asociado de determinado núcleo depende del grado en que se suman o anulan entre sí los campos magnéticos de los nucleones individuales. La RM depende absolutamente de la existencia de un momento magnético neto del núcleo. De los núcleos de importancia biológica, el de hidrógeno proporciona la mayor sensibilidad de todos. Esto es debido tanto a su momento magnético elevado como a su gran abundancia en el cuerpo; ya sea en forma de agua como de otras moléculas de importancia biológica. Se entiende así por qué la RM es más sensible que la TC (Jacobson, H., 1988), ya que las diferencias en el contenido de agua, que a su vez implican diferencias

en el contenido de hidrógeno en los tejidos biológicos, son mucho mayores que las diferencias correspondientes a la atenuación de los rayos X.

En el caso de un núcleo que gira, el vector magnético nuclear está alineado perpendicular al plano de giro. En un medio donde todos los núcleos tienen sus vectores alineados al azar en todas las direcciones, debido a las interacciones aleatorias con los núcleos vecinos, estos vectores se suman y anulan entre sí. Esto implica que no existe un campo electromagnético externo del medio considerado globalmente (los vectores nucleares se cancelan entre sí). Así ocurre con los tejidos biológicos. Sin embargo existe una susceptibilidad magnética potencial.

Si el medio es colocado en un campo magnético externo fuerte (B_0), los vectores magnéticos nucleares tienden a alinearse con este campo magnético externo (Keller, P., 1988). El hidrógeno tiene dos formas de alineación posible, en la misma dirección del campo magnético externo (alineamiento paralelo) y en la dirección opuesta (alineamiento antiparalelo). El estado de alineamiento paralelo es el de menor energía, esto implica que un pequeño exceso de protones se alinean en esta dirección. A causa del pequeño exceso de alineamiento paralelo, permanece cierta magnetización neta en esa dirección. La fuerza de esa magnetización varía con la intensidad del campo B_0 .

Cuando los vectores nucleares están bajo el influjo de un campo magnético externo tiene lugar un fenómeno adicional muy importante: los vectores no se alinean exactamente paralelo o antiparalelo, sino que en realidad, efectúan un movimiento de precesión alrededor de la dirección de la campo externo (Ver figura 2-1).

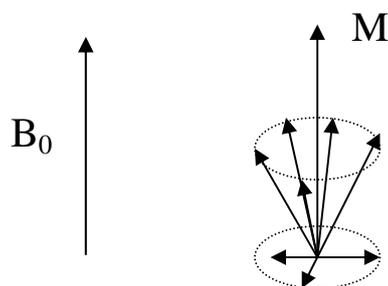


Fig.2-1 Cuando se sitúa un fuerte campo magnético externo (M), los momentos nucleares se alinean en paralelo o antiparalelo y adquieren un movimiento de precesión alrededor del campo externo (B_0).

Este movimiento de precesión tiene una frecuencia que depende de B_0 regida por la ecuación Larmor (Keller, P., 1990):

$$f = k.B_0 \quad (2-1)$$

donde k es una constante para cada núcleo llamada constante giromagnética. Esta constante es para el hidrógeno mayor que para cualquier otro núcleo de importancia biológica.

El conjunto de los vectores magnéticos participantes de todos los núcleos de una región forman un cono de vectores al precesar alrededor de un campo magnético externo estático, cada uno con fase aleatoria. Observando la proyección en un instante dado, y al no haber direcciones preferidas en el espacio, las proyecciones transversales se anulan entre sí. Esto implica que no hay magnetización neta en el campo transversal. Sin embargo las proyecciones longitudinales se suman resultando un vector magnetización apreciable. Este vector está completamente alineado en la dirección longitudinal. Se dice que en esta situación el sistema está relajado y en equilibrio dinámico.

No hay señal detectable en el estado de equilibrio, ya que no hay componente magnética transversal. Sin embargo si se altera el estado de equilibrio, se podrá producir una señal.

2.1.2 Proceso de excitación

Para poder detectar una señal debe haber algún grado de magnetización sobre el eje transversal. Lo que se hace es excitar intencionalmente los núcleos para sacarlos de su alineamiento longitudinal hacia el plano transversal y de esa manera obtener una señal. Mientras el núcleo se relaja al equilibrio, esta señal decrece con un patrón temporal característico que depende del contenido de hidrógeno del tejido (o sea de su composición química particular). Esta señal proporcionará la información de las propiedades en cada punto del tejido.

Las ondas de radiofrecuencia son las más apropiadas para excitar los núcleos, dado que la constante giromagnética para los tejidos humanos es tal que la frecuencia obtenida por la ecuación de Larmor cae en el rango de las ondas de radiofrecuencia. Si aplicamos

una señal con la frecuencia de Larmor, ésta será transferida al núcleo, ya que se trata de su frecuencia de resonancia, y éste se excitará. El efecto obtenido es que el vector magnetización se inclina sobre el plano transversal y los vectores que antes precesaban de manera aleatoria alrededor de B_0 , ahora lo hacen coherentemente girando en fase. Como consecuencia de esta coherencia de fase los vectores ya no se anulan entre sí en el plano transversal quedando por lo tanto una magnetización neta transversal apreciable.

El vector magnetización se inclinará con un ángulo que dependerá del tiempo de aplicación de la radiofrecuencia (RF). El vector de magnetización comienza a precesar en un movimiento en espiral alejándose del alineamiento longitudinal original. A medida que el vector magnetización desciende en espiral, la magnetización longitudinal se reduce y la transversal aumenta. Con un ángulo de 90° la magnetización longitudinal es cero y la transversal es máxima, que es la productora de señal (Ver figura 2-2).

Resumiendo, la RF excita los núcleos y tal excitación perturba el alineamiento longitudinal existente en la condición de equilibrio para crear una componente transversal. Esta componente es la que genera una señal detectable. La RF incide sobre los tejidos a una frecuencia que no distorsiona los enlaces electrostáticos de los átomos y moléculas constituyentes de los tejidos, en otras palabras no hay efectos indeseables. Cuando cesa la aplicación de RF, los protones de hidrógeno estarán en un determinado estado de excitación manifestado por el desplazamiento del vector a cierto ángulo en relación al eje longitudinal y generando determinada señal debida a la componente de magnetización transversal

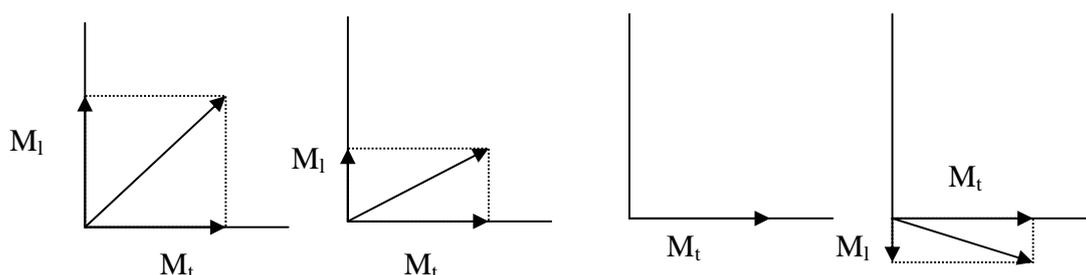


Fig.2-2 El vector de magnetización comienza a precesar en un movimiento en espiral alejándose del alineamiento longitudinal la magnetización longitudinal (M_l) se reduce y la transversal (M_t) aumenta.

inducida. Los núcleos revierten gradualmente su alineamiento longitudinal por la pérdida de la energía de excitación al medio. Estas interacciones son llamadas *spin-lattice*. Los núcleos también intercambian energía magnética entre ellos. Estas interacciones causan el desfase de los vectores de giro individual, es decir, al interactuar entre sí pierden su coherencia de fase más allá de que el medio permanezca en excitación. Estas interacciones son llamadas *spin-spin*. El tiempo asociado con la recuperación de la magnetización longitudinal, interacciones *spin-lattice*, se conoce como tiempo de relajación T_1 mientras que el tiempo asociado con la pérdida de fase, interacciones *spin-spin*, se conoce como tiempo de relajación T_2 . Ambos procesos conducen a la pérdida de la magnetización transversal y en consecuencia la señal detectada disminuye (Keller, P., 1990).

La señal se detecta mediante una bobina conductora que permite determinar la cantidad de magnetización transversal. Cuando el vector magnetización precesa, induce en la bobina una señal eléctrica y la intensidad de dicha señal eléctrica depende del ángulo que exista en cada momento entre el vector y la posición de la bobina. El tiempo de relajación T_1 se define en términos de recuperación del alineamiento longitudinal, concretamente T_1 se define como el tiempo de recuperación del 63,2 % del valor original.

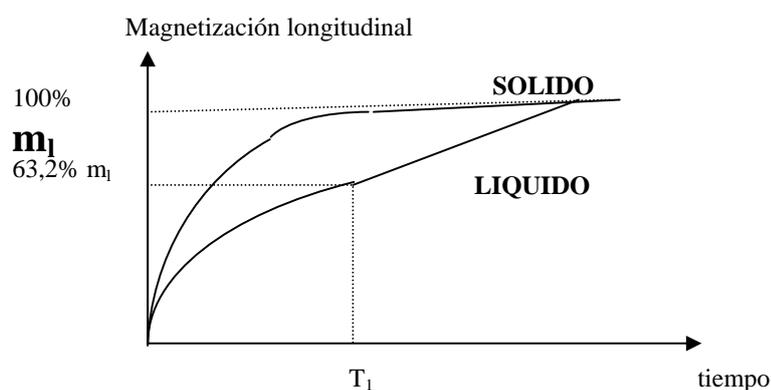


Fig.2-3 El tiempo de relajación T_1 , tiempo de recuperación del 63,2% del valor de la magnetización longitudinal.

En los sólidos las moléculas están más cerca y más entrelazadas entre sí, en consecuencia la pérdida de energía por interacciones *spin-lattice* es más rápida, lo que a su vez implica que los T_1 son menores como se ve en la figura 2-3. Los tiempos de relajación T_1 son variables y dependen de los enlaces intermoleculares de cada tipo de tejido.

Las interacciones *spin-spin* se dan entre vecinos que individualmente intercambian energía. En este proceso la energía es transferida entre los núcleos provocando la aceleración de algunos y el retardo de otros. Como consecuencia de este proceso la coherencia de fase inicial que existe después de la excitación desaparece conduciendo rápidamente a cero la magnetización transversal. Esto es debido a que las componentes transversales de los diferentes vectores se cancelan entre si disminuyendo a cero la señal detectada. Este proceso es independiente de la recuperación de la magnetización longitudinal y se produce antes de haber alcanzado el equilibrio. El tiempo de desfase de los vectores y de la caída de la señal por este mecanismo está dado por T_2 (Ver figura 2-4). T_2 se define como el tiempo necesario para que la señal se reduzca a un 36,8 % de su valor original. (Tanto el valor 36,8% como el 63,2% simplifican las ecuaciones matemáticas relacionadas con los fenómenos exponenciales y el número e .) En general los tiempos T_2 son del orden de la décima parte de T_1 para los tejidos biológicos. (T_2 decenas de milisegundos y T_1 cientos de milisegundos.)

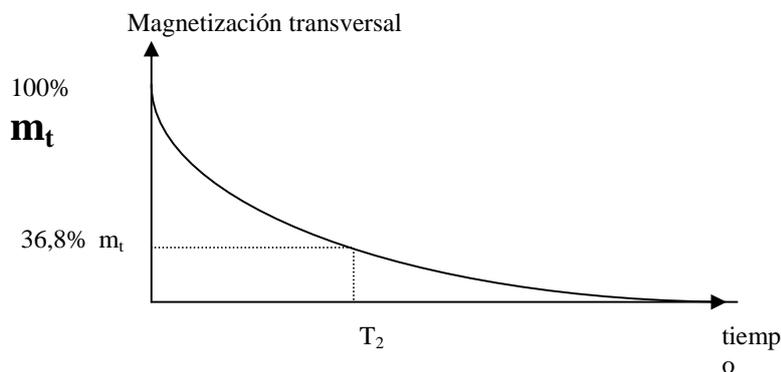


Fig.2-4 El tiempo de relajación T_2 , tiempo el tiempo necesario para que la magnetización transversal se reduzca a un 36,8 % de su valor original.

Un tercer mecanismo de caída de señal que contribuye a las *interacciones spin-spin* es debido al hecho de que el campo magnético no es totalmente uniforme debido a las inhomogeneidades locales. Éstos aumentan las interacciones *spin-spin*, acelerando el procesos de desfasaje y la caída de la señal correspondiente. Este desfasaje es tan rápido que enmascara toda la información T_1 y T_2 de la señal. Este tiempo de relajación se conoce como T_2^* . Por otro lado T_2 a su vez enmascara la relajación T_1 que es relativamente larga. Por lo tanto, se debe plantear de que manera separar T_1 de T_2 y a su vez éstos de T_2^* . (Ver figura 2-5).

2.2 Distintas secuencias de pulso

2.2.1 Saturación - Recuperación

Para eliminar los efectos de T_2^* se han diseñado varias secuencias de pulsos, una de ellas es la *saturación - recuperación*. Aunque no es de uso habitual ilustra bien los proceso de RM.

La secuencia saturación-recuperación es una secuencia de pulso FID (Free Induction Decay) repetida, es decir la aplicación de varios pulsos de 90° separados por un tiempo de repetición (T_R). (Ver figura 2-6).

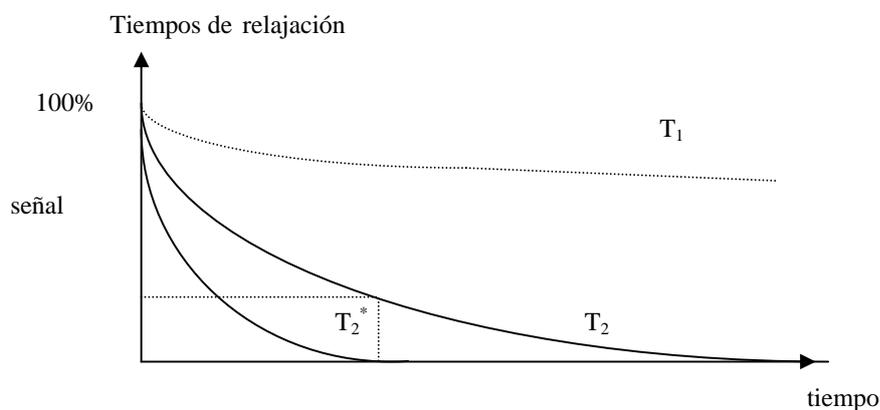


Fig.2-5 El tiempo de relajación T_2^* es tan pequeño que enmascara al tiempo T_2 que a su vez enmascara a T_1 .

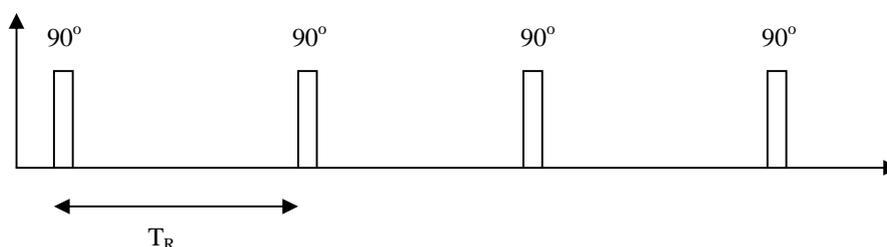


Fig.2-6 La secuencia saturación-recuperación. Pulsos FID repetidos de 90°.

Después de cada pulso de 90°, todos los vectores magnéticos quedan transversales y en fase. Comienzan inmediatamente a desfasarse y a volver a la posición longitudinal espiraladamente. Cuando se repiten los pulsos de 90°, el segundo pulso, capturarán vectores en posiciones intermedias, es decir saturados antes de alcanzar la recuperación longitudinal completa y los proyectará 90° en el cuadrante siguiente. De esta manera, permanece una proyección neta productora de señal. La intensidad de esta señal dependerá del grado de recuperación longitudinal o sea del tiempo de relajación T_1 que haya tenido lugar en cada punto. Se dispone así de una forma de distinguir entre los diferentes tiempos de relajación T_1 y de los diferentes tejidos que representan. Al aplicar un nuevo pulso los vectores vuelven a ponerse en fase. En todos los casos la señal es detectada independientemente de T_2^* .

La señal detectada es igual a:

$$S_N = N (1 - \exp(-T_R/T_1)) \quad (2-2)$$

donde N es la densidad de protones presentes. Si el tiempo de repetición T_R es corto en relación a T_1 , la magnetización longitudinal se recupera parcialmente y los siguientes pulsos de 90° proporcionan señales menos intensas. Por el contrario si la relación entre T_R y T_1 es grande entonces las señales serán relativamente altas y mejora el contraste. En otras palabras, el contraste entre diferentes tejidos en una imagen es simplemente la diferencia entre las curvas de recuperación de cada tejido. Se debe buscar el T_R óptimo para visualizar los diferentes tejidos.

La secuencia saturación-recuperación es bastante sensible a los errores de determinación del ángulo y tiene una escala de contrastes escasa comparada con otros tipos de secuencias como la de inversión recuperación que es la que habitualmente se utiliza.

2.2.2 Inversión - Recuperación

La inversión-recuperación es una secuencia de pulsos utilizada para obtener imágenes ponderadas en T_1 . Concretamente se aplica un pulso de 180° que invierte la magnetización hacia la dirección antiparalela, inmediatamente después que cesa el pulso, aunque todos los vectores están en fase, no hay señal ya que no hay componente de magnetización transversal.

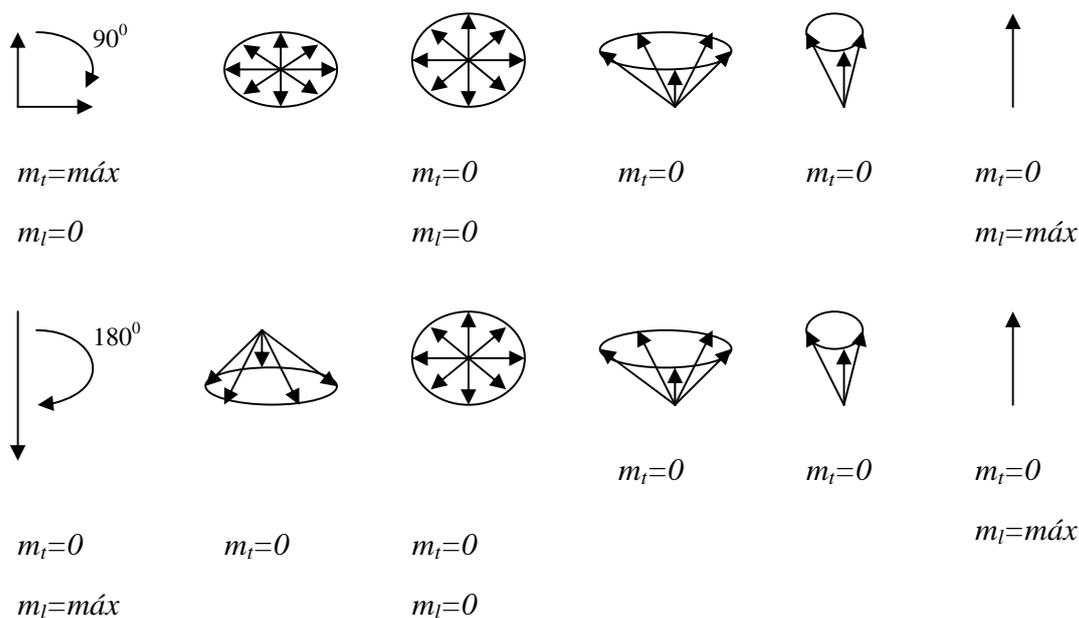


Fig. 2-7 El efecto de la secuencia inversión-recuperación sobre las componentes longitudinal (m_l) y transversal (m_t) de vector magnetización.

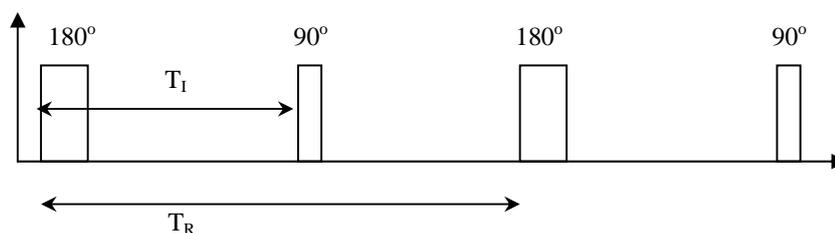


Fig.2-8 La secuencia inversión-recuperación. Pulsos de 180° intercalados con pulsos de 90°. (T_R, tiempo de repetición; T₁, tiempo de relajación.)

A medida que pasa el tiempo y mientras los vectores se recuperan tampoco se produce señal dado el desfase que tiene lugar, como se ve en la figura 2-7. Después de un intervalo de tiempo T₁, en el que los vectores habrán recuperado la magnetización en distinto grado de acuerdo a los valores de T₁ de cada uno de los tejidos, se aplica un segundo pulso de 90°. Este pulso tiene el efecto de trasladar el vector magnetización al siguiente cuadrante y poner de nuevo en fase los *spins* proporcionando una señal medible.

La secuencia de inversión-recuperación es muy similar a la de saturación-recuperación aunque los vectores tienen más espacio para recuperarse, 180° en vez de 90°, de esta manera se pueden observar mayores diferencias entre ellos (ver figura 2-8).

Las señales dependen de T₁ y de las características de los tejidos. Si T₁ es demasiado corto se dará poco tiempo para que se produzcan diferencias apreciables; si T₁ es demasiado largo se efectuará toda la recuperación longitudinal y habrá poca variaciones entre los tejidos. Si el vector magnetización se encontrara justo a 0° al aplicar el pulso de 180°, en el instante inmediatamente posterior irá a -90° implicando una magnetización transversal nula y por lo tanto no se producirá señal. Estas últimas consideraciones sobre los tiempos se grafican en la figura 2-9.

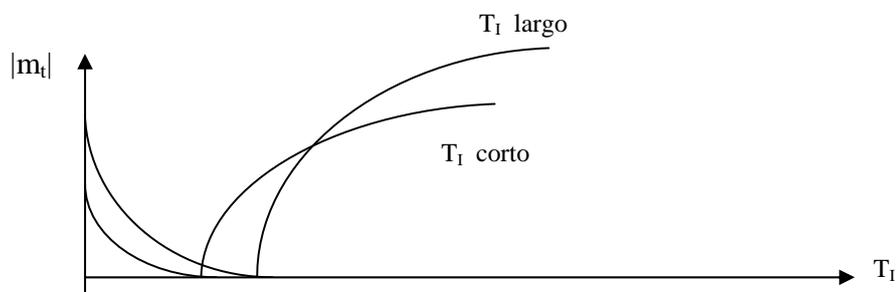


Fig.2-9 Variación de la magnitud del vector magnetización longitudinal en función de los valores de T₁.

Un aspecto interesante de la imagen es el hecho de que el contraste relativo puede ser invertido, es decir lo brillante a oscuro y viceversa. Si el T_1 es corto puede darse esta inversión. Hay un punto donde ambos tejidos proporcionan la misma señal, es decir no hay contraste y por lo tanto los mismos no se pueden distinguir.

2.2.3 Secuencia de pulso spin-eco

Para obtener una imagen ponderada en T_2 se debe eliminar la influencia del tiempo de relajación T_2^* . Primero se aplica un pulso de 90° que coloca al vector magnetización en el plano transversal. Inmediatamente después comienza a tener lugar un desfase. Este desfase depende tanto de las interacciones *spin-spin* como de las inhomogeneidades del campo magnético externo. Con el tiempo los vectores de giro más lento se separan de los de precesión de giro más rápido provocando que la magnetización transversal, como la señal, tienda a cero. Después se aplica un nuevo pulso de 180° con un intervalo de tiempo aplicado $T_E/2$ (siendo T_E el tiempo de eco). Este pulso está diseñado para trasladar a los vectores al lado opuesto del plano transversal, tal que los vectores que precesan se muevan ahora hacia el punto de partida tendiendo a volver a estar en fase. Es decir, los más rápidos alcanzan a los más lentos, volviendo ambos, rápidos y lentos, al mismo tiempo al punto de partida, en fase en el tiempo T_E . Tan pronto como los vectores vuelven a estar en fase se produce una señal detectable o señal de eco. Este eco aumenta alcanzando su valor máximo en T_E , cuando los vectores están totalmente en fase. En la figura 2-10 se observa la secuencia de pulso *spin-eco*.

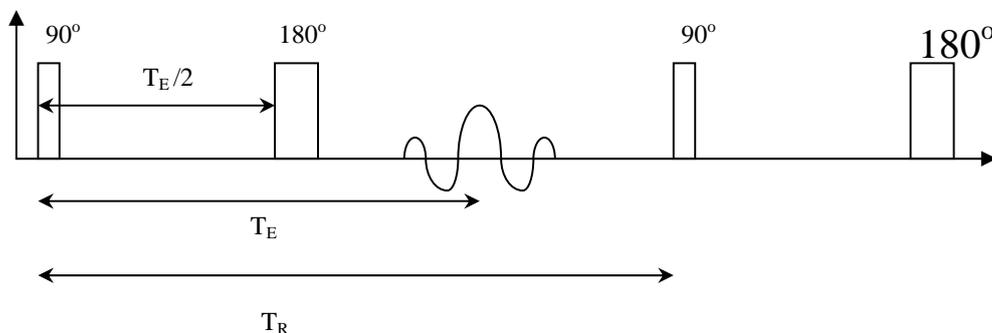


Fig.2-10 Secuencia de pulso spin-eco. (T_R , tiempo de repetición; T_E , tiempo de eco.)

Esta vuelta a estar en fase tiene sólo lugar para los desfases debido a las inhomogeneidades locales, ya que están fijadas en el espacio y el desfase que causan es reversible. Por otro lado el desfase debido al verdadero T_2 es aleatorio e irreversible y no es afectado en la vuelta de fase. La señal entonces corresponde al desfase T_2 que hubiera tenido si T_2^* no hubiera estado presente.

Si T_E es largo se deja más tiempo a los vectores para separar a sus diferentes T_2 y la imagen final es ponderada en T_2 . Si T_E es muy corto se produce poco desfase y la secuencia, se aproxima a la saturación parcial, esto implica que las imágenes proporcionadas son ponderadas en T_1 . También en este caso se puede invertir el contraste relativo. Esta relación entre la señal detectada y los tiempos T_E , T_1 y T_2 queda plasmada en la ecuación 3-2.

$$S = N \cdot \exp\left(-\frac{T_E}{T_2}\right) \cdot \left[1 - \exp\left(-\frac{T_R}{T_1}\right)\right] \quad (2-3)$$

En la práctica clínica y debido a que la señal de eco tiene un tratamiento matemático más favorable, tanto la secuencia de saturación-recuperación como la de inversión-recuperación, son complementadas con un pulso final de 180° . Los T_E empleados son tan cortos que las imágenes resultantes son T_2 -independientes.

Resumiendo, el contraste entre dos tipos de tejidos es la diferencia de intensidad entre las señales que emanan de cada uno de ellos. La intensidad depende de las combinaciones específicas de los parámetros de tiempo T_1 , T_R y T_E involucrados en la secuencia de pulso.

- T_R determina el grado en que la magnetización longitudinal se puede recuperar. Afecta la ponderación en T_1 .
- T_E afecta la ponderación en T_2 . Con un T_R largo las diferencias casi no dependen de T_1 .

Estas combinaciones de tiempos se pueden resumir en la Tabla 2-1. Como escribiera Bradley en 1984 "con una selección adecuada de T_R y T_E se tiene forma de cambiar la ponderación relativa en T_1 y T_2 de la imagen".

	T_R corto	T_R largo
T_E corto	T ₁	Densidad protónica
T_E corto	--	T ₂

Tab. 2-1 Resumen de las combinaciones específicas de los parámetros de tiempo T_R y T_E, y su relación con las diferentes ponderaciones T₁ y T₂.

La intensidad o brillo en una posición dada de la imagen de RM refleja la amplitud de la señal de RM en esa posición, la cuál es proporcional a la concentración de protones móviles de hidrógeno en esa región. Si los parámetros de la imagen son seleccionados de manera tal de reflejar sólo las variaciones de densidad de protones la imagen se conoce cómo imagen de densidad de protones PD. Un ejemplo de imagen PD se muestra la en figura 2-11. En las imágenes PD, la intensidad no varía mucho de estructura a estructura. La razón para esta apariencia es que la densidad de protones no varía mucho para los diferentes tejidos. Si T_R es muy largo (T_R >> T₁) y T_E es muy corto (T_E << T₂) entonces ambos tejidos recuperan totalmente su magnetización longitudinal entre cada secuencia *spin-echo* de excitación-detección, aun si los tejidos poseen diferentes valores de T₁. Por lo tanto las diferencias de T₁ no afectarán la cantidad de magnetización longitudinal disponible para la próxima secuencia *spin-echo* del tren de pulsos. Teniendo en cuenta que el tiempo de relajación T₂ describe la relación de disminución de la señal en plano transversal, un T_E largo pondrá en evidencia las diferentes valores de las señales procedentes de tejidos que poseen diferentes T₂. Sin embargo para T_E muy cortos la señal de ningún tejido tendrá tiempo de decaer, por lo que ni las diferencias en T₁ ni las en T₂ afectarán el nivel de la intensidad de la imagen (Hornak, J. and Fletcher, L., 1994).

En las imágenes pesadas en T₁ y T₂ la intensidad varía significativamente de tejido a tejido logrando muy buen contraste. Aun los tejidos en donde la densidad protónica es muy similar pueden poseer tiempos de relajación muy diferentes.

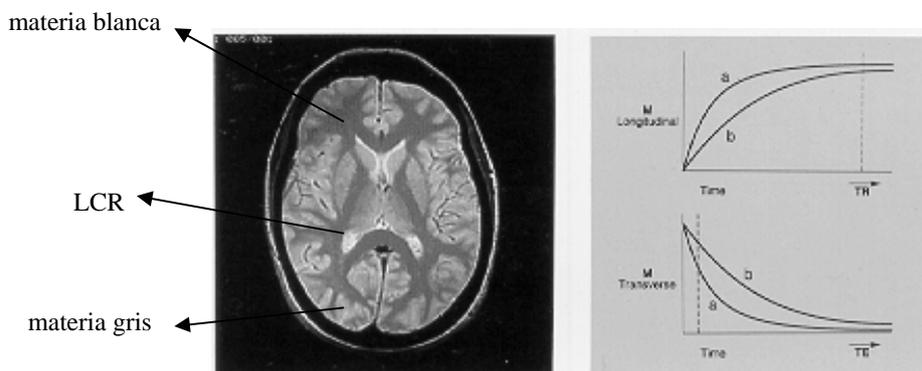


Fig.2-11 Ejemplo de imagen de densidad de protones obtenida utilizando un tiempo de repetición T_R largo de 6000 ms y un tiempo de eco T_E corto de 20 ms. En los dos gráficos los tejidos con diferente características de relajación son indicados como a y b.

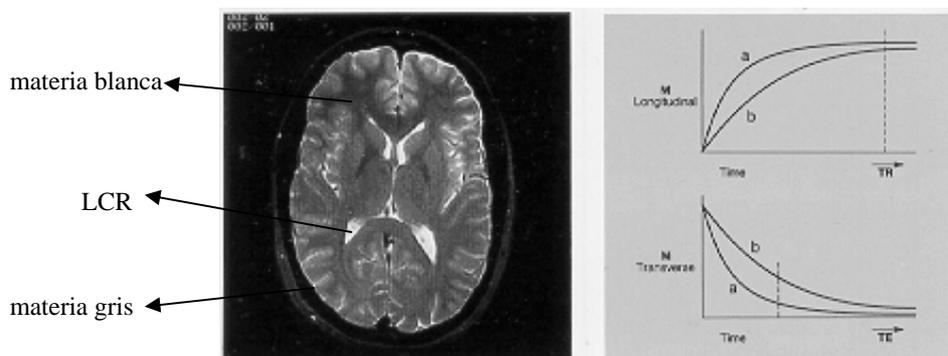


Fig.2-13 Ejemplo de imagen pesada en T_2 obtenida utilizando un tiempo de repetición T_R largo de 4000 ms y un tiempo de eco T_E corto de 80 ms. En los dos gráficos los tejidos con diferente características de relajación son indicados como a y b.

Las imágenes pesadas en T_2 presentan un buen contraste entre la materia gris y el LCE (liquido cerebro espinal) y poco contraste entre la materia gris y la materia blanca; esto se puede atribuir a que el tiempo T_2 esta directamente relacionado con las interacciones *spin-spin*. Como en el caso anterior si T_R es muy largo permite una completa recuperación de la magnitud longitudinal en ambos tejidos entre la secuencia *spin-echo*, mas allá de las variaciones de los valores de T_1 de los tejidos. A diferencia del caso anterior, las diferencias de T_2 serán reflejadas en las amplitudes de las señales. Dado que la señal no es detectada hasta un tiempo T_E después del pulso de 90° , la magnitud transversal de un tejido con T_2 corto decaerá más rápidamente que la de un tejido con un T_2 largo. El tejido de T_2

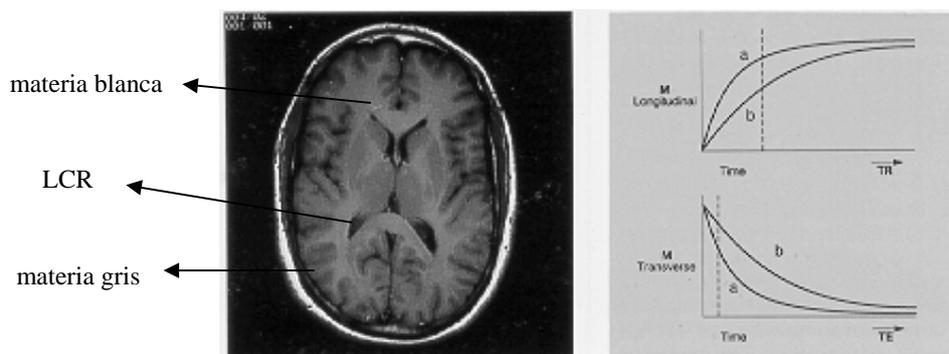


Fig.2-14 Ejemplo de imagen pesada en T_1 obtenida utilizando un tiempo un tiempo de eco T_E corto de 20 ms. y un tiempo de repetición T_R intermedio de 400 ms. Las estructuras de larga relajación son ahora de baja intensidad en la imagen.

largo contribuye con más señal, causando en la imagen de RM, una intensidad mayor de nivel de gris. Esta imagen se conoce como imagen pesada en T_2 (Ver figura 2-13). En estas imágenes se ve con mayor intensidad el líquido cefalo-ráquideo (LCR), luego la materia gris, la blanca y por último con el menor nivel de gris, la grasa subcutánea.

Por último, si se acorta T_R al rango de valores de T_1 de los tejidos ($T_E \gg T_2$), como en el primer caso, un T_E muy corto no permite tiempo suficiente para que decaiga la magnetización transversal significativamente, de manera que las variaciones de T_2 no afecten la intensidad de la señal. Sin embargo dado que T_R es corto, la cantidad de magnitud longitudinal presente inmediatamente antes de cada secuencia de excitación detección *spin-echo* dependerá de que tan rápido se recupere del pulso de excitación previo. Por lo tanto si el tejido tiene un T_1 menor, producirá una señal mayor y por lo tanto una intensidad en la imagen también mayor. Esta imagen se conoce como imagen pesada en T_1 (Ver figura 2-14).

En resumen, T_R controla T_1 y T_E controla T_2 . Los tejidos con tiempos de relajación T_2 cortos son oscuros en las imágenes pesadas en T_2 mientras que los tejidos con tiempos de relajación T_1 cortos son brillantes en las imágenes pesadas en T_1 . La tabla 2-2 se muestran valores de los tiempos de relajación T_1 y T_2 para los diferentes tejidos.

TEJIDO	T ₁ (ms)	T ₂ (ms)
materia blanca	390	90
materia gris	520	100
líquido cerebroespinal	2000	300
músculo esquelético	600	40
grasa	180	90
sangre	800	180

Tab. 2-2 Representación de los tiempos de relajación para los diferentes tejidos. (Valores en milisegundos medidos a 1 Tesla)

2.3 El rol de la RMN en la enfermedad de Alzheimer

La neuroimagen provee un importante apoyo para el diagnóstico clínico de la Enfermedad de Alzheimer, de la demencia vascular y de la demencia asociada con atrofia cortical. La imagen de RMN provee una imagen del cerebro que permite la diferenciación de los distintos tejidos y la identificación de estructuras neuroanatómicas. La imagen de RMN puede utilizarse para descartar lesiones e identificar distintos patrones de atrofia en diferentes enfermedades neurodegenerativas a diferencia de la Resonancia Magnética Funcional que puede diferenciar patrones de hipometabolismo que indican la presencia de un proceso degenerativo (Manes, F. 2000). Sin bien en la Enfermedad de Alzheimer se observa un patrón de hipometabolismo bitemporoparietal, la imagen funcional es todavía una herramienta de investigación y es utilizada en sólo dos centros en nuestro país. La Resonancia Magnética está relativamente disponible y debido a su alta resolución y mejor contraste de los tejidos blandos (respecto a la Tomografía Computada) posee una gran sensibilidad para los cambios que se producen en la Enfermedad de Alzheimer.

En 1994 el Subcomité de Estándares de Calidad de la Academia Americana de Neurología (Quality Standards Subcommittee of the American Academy of Neurology) publicó "práctica y parámetros" para la evaluación diagnóstica de personas sospechadas

de padecer demencias. Estas guías establecían la necesidad de un examen neurológico estándar y de ciertos análisis de laboratorio como componentes esenciales del procedimiento diagnóstico. Sin embargo, los estudios con neuroimágenes fueron sugeridos como opcionales.

Algunos años más tarde, en 1997, la utilidad de los parámetros sugeridos en 1994 para la evaluación de las demencias fue analizada a través de 119 casos. El principal resultado fue que los estudios de imágenes mejoraban la exactitud de los diagnósticos, aunque con un importante aumento en costos. El mayor interés de los investigadores en neuroradiología sobre la Enfermedad de Alzheimer ha sido la medición de la atrofia. La enfermedad de Alzheimer provoca una disminución en el tamaño del cerebro, especialmente alrededor de los lóbulos temporales y el área del hipocampo. Como contrapartida la fisura sucual y los ventrículos aumentan su tamaño. Sin embargo, se observa una considerable superposición cuando se compara con sujetos control añosos, ya que el envejecimiento normal también trae aparejado una reducción del pesos cerebral y un incremento en el volumen ventricular. El único método que se practica en nuestro país en la clínica de rutina es la evaluación visual del radiólogo y su opinión sobre si los surcos o el volumen ventricular están fuera del rango de normalidad. (Manes, F., 2000).

Teniendo en cuenta que las neuronas destruidas no pueden ser reemplazadas, uno de los objetivos primordiales de estos procedimientos diagnósticos es la detección de los primeros cambios en el cerebro que produce la enfermedad de Alzheimer. Esto permitiría que cualquier droga, experimental o no, pudiera detener el avance de la atrofia del cerebro, siendo administrada tempranamente.

El *Multicentre Consortium to Establish a Registry for Alzheimer's Disease* (CERAD) demostró que la evaluación visual de la atrofia generalizada era insatisfactoria y que la interpretación de las imágenes era altamente subjetiva. El CERAD determinó que se necesitaban técnicas de mayor precisión para medir la atrofia global (Davis, P., Gray, A., Albert, M. et al, 1992).

La textura en una imagen es una característica importante en el diagnóstico y es totalmente inherente a la percepción del ojo humano. Sin embargo la habilidad humana

para distinguir sutiles variaciones en las diferentes texturas, es bastante limitada. El análisis de imágenes de las diferentes texturas por computadora es una herramienta poderosa y la alta calidad de las imágenes RMN las hacen apropiadas para este tipo de análisis. Los esfuerzos apuntan entonces a cuantificar los diferentes tejidos cerebrales de una manera más automática, más sensible y sobre todo menos subjetiva y dar así un primer paso hacia el diagnóstico temprano de la atrofia cerebral que produce esta enfermedad.

Capítulo III

ANÁLISIS DE TEXTURAS

En muchos sistemas de visión artificial y en los algoritmos de procesamiento de imágenes se realizan simplificaciones acerca de la uniformidad de intensidad en regiones localizadas de la imagen. Sin embargo, imágenes de objetos reales a menudo exhiben regiones de intensidad no uniformes. En las imágenes de RMN, los diferentes tejidos no exhiben uniformidad y contienen variaciones de intensidad, las que forman ciertas estructuras o patrones repetidos llamadas texturas visuales. Estos patrones pueden ser el resultado de propiedades de los tejidos o podrían ser el resultado del propio sistema de medición.

El análisis de texturas es uno de los más importantes enfoques para el análisis de imágenes debido a que la mayoría de las superficies naturales exhiben características de texturas.

Los métodos convencionales de clasificación de imágenes están basados en las propiedades espectrales de los píxeles tratados de manera individual y, por tanto, no tienen en cuenta la textura. Los métodos de análisis textural proponen una alternativa para la clasificación de imágenes. Estos métodos se basan en discriminar texels en vez de píxeles.

3.1 Definición del concepto de textura

En general se puede ver o reconocer la textura presente en una imagen cualquiera, pero es sumamente difícil establecer un concepto que defina concretamente a la textura. Ésta se observa en forma de patrones estructurales en superficies de objetos tales como madera, algodón, granos, arena. La textura es una propiedad que se puede ver o reconocer en la superficie de los objetos. Desde el punto de vista conceptual es difícil establecer una definición concreta de la misma. Sin embargo, textura se puede definir como la manera que

están dispuestas las partículas o sustancias que se distinguen macroscópicamente como integrantes de una misma región.

La dificultad enunciada en el comienzo se demuestra por el número de definiciones diferentes de textura a las que se llega en función, tanto de, la aplicación que persiga, como del enfoque elegido. La noción de *textura* no es plausible de una descripción muy rígida. La siguiente es una definición de diccionario: “*textura es alguna cosa compuesta de elementos entretejidos cercanos, o apretados*”.

Si se considera a la textura como parte integrante de una región macroscópica, su estructura se atribuye simplemente a patrones repetitivos en los que los elementos primitivos se hallan ordenados de acuerdo a una regla dada. Desde este enfoque el término textura se utiliza para caracterizar la distribución espacial de los elementos de una imagen (Fukunaga, K., 1985). Se considera la textura como una organización, que una vez descompuesta, presenta dos características básicas que la definen: la señal o intensidad de los píxeles que forman la imagen, y las interacciones o dependencias espaciales entre esos píxeles.

Otra aproximación a la definición de textura se enuncia a continuación: *la textura* se refiere a la impresión de rugosidad que presentan algunas superficies, y que es creada por las variaciones de tonos o repetición de patrones visuales en la misma (Russ, J., 1995).

Mather y Frohn la entendieron como una variabilidad local de la reflectancia dentro de una unidad que a mayor escala se puede considerar como homogénea (Mather, 1976; Frohn, 1997). Profundizando la definición anterior, se puede hablar de textura como la repetición de elementos de textura básicos llamados *texels* (*texture element*).

Un texel contiene varios pixels, cuya ubicación y/o localización podría ser de las siguientes formas:

- Periódica
- Cuasi-periódica
- Aleatoria

Otro nombre que reciben los *texels* es el de *primitivas de nivel de gris*. Las primitivas de nivel de gris, son regiones con diferentes propiedades en cuanto a nivel de gris. Éstas se pueden describir en términos de nivel de gris promedio, o de máximos y mínimos niveles de gris dentro de su región. Una región es un conjunto conectado de pixels que tienen una determinada propiedad de nivel de gris. La región de nivel de gris se puede evaluar en función de su forma y su área. Las primitivas de nivel de gris incluyen ambos, su nivel de gris y las propiedades de la región de nivel de gris. De esto se desprende que las *primitivas de nivel de gris* son lo que se denominó con anterioridad *texel*. De aquí en más se mencionará indistintamente a los términos planteados.

Se puede pensar a la textura de una imagen digital como un fenómeno que se puede descomponer en un análisis de dos dimensiones. La primera, está relacionada con las primitivas de nivel de gris o propiedades locales que constituyen la textura de una imagen. La segunda dimensión hace alusión a la distribución espacial de las primitivas de nivel de gris.

Una textura en una imagen se puede intentar describir por el número y tipos de sus *texels* y sus relaciones u organización espacial. Ésta puede ser aleatoria, puede tener una dependencia de a pares de un *texel* respecto a su vecino, o puede tener una dependencia de n *texels* de una vez. La dependencia puede ser estructural, probabilístico, o funcional como una dependencia lineal (Duda, R. & Hart, P., 1973).

3.1.1 Descripción de la textura

Se puede intentar describir a la textura en una imagen digital por el número y tipo de sus *texels* y sus relaciones u organización espacial. Para llevar a cabo esta descripción, se puede descomponer el análisis en dos dimensiones:

- La primera dimensión está relacionada con el número y tipo de *texels* que constituyen la textura de la imagen.
- La segunda dimensión está relacionada con la distribución espacial de los *texels*.

La distribución espacial de los texels puede ser aleatoria, puede tener una dependencia de un texel respecto a su vecino de a pares, o de n texels a la una vez. La dependencia puede ser estructural, probabilística, o funcional .

La textura en la imagen puede ser evaluada cuantitativamente en la medida en que tenga una o más de las siguientes propiedades: fineza, tersura, granulación, uniformidad, aleatoriedad. Cada una de estas cualidades se traducen en algunas propiedades de los texels y la interacción espacial entre ellos.

3.1.2 Resolución de textura

Podemos pensar a la resolución de la textura como la cantidad promedio de pixels para cada texel discernible. Los texels están íntimamente ligados a la resolución de la textura.

Cuando la cantidad promedio de pixels es un número grande, se puede intentar describir a los elementos individuales con algún grado de detalle. A medida que éste número se hace cercano a la unidad se torna difícil caracterizar a estos elementos individuales y por lo tanto se pierden los patrones espaciales distintivos.

En la Figura 3-1 se pueden ver ejemplos de imágenes de baja resolución. Las mismas no poseen elementos distintivos que se puedan detectar en forma sencilla, lo que no significa que no exista la posibilidad de encontrar elementos primitivos.

En la Figura 3-2 se presentan dos imágenes que son ejemplos de textura de alta resolución. En las mismas se pueden observar que los elementos primitivos repetidos son evidentes.

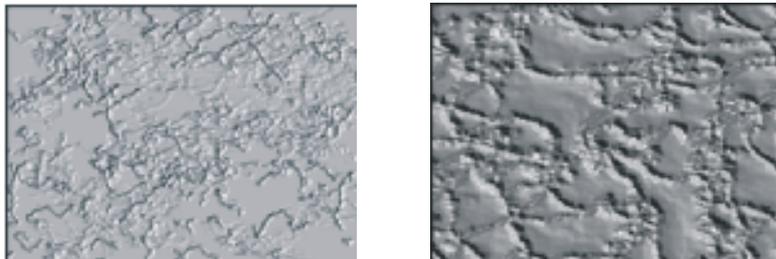


Fig. 3-1 Ejemplo de texturas de baja resolución.

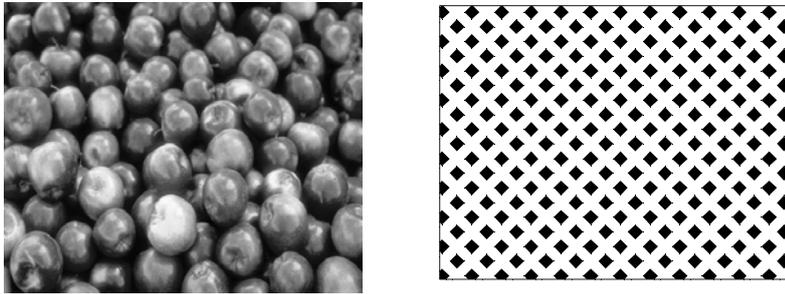


Fig. 3-2 Ejemplos de texturas de alta resolución

3.1.3 Nivel de gris y textura

Para usar el nivel de gris y los elementos de textura en forma objetiva, se debe tratar de definir lo mejor posible los conceptos de nivel de gris y textura. Se verá que los mismos no son independientes, los une una relación del tipo onda-partícula pero en un grado de interrelación muy superior. Todo lo que existe tiene ambas propiedades, de comportarse como onda o partícula dependiendo de la situación, de esta forma prevalecerán las propiedades de un efecto o el otro. Análogamente en el contexto de una imagen, esta tiene siempre presente al nivel de gris y a la textura, existirán veces en que una propiedad pueda dominar a la otra. Por lo tanto, cuando estamos definiendo explícitamente nivel de gris y textura, no se están definiendo dos conceptos aislados, sino uno que abarca a los dos: *textura-nivel de gris*.

Las interrelaciones básicas en el concepto textura-nivel de gris son las siguientes: cuando en un área pequeña, de aquí en más llamada *patch*, de una imagen existen pocas variaciones en el nivel de gris de las primitivas, la propiedad dominante de esa región es el nivel de gris. En contrapartida cuando se tiene un patch con gran variación del nivel de gris de las primitivas, la propiedad predominante es la textura. Es crucial en esta distinción el tamaño del área pequeña, los tamaños relativos y los tipos de primitivas de nivel de gris, y el número y forma de disposición de las primitivas. A medida que la cantidad de primitivas distinguibles disminuyen predominarán las propiedades del nivel de gris. Si nos colocamos en el caso extremo, cuando el patch sea del tamaño de un pixel, existe sólo una característica, la única propiedad presente es el nivel de gris del pixel en cuestión. Cuando

se incrementa el número de primitivas de nivel de gris dentro del patch, las propiedades de textura adquirirán relevancia. En tanto que si el patrón espacial de las primitivas es aleatorio y las variaciones de nivel de gris entre primitivas son importantes, se estará en presencia de una *textura fina*. A medida que la ubicación espacial se torna más definida y las regiones de nivel de gris involucran mayor cantidad de pixels estamos en presencia de una *textura gruesa*.

En resumen, para caracterizar la textura de una imagen dada se deben caracterizar las propiedades de las primitivas de nivel de gris como así mismo las relaciones espaciales entre ellas. Esto implica que la textura es una estructura de dos capas, la primera tiene relación directa con las propiedades locales de los texels; la segunda apunta a la organización espacial de los texels.

3.1.4 Propiedades de las texturas

Para poder encontrar un modelo matemático representativo de la textura de una imagen es necesario identificar características que denoten la textura o bien investigar particularidades que marquen diferencias entre las texturas de la imagen.

La textura en una imagen presenta las siguientes propiedades:

- La textura es una propiedad de áreas. Su definición involucra niveles de gris en un entorno del espacio. El tamaño del entorno depende del tipo de textura, o bien de los texels que se tomen en cuenta para definir a la textura en la imagen.
- La textura de un punto no está definida.
- La textura involucra la distribución espacial de los niveles de gris. Por lo tanto un histograma en dos dimensiones o matrices de co-ocurrencia son herramientas razonables para el análisis de textura.
- La textura en una imagen se percibe cuando no se presentan formas individuales significativas, es decir, el número de texels debe ser grande. Si se presentan sólo unos pocos objetos, lo que se tiene entonces es, un conjunto de objetos en lugar de una imagen con textura.

- La textura en una imagen se puede percibir en diferentes escalas o niveles de resolución de la textura.

Por ejemplo la resolución de textura gruesa (baja resolución) se percibe una textura formada por rombos que componen la malla de la Figura 3-3; mientras que la resolución de la textura fina (alta resolución), si se considera un campo de visión que abarque el interior de un rombo de la trama, se pueden observar los detalles de la textura de cada rombo.

3.2 Modelos para la clasificación de texturas

Las técnicas de análisis de texturas se basan en asignarle a cada región de la imagen uno o varios parámetros indicadores de características de la textura presente. Estos parámetros o característicos se utilizan como patrones en una posterior clasificación. De acuerdo al tipo de problema se utilizan técnicas de Reconocimiento de Patrones supervisadas o no supervisadas (Gonzalez R., Woods R. , 1982; Cernuschi Frias B. , Belausteguigoitia C., 1987).

Las técnicas texturales difieren entre sí en la metodología de calcular y obtener los característicos que definen la textura. Debido a que la distribución de los pixels en una determinada textura puede adoptar diversas estructuras, ya sea periódica, cuasiperiódica o aleatoria, es conveniente efectuar el tratamiento por textura bajo enfoques diferentes. Al no existir unanimidad general sobre el significado de textura y teniendo en cuenta que además ésta se define a partir del uso combinado de múltiples informaciones, su utilización para la segmentación de formas presenta mayores dificultades que en el caso de superficies de intensidades.

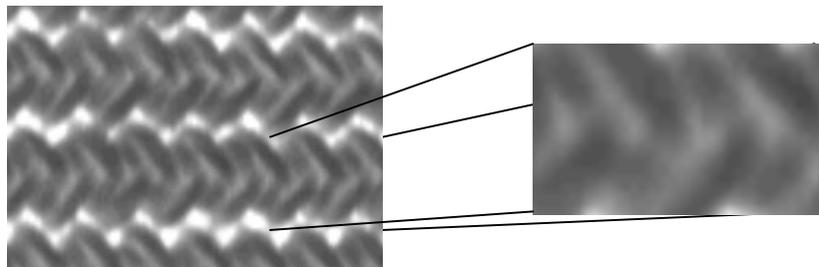


Fig. 3-3 Ejemplos de textura gruesa y textura fina.

Existen diversos modelos que permiten la caracterización de texturas. Entre los más utilizados se analizaron y probaron los siguientes:

- Métodos estadísticos: Matrices de co-ocurrencia, autocorrelación. (Argenti, F. et al., 1990)
- Métodos geométricos: Características basadas en la partición de Voronoi. (Bertin, E.; Parazza, F., Chassery, J.M., 1993).
- Métodos basados en modelos: Campos aleatorios Markovianos, fractales. (Chen, Y.Q., and Bi, G., 1999; Kaplan, L.M., 1999).
- Métodos espectrales: Transformada de Fourier, Modelos de Gabor, Wavelet. (Moler, E., Ballarin, V., 1999; Mojsilović, A. et al. 2000).
- Métodos de Morfología Matemática: Granulometría. (Dougherty, E. and Sand, F., 1995; Ballarin et al. 2001)

Todos estos métodos permiten la extracción de distintos característicos, desde distintas metodologías, para la posterior clasificación de texturas (Moler, E. et al., 1999; Burril, J., 2000). Sin embargo no todos los característicos permiten esta detección en forma eficiente de los diferentes tejidos en las imágenes de RMN. Es importante realizar análisis específicos de las características intrínsecas de las diferentes texturas en las imágenes de RMN y de los parámetros calculados para utilizar aquellos que sean más adecuados para este fin (Vincent L., Dougherty E., 1994).

3.3 Enfoque Geométrico

Bajo este enfoque se pueden analizar aquellos casos en que los texels forman patrones que se repiten en la imagen y se describe por medio de reglas para generar dichos patrones.

Los texels están íntimamente ligados a la resolución de textura, en la que podríamos pensar como cantidad promedio de pixels para cada elemento de textura discernible. Si este número es grande, podemos intentar describir los elementos individuales en algún detalle. Sin embargo, en la medida que este número sea cercano a la unidad se tornará sumamente

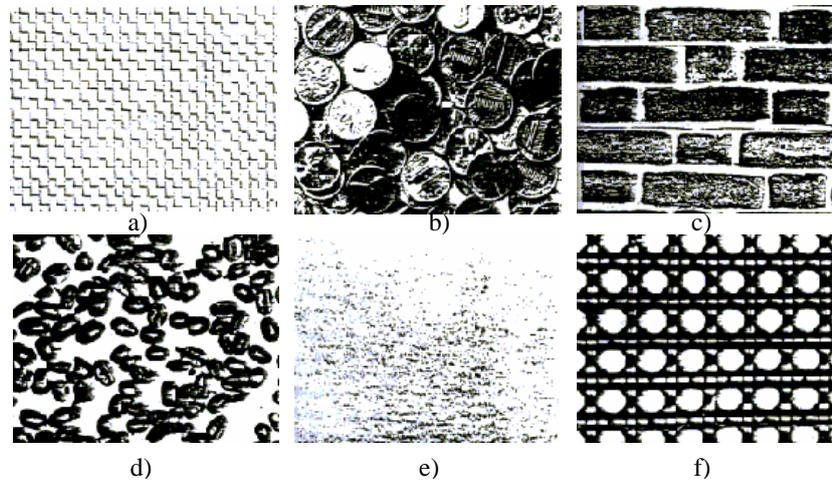


Fig. 3-4 Ejemplos de texturas: a) alambre trenzado, b) monedas, c) pared de ladrillos, d) granos de café, e) papel, f) caña.

difícil caracterizar estos elementos individuales y se caerá en la pérdida de patrones espaciales distintivos. Para poder visualizar esto, examinaremos algunas texturas.

En la Figura 3-4 se detallan seis imágenes correspondientes a alambre trenzado., monedas, pared de ladrillos, granos de café, papel y caña.

Cinco de estos ejemplos son de textura de alta resolución: Muestran elementos primitivos repetidos que exhiben alguna especie de variación. Los granos de café, las monedas y la pared de ladrillos todos tienen elementos primitivos obvios. Dos ejemplos más ilustran adicionalmente que, el que estudia, algunas veces tiene que ser creativo a la hora de definir los elementos primitivos. En la imagen de la caña los elementos primitivos más fáciles de distinguir son los huecos en la textura, como contrapartida, la textura del papel no es apta para introducirla en este modelo. Esto, sin embargo, no quiere decir que no exista posibilidad de encontrar elementos primitivos. Una alternativa sería analizar las zonas brillantes en contraste con las oscuras. Pero como los texels, para este caso, tienen dimensiones muy pequeñas en relación con el tamaño de los píxeles, en consecuencia llegaríamos a analizar píxel a píxel perdiendo de vista el enfoque de la textura.

Una pregunta surge: ¿Cuál deberá ser el número de texels de la subimagen que se utilice para una correcta definición de textura? Imaginemos una ventana que corresponde a nuestro campo de visión sobreimpuesta a un área de textura muy grande. A medida que la ventana se torne más y más pequeña, a medida que acercamos nuestro punto de visión, cada vez entrarán menos elementos primitivos en la ventana. En algún punto de nuestra aproximación, la imagen en la ventana, ya no aparecerá con textura; o si lo es, la traslación de la ventana cambia la textura que se percibe drásticamente. En este punto nosotros ya no tenemos una textura. Un efecto similar ocurre si la ventana se torna muy grande, correspondiente al caso en que movemos el campo de observación de forma que nos alejamos de la imagen. En forma análoga al caso descrito anteriormente, los detalles de la textura se pierden y no son plausibles de detección alguna.

Lo anterior nos acerca a la idea de que una correcta resolución, o el número de texels en una subimagen, es una parte implícita de nuestra definición cualitativa de textura. Si la resolución es apropiada, la textura será aparente y observaremos lo mismo a medida que el campo de observación se traslade a través del área de la textura en cuestión. Se tiene que la mayoría de las veces la resolución apropiada no es conocida pero debe ser computada. A menudo este tratamiento computacional es más simple de llevar a cabo que caracterizaciones computacionales más detalladas de las primitivas, y por ende es el precursor de los métodos de análisis modernos implementados a través del uso de computadora.

Una poderosa forma de describir las reglas que gobiernan el modelo estructural es a través del *grammar*. ¿Qué es esto del *grammar*? El mismo describe cómo se generan los patrones aplicando reglas de re-escritura a un pequeño número de símbolos. Formalmente estas reglas son conocidas como *grammar* o gramaticales, que son el conjunto de reglas que se aplican a símbolos en forma repetitiva con el fin de replicar una textura del mundo real. Basándose en una cantidad reducida de símbolos y reglas, el *grammar* puede generar patrones de textura complejos. Por supuesto los símbolos a los que se refiere se encuentran estrechamente relacionados con nuestro ya conocido texel.

En una primera etapa en el desarrollo experimental de esta tesis se implementaron los algoritmos y se realizaron algunas pruebas con las imágenes de RMN, pero, como era

de esperarse, al tratarse de texturas finas sin regularidad no resultaron aptas para extraer características a través de este enfoque.

3.4 Enfoque Estadístico

Cuando las texturas no tienen la regularidad geométrica a veces presentan variaciones que no se pueden describir en forma satisfactoria por las formas, pero son descritas mejor por modelos estadísticos. Un claro ejemplo de estos casos lo constituyen las imágenes aéreas, tanto las provenientes de satélites; como las de fotografía aérea, que tienen elementos primitivos apenas discernibles. Estos tipos de texturas presentan variaciones que no se pueden describir mediante la forma de manera satisfactoria y para las cuales es más adecuado emplear modelos estadísticos. En un principio este enfoque parecía factible ya que describe texturas basándose en reglas estadísticas, que gobiernan la distribución y la relación de niveles de gris. (Cernuschi Frías, B., 1987; Argenti, F. et al., 1990.)

3.4.1 Método de Histogramas

Uno de los enfoques más simples para describir la textura de una imagen digital, consiste en el uso de los momentos del histograma de los niveles de gris de una imagen o región (Gonzalez, R. & Woods, R. 1992). Se asume z como una variable aleatoria que denota la intensidad discreta de la imagen y se define $p(z_i)$, $i=1, 2, \dots, L$ como el histograma correspondiente. Donde L es el número de los distintos niveles de intensidad. Se define el momento n -ésimo de z en torno de la *media* como:

$$\mu_n(z) = \sum_{i=1}^L (z_i - m)^n \cdot p(z_i) \quad (3-1)$$

Donde m es el valor medio, media o la intensidad promedio. Ésta viene dada por:

$$m = \sum_{i=1}^L z_i \cdot p(z_i) \quad (3-2)$$

Se debe observar a partir de la Eq. 3-1 que $\mu_0=1$ y $\mu_1=0$. El segundo momento, también se conoce con el nombre de varianza y se denota al mismo $\sigma^2(z)$, es de particular importancia en el análisis de texturas. Ésta es una medida de contraste de niveles de gris, que se puede usar para establecer descripciones de uniformidad o suavidad relativa (Burril, J., 2000). Por ejemplo, la medida:

$$R = 1 - \frac{1}{1 + \sigma^2(z)} \quad (3-3)$$

Es igual a cero para áreas de intensidad constante, en donde se tiene: $\sigma^2(z)=0$ si todos los z_i tienen el mismo valor de nivel de gris.

Cuando sólo se utiliza en el proceso de medición de la textura el histograma de la imagen, se sufre la limitación de no contar con información de la posición relativa de los pixels de unos en relación con los demás. Una manera para tener este tipo de información en el análisis de textura es considerar no sólo la distribución de las intensidades, sino también la posición de los pixels con igual o aproximadamente igual valor de intensidad (Jain, A., 1989).

En determinadas situaciones es útil considerar no sólo la distribución de las intensidades, sino también la posición de los pixels con igual o aproximadamente igual valor de intensidad. La dependencia espacial de los niveles de gris permite caracterizar una textura a través de la co-ocurrencia de sus niveles de gris. La textura gruesa es aquella en la que la distribución varía pobremente conforme se incrementa la distancia mientras que en la textura fina la distribución varía rápidamente.

3.4.2 Matriz de Co-ocurrencia de niveles de gris

El enfoque de la dependencia espacial de los niveles de gris caracteriza a la textura a través de la *co-ocurrencia* de sus niveles de gris. La textura gruesa es aquella en la que la distribución varía pobremente conforme se incrementa la distancia. Por otro lado en la textura fina la distribución cambia rápidamente con la distancia.

La co-ocurrencia de los niveles de gris se puede especificar en una matriz de frecuencias relativas (con elementos p_{ij}) en la que dos pixels vecinos separados por una distancia d ocurren en la imagen, uno con nivel de gris i y el otro con nivel de gris j . Las matrices de frecuencia de dependencia espacial de niveles de gris son simétricas y función de la relación angular entre los pixels vecinos así como función de la distancia entre ellos. Por ejemplo, para una relación angular de 0° , los valores de la matriz de frecuencias relativas explicitan la probabilidad de una transición de derecha a izquierda y de izquierda a derecha de un nivel de gris i a otro j . Si la imagen a tratar posee G niveles de gris la matriz de frecuencias relativas tendrá la dimensión de $G \times G$.

Se define a la *matriz de co-ocurrencia*, como la matriz de frecuencia relativas, conformada con elementos que representan la cantidad de veces que una dada combinación de niveles de gris se repiten en una imagen (Jain, A., 1989; Argenti, F. et al., 1990). Debe considerarse la distancia de los pixels a procesar (d), y también la dirección (a) en la cual se analiza la imagen.

El conjunto de todos los pixeles vecinos horizontales separados por una distancia d , está dado por:

$$R_H = \{(k,l), (m,n)\} \in (L_y \times L_x) \times (L_y \times L_x) / k - m = 0, |l - n| = d \} \quad (3-4)$$

donde $(L_y \times L_x) \times (L_y \times L_x)$ es el conjunto de valores que representa la ventana de análisis; L_y es el conjunto de valores de gris en dirección vertical y L_x es el conjunto de valores de gris en dirección horizontal.

Considerando ángulos espaciados a intervalos de 45° , distancia $d=1$ y denotando por $\#$ al cardinal del conjunto, las diferentes matrices son las siguientes:

$$p(i,j) / [d=1, a=0^\circ] = \# \{ [(k,l), (m,n)] / k - m = 0, |l - n| = d, I(k,l) = i, I(m,n) = j \} \quad (3-5)$$

$$\begin{aligned}
 p(i, j) / [d=1, a=45^\circ] &= \# \{[(k, l), (m, n)] / \\
 &\quad (k - m = d, l - n = -d) \\
 &\quad (k - m = -d, l - n = d) \\
 &\quad I(k, l) = i, I(m, n) = j\} \quad (3-6)
 \end{aligned}$$

$$\begin{aligned}
 p(i, j) / [d=1, a=90^\circ] &= \# \{[(k, l), (m, n)] / \\
 &\quad |k - m = d|, l - n = 0 \\
 &\quad I(k, l) = i, I(m, n) = j\} \quad (3-7)
 \end{aligned}$$

$$\begin{aligned}
 p(i, j) / [d=1, a=135^\circ] &= \# \{[(k, l), (m, n)] / \\
 &\quad (k - m = d, l - n = d) \\
 &\quad (k - m = -d, l - n = -d) \\
 &\quad I(k, l) = i, I(m, n) = j\} \quad (3-8)
 \end{aligned}$$

donde # denota el número de elementos en el conjunto. El tamaño de las matrices de co-ocurrencia está determinado sólo por el número de los diferentes niveles de gris de la imagen que se está analizando.

A partir de las matrices de co-ocurrencia se pueden calcular diversos valores característicos. Estos valores serán elementos del vector de característicos, que se utilizará como dato de entrada en algoritmos de Reconocimiento de Patrones. Los valores característicos más relevantes son (Jain, A., 1989):

- Entropía de Shannon:

$$\sum_{ij} p_{ij} \log p_{ij} \quad (3-9)$$

- Momento Diferencial de Orden k (Contraste):

$$\sum_{ij} |i - j|^k (p_{ij})^p \quad (3-10)$$

- Momento Diferencial inverso de orden k:

$$\sum_{\substack{ij \\ i \neq j}} \frac{(p_{ij})^p}{|i - j|^k} \quad (3-11)$$

- Probabilidad máxima:

$$\max_{ij} p_{ij} \quad (3-12)$$

La interpretación visual de estos característicos es la siguiente (Jain, A., 1989):

- La entropía es una medida de la aleatoriedad de la ocurrencia de los diferentes niveles de gris. Alcanza su valor máximo cuando todos los elementos de la matriz de co-ocurrencia son iguales. Una imagen que presente un solo nivel de gris tendrá entropía igual a cero. Si la imagen presenta diferentes niveles de gris su entropía crece.
- El momento diferencial de orden k, más significativo en una imagen es cuando k=2. Este momento se denomina contraste. Este característico asumirá valores relativamente bajos cuando los valores altos de la matriz de co-ocurrencia se sucedan cercanos a la diagonal principal.
- El Momento Diferencial inverso de orden k (k=2) expresa la situación opuesta expresada anteriormente. Proporcionará valores pequeños cuando la imagen presente grandes variaciones de contraste y viceversa.
- La Probabilidad Máxima es el máximo elemento de la matriz de co-ocurrencia.

El poder del método de las matrices de co-ocurrencia, radica en que caracteriza las interrelaciones espaciales de los niveles de gris en patrones de textura. Esta relación la hace de manera tal que es invariante a los niveles de gris. Su debilidad, que de hecho lo tiene, es que no captura aspectos de la forma de las primitivas de nivel de gris. Por lo tanto no es apto para trabajar con imágenes de textura que contengan texels de gran tamaño. Tampoco

se puede, por medio de este enfoque, detectar la relación espacial entre primitivas cuyo tamaño sea mayor a un pixel.

Surge en este punto la cuestión acerca de cuándo es adecuado el uso de este enfoque. La respuesta nos encamina a tratar con imágenes que posean dependencia espacial de los niveles de gris en las cuales la información que aporta la textura es sustancialmente alta. No es el caso de esta tesis.

3.4.3 Método de Función Autocorrelación

La textura relaciona el tamaño espacial de las primitivas de nivel de gris en una imagen. Por ejemplo, las primitivas de nivel de gris de gran tamaño son indicativas de textura gruesa; por contrapartida los texels de talla pequeña delatan textura fina. Desde este punto de vista, la función de autocorrelación es una característica que describe el tamaño de las primitivas de nivel de gris y por lo tanto de la textura presente.

Para comprender mejor la función autocorrelación imaginemos dos transparencias de imágenes (filminas), las cuales son idénticas. Se procede a superponer una imagen encima de la otra, se aplica una fuente de luz uniforme a través de las transparencias. Se mide el promedio de luz que se propaga a través de ellas. Ahora se traslada una transparencia respecto de la otra y se mide sólo el promedio de luz que atraviesa la porción de la imagen donde una transparencia solapa a la imagen trasladada. La función de autocorrelación bidimensional (2-D) de la transparencia de la imagen, es su promedio normalizado respecto de la traslación desde el origen $i=0, j=0$.

Formalmente, se parte de la definición de la función de autocorrelación en el campo continuo para luego llegar a la autocorrelación establecida en el mundo discreto. Sea $f(x,y)$ una función continua, su correspondiente autocorrelación se define como:

$$R(\tau_1, \tau_2) = \int \int_{-\infty}^{+\infty} f(x + \tau_1, y + \tau_2) f^*(x, y) dx dy \quad (3-13)$$

Se define el coeficiente de autocorrelación como, la función de autocorrelación dividida el valor máximo, que como se sabe se encuentra en el origen. Es decir, cuando se toma la autocorrelación en cero: $\tau_1 = 0$ y $\tau_2 = 0$.

$$\rho(x, y) = \frac{R(\tau_1, \tau_2)}{R(0,0)} = \frac{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x + \tau_1, y + \tau_2) f^*(x, y) dx dy}{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} |f(x, y)|^2 dx dy} \quad (3-14)$$

En forma análoga, se procede a plantear la función autocorrelación al caso discreto, que es el que se tiene al tratar con imágenes digitales. Formalmente el coeficiente de autocorrelación para una imagen $Z(i,j)$, cuyo tamaño es de $N \times N$ pixels viene dada por:

$$\rho(i, j) = \frac{R(i, j)}{R(0,0)} = \frac{\sum_{u=0}^N \sum_{v=0}^N I(u, v) I(u + x, v + y)}{\sum_{u=0}^N \sum_{v=0}^N I^2(u, v)} \quad (3-15)$$

Las variables (u,v) presentes en la ecuación anterior son las que se utilizan para llevar a cabo los desplazamientos a los que en el párrafo anterior se hace alusión.

El concepto que encierra la función de autocorrelación es dar una idea de cuan semejante es una imagen en sí misma. Aplicado el concepto a la textura se tiene: si las primitivas de nivel de gris sobre la imagen son relativamente grandes, entonces la función de autocorrelación disminuye lentamente conforme aumenta la distancia. En contrapartida, si las primitivas de nivel de gris son pequeñas, la función de autocorrelación disminuye rápidamente con la distancia. Se extiende la idea presentada hasta el momento al caso de tener primitivas de nivel de gris que se repiten periódicamente, la función de autocorrelación disminuye y vuelve a crecer en forma periódica como lo hace la repetición de las primitivas. Vale la pena recordar que la autocorrelación de una señal periódica da una función de autocorrelación periódica.

Las primitivas de nivel de gris en el modelo de la autocorrelación son los niveles de gris. La organización espacial se caracteriza por los coeficientes de correlación que

establecen una medida de la dependencia lineal de un pixel con otro (Haralick R., Shapiro L., 1992).

Este enfoque resultó excesivamente lento y los resultados tampoco fueron satisfactorios en el desarrollo experimental de esta tesis.

3.5 Enfoque Espectral

Las técnicas espectrales se basan en las propiedades del espectro de Fourier. La imagen se analiza globalmente identificando la energía porcentual del pico. Puesto que el grado de rusticidad de la textura es proporcional al periodo espacial, una región de textura gruesa deberá tener su energía espectral de Fourier concentrada en las frecuencias espaciales bajas. Contrariamente, las regiones de textura fina mostrarán una concentración de energía espectral en las altas frecuencias espaciales (Leguizamón, S., 1989).

3.5.1 Métodos frecuenciales

El análisis de textura bajo esta metodología se obtiene en términos del *espectro de Fourier* de una imagen. Se considera que el grado de rugosidad o suavidad de una textura es proporcional al período espacial. Por lo tanto, una región de textura gruesa deberá tener su energía espectral de Fourier concentrada en las bajas frecuencias espaciales. Contrariamente, las regiones de textura fina mostrarán una concentración de energía espectral en las altas frecuencias espaciales.

Bajo este enfoque, se puede utilizar para caracterizar una textura presente en una imagen el valor de entropía que presenta la misma. Este concepto, análogo al utilizado en el área de comunicaciones, se lo considera como una medida de probabilidad de la ocurrencia de distintas frecuencias en regiones determinadas del dominio frecuencial, la cual está ligado a la densidad espectral de energía de esa región. El modelo de entropía frecuencial refleja la distribución de las componentes espectrales de una determinada banda.

Si se considera a R como una región determinada en el dominio de la frecuencia, la energía total de la región se obtiene como:

$$e_t = \sum_{u,v \in R} S(u,v) \quad (3-16)$$

donde $S(u,v) = |F(u,v)|^2$ es la densidad espectral de potencia. Definiendo a la entropía de las componentes espaciales de la región R como:

$$h = - \sum_{u,v \in R} [p(u,v) \cdot \log p(u,v)] \quad (3-17)$$

donde $p(u,v)$ son los valores de energía total de la región normalizados, es decir:

$$p(u,v) = S(u,v) / ET \quad (3-18)$$

Por medio de este parámetro se puede caracterizar la textura en el dominio frecuencial en distintas regiones del plano, ya que si una textura es espacialmente periódica o direccional, su espectro de potencia tiende a tener picos correspondientes a la distribución espacial de frecuencias. Por lo tanto estos picos aportan información relevante sobre la imagen y pueden caracterizarse por este parámetro.

Para definir a estos característicos se debe particionar el espacio de Fourier para determinar las distintas regiones R . Esta partición en regiones (bandas de frecuencias o *bins*) se puede realizar en forma radial o angular. Estos bins, junto con el espectro de potencias de Fourier son utilizados para determinar los característicos.

Los característicos radiales están dados, en el dominio continuo, por:

$$\begin{aligned} V_{r_1 r_2} &= \iint_{R_{u,v}} |F(u,v)|^2 du dv \\ &= \iint_{R_{r_1, r_2}} |F(r \cos \theta, r \sin \theta)|^2 J(r, \theta) dr d\theta \\ &= \int_0^{2\pi} \int_{r_1}^{r_2} |F(r \cos \theta, r \sin \theta)|^2 r dr d\theta \end{aligned} \quad (3-19)$$

Siendo F la transformada de Fourier de la imagen, $J(r,\theta)$ el Jacobiano de transformación, los límites de integración están definidos por:

$$r_1^2 \leq u^2 + v^2 < r_2^2 \quad 0 \leq \theta < 2\pi \quad (3-20)$$

Donde $[r_1, r_2]$ es un bin radial y (u, v) es un vector definido por los diferentes valores de r_1 y r_2 . (Ver Fig. 3-5.)

Una textura suave tendrá valores elevados de $V_{r_1 r_2}$ para radios pequeños, en tanto una textura gruesa tiende a tener valores altos para radios grandes.

En forma análoga, los distintivos que miden la orientación angular están dados por:

$$\begin{aligned} V_{\theta_1 \theta_2} &= \iint |F(u, v)|^2 du dv \\ &= \int_{\theta_1}^{\theta_2} \int_0^{+\infty} |F(r \cos \theta, r \sin \theta)|^2 r dr d\theta \end{aligned} \quad (3-21)$$

donde los límites de integración están definidos por:

$$\theta_1 \leq \tan^{-1}\left(\frac{v}{u}\right) \leq \theta_2 ; \quad 0 < u, v \leq n-1 \quad (3-22)$$

donde (θ_1, θ_2) es uno de los sectores circulares y v está definido por diferentes valores de θ_1 y θ_2 . Estos distintivos expresan la sensibilidad del espectro de potencia hacia la direccionalidad de la textura. Si se presenta una textura rica en líneas y bordes en una determinada dirección, el espectro de potencia se inclina a tener niveles altos agrupados alrededor de la dirección $\theta + \pi/2$ de la frecuencia espacial.

A partir de lo anterior se define el vector de características de entropía H formado por cada valor de entropía en la región R_i (Leguizamón, S., 1989). Este vector se utilizará como dato de entrada al aplicar un algoritmo de clasificación para separar las diferentes texturas de una imagen.

Estos algoritmos resultaron ser los más lentos e ineficientes al no encontrar periodicidad alguna en las texturas presentes en las imágenes de RMN.

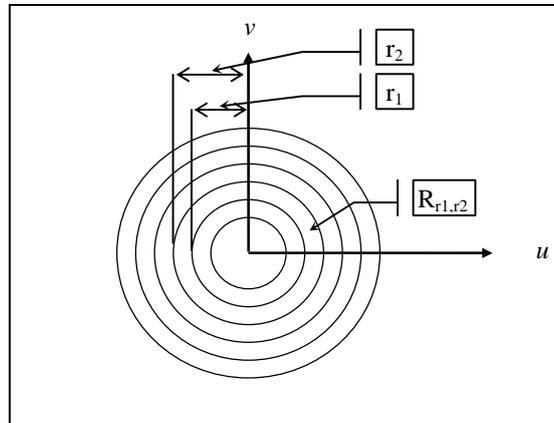


Figura 3-5. Límites de los bins radiales.

3.6 Enfoque Morfológico

La Morfología Matemática es una teoría de operadores y funcionales de imágenes basadas en teoría de conjuntos, conceptos geométricos y topológicos (Serra, J. 1982).. Basado en esta teoría, el Criterio de Tamaños por aperturas sucesivas analiza cómo interactúa la imagen con elementos estructurantes crecientes (Vincent L., Dougherty E., 1994).

La idea de este enfoque es segmentar regiones por textura tomando para cada pixel un vector de características obtenidas a través de operaciones morfológicas, que indican una medida de textura presente en dicho punto. Las características asociadas a cada pixel se obtienen de aplicar el Criterio de Tamaños de Aperturas Sucesivas sobre una máscara centrada en un pixel. El Criterio de Tamaños, involucra las transformaciones morfológicas básicas erosión, dilatación, apertura y cerradura. Con ello se obtiene una Función de Distribución de Tamaños asociada a cada máscara.

Derivando esta Función de Distribución se obtiene una Función de Densidad, con la cual se puede calcular estadísticos como el valor medio y la varianza que pasan a formar parte del vector de características. Este vector de características es la variable de entrada para los distintos algoritmos de clasificación.

3.6.1 Operaciones Morfológicas básicas: Dilatación y Erosión

La Morfología Matemática es inicialmente un método dirigido a cuantificar las descripciones de los fenómenos físicos. Sin embargo, desarrolla paralelamente una herramienta muy poderosa, que es toda una familia de transformaciones y algoritmos asociados a ella, basadas en el concepto de *elemento estructurante* (Serra, J. 1982).

Este último concepto se basa en analizar una imagen no por un análisis directo, sino por la forma en que interactúa con pequeños objetos, por ejemplo, contando en cuántas partes la imagen puede contener esos objetos. Para caracterizar el ajuste se debe tener en cuenta la relación entre un subconjunto X y la traslación de este conjunto por un punto h .

Consideremos R^n como R -espacio vectorial, una imagen Euclídea será un subconjunto cerrado X de R^n ($X \in F(R^n)$) donde $F(R^n)$ es la familia de subconjuntos cerrados de R^n).

Def: Sea X un sub-conjunto de R^n y $h \in R^n$, definimos la **Traslación** $T_h: P(R^n) \rightarrow P(R^n)$ como:

$$T_h(X) = X_h = \{ x+h : x \in X \} \quad (3-23)$$

En la figura 3-6 se muestra un elemento estructurante de forma circular, en dos posiciones diferentes dentro de una imagen binaria. El procedimiento consiste en marcar las traslaciones del elemento estructurante, siempre y cuando éste se ajuste dentro de la imagen. Si se marcan las posiciones en las cuales el elemento estructurante cae dentro de la figura, se puede obtener información estructural concerniente a la imagen. Esta información depende del tamaño así como de la forma del elemento estructurante elegido.

Las operaciones morfológicas dilatación y erosión constituyen la base de todas las operaciones morfológicas, por lo tanto serán descritas con mayor detalle a continuación.

3.6.1.1 Erosión Binaria

Esta operación morfológica erosiona una imagen binaria o con niveles de gris, con un elemento estructurante plano o una función estructurante respectivamente. Sin embargo

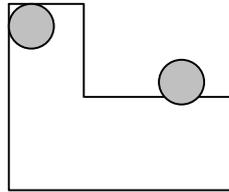


Fig. 3-6 Ejemplo de translación de un elemento estructurante circular.

para comprender tanto el proceso de *erosión* como el de *dilatación* es conveniente trabajar en principio con imágenes binarias, extendiéndose luego el concepto a imágenes con niveles de gris.

La definición formal de *erosión* para imágenes binarias es la siguiente:

Def: Dados dos conjuntos $X, B \subset \mathbb{R}^n$, definimos la *erosión* $X \ominus B$ de X por B como:

$$X \ominus B = \{ x : B_x \subset X \} \quad , \text{ siendo } B_x = \{ b + x : b \in B \} \quad (3-24)$$

Al conjunto B se lo conoce con el nombre de *elemento estructurante* y puede hacerse una analogía del mismo con una máscara de convolución. Si bien la operación erosión está basada en la teoría de conjuntos mientras que la convolución se basa en operaciones aritméticas, el proceso de desplazarlo sucesivamente sobre la imagen X es similar al proceso de convolución.

Por lo tanto, erosionar un conjunto X por un elemento estructurante B equivale a trasladar B por todos los puntos x del espacio \mathbb{R}^n . Para cada punto x de \mathbb{R}^n , si esta traslación está incluida en la imagen X decimos que el punto x está en $X \ominus B$.

Def: Dados dos conjuntos $X, B \subset \mathbb{R}^n$, definimos la *resta de Minkowsky* $X \ominus B$ (Serra, J., 1982) de X por B como

$$X \ominus B = \bigcap_{b \in B} X_b \quad (3-25)$$

Def : Sea $B \subset \mathbb{R}^n$, definimos el simétrico B' (o reflejado) de B respecto al origen como:

$$B' = \{-b : b \in B\} = (-1) \cdot B = -B \quad (3-26)$$

La siguiente proposición nos da una relación directa entre la *erosión* y la *resta de Minkowsky* (Serra, J. 1982):

Prop : sean $X, B \subset \mathbb{R}^n$, entonces

$$X \ominus B' = X \ominus B \quad (3-27)$$

Si el origen está contenido dentro del elemento estructurante, la imagen erosionada es un subconjunto de la imagen de entrada, es decir, si el origen se apoya dentro del elemento estructurante, la erosión tiene el efecto de achicar la imagen de entrada.

En la Figura 3-7 se muestra un ejemplo sencillo, en el cual X es un conjunto cuadrado de lado ℓ . El elemento estructurante también es cuadrado de lado $\ell/4$ y además es simétrico respecto de su origen.

Todos los puntos indicados con gris constituyen la erosión de X por B . La línea punteada indica el conjunto original X y se toma como referencia. Si se producen desplazamientos adicionales del origen del elemento estructurante B , éste no quedaría completamente contenido en X .

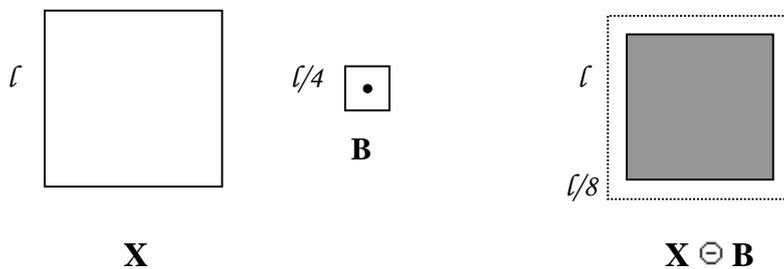


Fig. 3-7 Ejemplo de erosión en una imagen binaria euclídea.

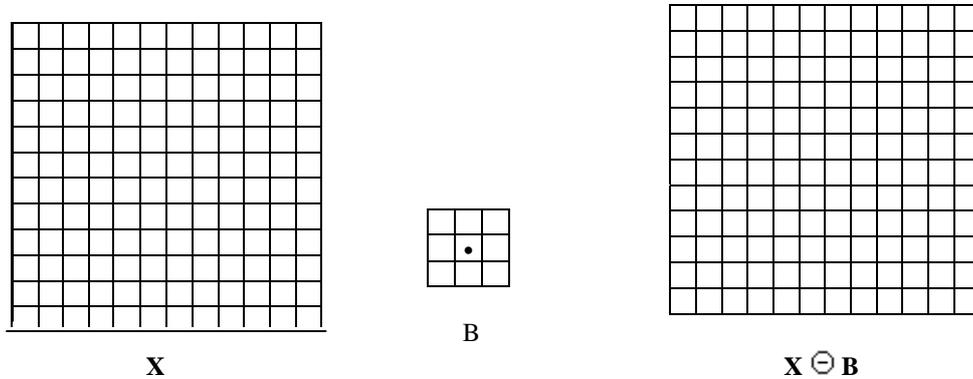


Fig. 3-8 Ejemplo de erosión en una imagen digital.

Con el elemento estructurante de que se utilizó en el ejemplo anterior y tomando una imagen digital no cuadrada, el resultado que se obtiene es el de la Figura 3-8.

3.6.1.2 Dilatación Binaria

Esta operación morfológica dilata una imagen binaria o con niveles de gris, con un elemento estructurante plano o una función estructurante respectivamente. En vez de realizar una erosión del objeto, podríamos hacerla sobre el fondo, con lo cual, en vez de disminuir la figura, esta crece (pues disminuye el fondo). A esta nueva transformación Serra la define como *dilatación* (Serra, J. 1982).

Def: Dados dos conjuntos $X, B \subset \mathbb{R}^n$, definimos la *dilatación* de X por B como

$$X \oplus B = (X^c \ominus B)^c \quad (3-28)$$

Def: Dados dos conjuntos $X, B \subset \mathbb{R}^n$, decimos que B intersecciona X sii

$$B \cap X \neq \emptyset \quad (3-29)$$

y lo notamos $B \uparrow X$ (Serra, J. 1982).

Obs : Dilatar la figura X por B es eliminar del fondo todos los puntos x donde B_x no esté incluido en el fondo, que equivale a asignar a la imagen dilatada todos los puntos x tales que B_x intercepte a la imagen, luego :

Def: La definición formal de *Erosión* para imágenes binarias es entonces la siguiente :

$$\begin{aligned}
 X \oplus B &= \{ x : B_x \subset X^c \}^c \\
 &= \{ x : B_x \not\subset X^c \} \\
 &= \{ x : B_x \cap X \neq \emptyset \} \\
 &= \{ x : B_x \uparrow X \}
 \end{aligned} \tag{3-30}$$

Es decir, el proceso de *dilatación* consiste efectuar una traslación de B por X. De ésta forma, la *dilatación* de X por B estará formada por el conjunto de todos los desplazamientos X tales que B y X se superponen al menos en un elemento no nulo.

La dilatación cumple con las propiedades (Serra, J., 1988):

•conmutativa $A \oplus B = B \oplus A$ (3-31)

•asociativa $(A \oplus B) \oplus C = A \oplus (B \oplus C)$ (3-32)

Si B contiene al origen, entonces la dilatación de X por B resulta en una expansión de X, ya que la dilatación implica un ajuste dentro del complemento de la imagen.

Def: Dados dos conjuntos $X, B \subset \mathbb{R}^n$, definimos la *suma de Minkowsky* de X por B como

$$X \oplus B = \bigcup_{b \in B} X_b \tag{3-33}$$

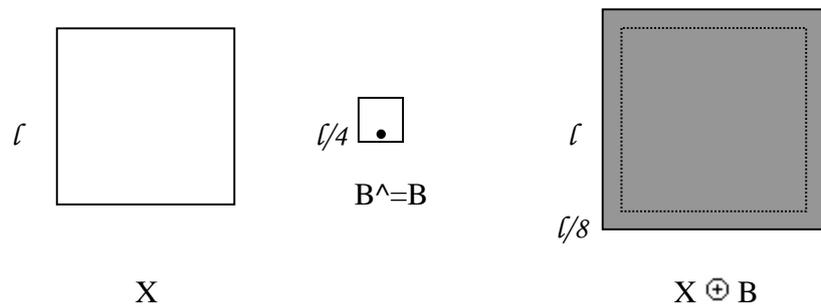


Fig. 3-9 Ejemplo de dilatación en una imagen binaria euclidea.

La siguiente proposición nos da una relación directa entre la *dilatación* y la *suma de Minkowsky*:

Prop : sean $X, B \subset \mathbb{R}^n$, entonces

$$X \oplus B' = X \oplus B \tag{3-34}$$

De la proposición se deduce que si B es simétrico ($B = B'$) entonces la *dilatación* y la *suma de Minkowsky* definen la misma transformación (Dougherty, E., 1992).

En la figura 3-9 se observa un ejemplo en el donde X es un conjunto cuadrado de lado 1. El elemento estructurante también es cuadrado de lado $1/4$ y además es simétrico respecto de su origen, por lo tanto B^{\wedge} será igual a B , donde con B^{\wedge} indicamos el conjugado de B .

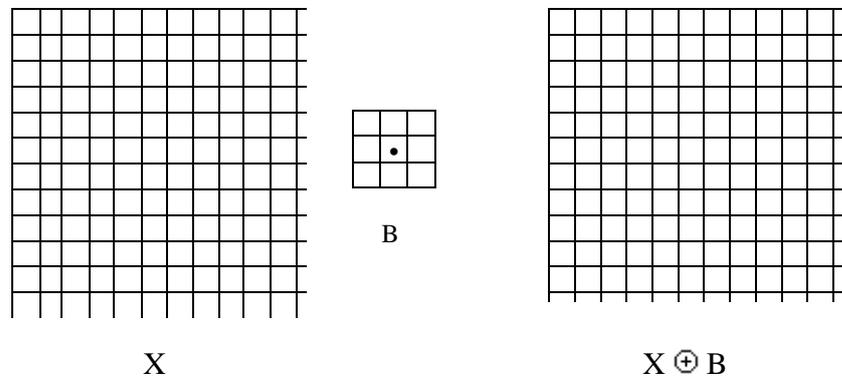


Fig. 3-10 Ejemplo de dilatación en una imagen binaria digital.

Todos los puntos indicados con gris constituyen la dilatación de X por B . La línea punteada indica el conjunto original X . Desplazamientos adicionales del origen del elemento estructurante B^{\wedge} por x , resultarían en una intersección vacía entre B^{\wedge} y X .

Con el mismo elemento estructurante que se utilizó en el ejemplo anterior y tomando una imagen no cuadrada, el resultado que se obtiene es el de la Figura 3-10.

3.6.1.3 Apertura y Cerradura Binarias

Uno de los problemas de la erosión y la dilatación es que no son inversas una de la otra, es decir que si erosionamos un conjunto X por un elemento estructurante B , no siempre podemos recuperar X dilatando por B el conjunto erosionado $X \ominus B$. Esta operación reconstruye sólo una parte de X , más simple y con menos detalles, pero que puede considerarse como su parte esencial. Este resultado nos lleva a definir la *apertura* y la *cerradura*.

Def: Dados un conjunto $X \subset \mathbb{R}^n$ y un elemento estructurante $B \subset \mathbb{R}^n$, definimos la *apertura* de X por B como

$$X \circ B = (X \ominus B) \oplus B \quad (3-35)$$

Def: Dado un conjunto $X \subset \mathbb{R}^n$ y un elemento estructurante $B \subset \mathbb{R}^n$, definimos la *cerradura* de X por B como

$$X \bullet B = (X \oplus B) \ominus B \quad (3-36)$$

Las transformaciones de Apertura y Cerradura son transformaciones conjugadas en el siguiente sentido:

$$\begin{aligned} (X^c) \circ B &= (X^c \ominus B) \oplus B \\ &= (X \oplus B)^c \oplus B \end{aligned}$$

$$\begin{aligned}
 &= [(X \oplus B) \ominus B]^c \\
 &= (X \bullet B)^c
 \end{aligned} \tag{3-37}$$

$$\begin{aligned}
 (X^c) \bullet B &= (X^c \oplus B) \ominus B \\
 &= (X \ominus B)^c \ominus B \\
 &= [(X \ominus B) \oplus B]^c \\
 &= (X \circ B)^c
 \end{aligned} \tag{3-38}$$

La apertura y la cerradura tienen un significado morfológico más fuerte que la erosión y la dilatación, pues son fundamentales para obtener descriptores de forma y tamaño de los objetos de la imagen, lo que será visto más adelante.

La apertura también puede interpretarse como la unión de todas las traslaciones de B que están incluidas en X.

$$\underline{\text{Prop}}: \quad X \circ B = \bigcup_{\substack{y \in \mathbb{R}^n \\ B_y \subset X}} B_y \tag{3-39}$$

De la misma forma podemos ver que un punto z pertenece al conjunto $X \bullet B$ si y sólo si todas las traslaciones de B que contienen a z tienen intersección no vacía con X.

$$\underline{\text{Prop}}: \quad X \bullet B = \{ z : z \in B_y \Rightarrow B_y \uparrow X \} \tag{3-40}$$

En la Figura 3-11 se presenta un ejemplo sencillo, en el cual a una imagen euclídeana A se le aplica una operación de apertura con un elemento estructurante en forma de disco.

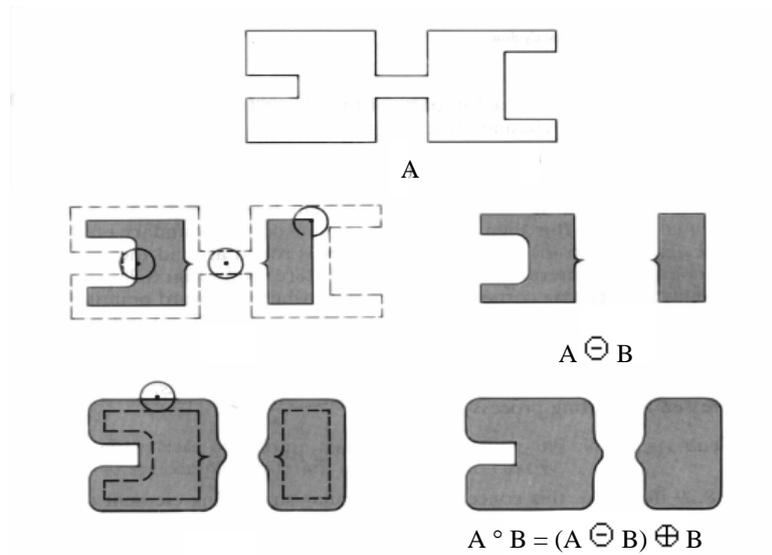


Fig. 3-11 Ejemplo de apertura binaria paso a paso.

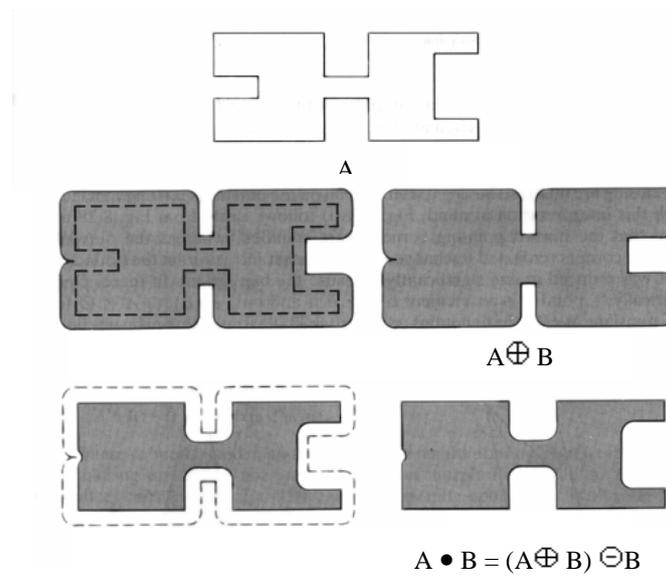


Fig. 3-12 Ejemplo de cerradura binaria paso a paso.

De la misma manera en la figura 3-12 se presenta un ejemplo, en el cual a una imagen euclídeana A se le aplica una operación de cerradura con un elemento estructurante en forma de disco (Gonzalez, R. & Woods, R., 1992).

En el caso de la apertura los istmos que son de tamaño menor al elemento estructurante desaparecen mientras que los huecos de tamaño mayor al estructurante se cierran. Para el caso de la cerradura sucede lo inverso, aquellos istmos de tamaño menor que el estructurante permanecen en la imagen resultado, pero los huecos de tamaño menor que el estructurante son cerrados. En ambos casos la forma del elemento estructurante tornea los bordes de la imagen binaria.

3.6.2 Criterio de tamaños: Granulometría Binaria

Una de las formas de analizar una imagen es aplicar un procedimiento similar al tamizado para separar objetos de diferente tamaño. Primero se pasa un tamiz de malla muy pequeña, con lo que se separan los objetos más pequeños, luego se van pasando tamices más grandes sobre los objetos restantes, hasta que finalmente no queda nada. Cada tamiz separa una porción de objetos, dependiendo de cómo están distribuidos los tamaños. Si hay muchos objetos pequeños, los primeros pasos del tamizado separarán más objetos que los últimos. Si predominan los objetos grandes entonces serán los últimos pasos del tamizado los que separen mayor parte de los objetos.

Aplicar un tamizado a una imagen significa aplicar primero una transformación que elimina de la imagen los detalles más pequeños, luego se aplica sobre la imagen resultante otra transformación que elimina detalles un poco más grandes. Se sigue de esta forma hasta que desaparecen completamente todos los detalles. La cantidad eliminada por cada transformación depende de cómo están distribuidos los detalles en la imagen y cuales son sus tamaños. Por esto a este método se lo llama *Distribución de Tamaños* o *Granulometría*, pues nos permite obtener información de la imagen que depende de los tamaños de los objetos que la componen (Dougerthy, E. and Sand, F., 1995; Ballarin, V., Brun, M. y Moler, E., 2001).

3.6.2.1 Axiomas de Matheron

Para poder realizar una clasificación de una imagen en base al tamaño de los detalles que la conforman, Matheron utilizó una familia de transformaciones $\Psi_\lambda(X)$, que

denominó Criterio de Tamaño (Serra, J. 1988). Esta familia depende de un parámetro positivo λ . Este parámetro es un indicador de cuán fino es el tamiz en ese paso.

Además de tener que cumplir con los cuatro principios de la Morfología Matemática, esta familia de transformaciones debe cumplir con los llamados Axiomas de Matheron, que son las propiedades que le permite comportarse como un proceso de tamizado.

Sea $\Psi_\lambda(X)$ es una familia de transformaciones dependientes de un parámetro λ , decimos que $\Psi_\lambda(X)$ cumple con los Axiomas de Matheron si:

$$1. \Psi_\lambda(X) \subset X \quad \forall \lambda > 0 \quad (\text{Antiextensividad}) \quad (3-41)$$

$$2. Y \subset X \Rightarrow \Psi_\lambda(Y) \subset \Psi_\lambda(X) \quad \forall \lambda > 0 \quad (\text{Incrementalidad}) \quad (3-42)$$

$$3. \Psi_\lambda[\Psi_\mu(X)] = \Psi_\mu[\Psi_\lambda(X)] = \Psi_{\text{supr}(\mu, \lambda)}(X) \quad \forall \lambda, \mu > 0 \quad (\text{Robustez}) \quad (3-43)$$

Estas restricciones son las que posibilitan que la familia $\Psi_\lambda(X)$ se comporte en forma similar a un proceso de tamizado real.

Una de las ventajas de especificar estos axiomas es que juntando los cuatro Principios de la Morfología Matemática y los tres Axiomas de Matheron, se puede demostrar que cualquier Criterio de Tamaños se puede escribir como unión de Aperturas Morfológicas. También se puede demostrar que todos los Criterios de Tamaños son digitalizables. (Ballarin, V. et al., 2001). Son transformaciones incrementales semi-contínuas.

Una vez obtenido un Criterio de Tamaños por medio de la familia $\Psi_\lambda(X)$, se puede agregar una medición $F[\Psi_\lambda(X)]$, donde F es una función positiva e incremental con respecto a λ . Habitualmente se utiliza la Medida de Lebesque.

3.6.2.2 Criterio de Tamaños por Aperturas Morfológicas

Una vez definidas las restricciones sobre la familia $\Psi_\lambda(X)$ se puede definir un Criterio de Tamaños, por medio de las transformaciones ya vistas anteriormente. La forma

de obtener esta familia es aplicando Aperturas Morfológicas sucesivas a la imagen bajo estudio. La validez de esta aproximación está dada por la siguiente proposición:

Prop: sea el elemento estructurante B un conjunto compacto convexo, la familia de transformaciones $\{\Psi_\lambda: \lambda \in \mathbb{R}\}$, definidas por

$$\Psi_\lambda(X) = X \circ \lambda \cdot B \quad (3-44)$$

es un Criterio de Tamaños (Serra, J., 1988; Vincent L., Dougherty E. 1994).

Por último se define un parámetro numérico sobre el resultado de cada transformación $\Psi_\lambda(X)$. Para ello se utiliza simplemente la medida de Lebesgue, siendo $\text{Med}(X)$ la longitud de X si $X \subset \mathbb{R}$, el área de X si $X \subset \mathbb{R}^2$, o el volumen de X si $X \subset \mathbb{R}^3$. Ya vimos que $\text{Med}(X)$ es un parámetro morfológico. Luego $\text{Med}[\Psi_\lambda(X)]$ es una operación morfológica para cada valor de λ .

Pero también si $Y \subset X$, entonces $\text{Med}(Y) \subset \text{Med}(X)$, por lo que $\text{Med}[\Psi_\lambda(X)]$ es decreciente con respecto a λ de acuerdo al primer axioma de Matheron (Eq.3-41). Además, si X es un conjunto acotado entonces $\text{Med}(X) < \infty$ y para algún valor μ se cumple que $\Psi_\mu(X) = \emptyset$.

Para cada valor de λ se obtiene un parámetro morfológico $\text{Med}[\Psi_\lambda(X)]$ sobre $\mathbb{F}(\mathbb{R}^n)$. Estos parámetros tienen las siguientes características:

- Si $\lambda > \mu$ entonces $\text{Med}[\Psi_\lambda(X)] < \text{Med}[\Psi_\mu(X)]$
- Si $\text{Med}(X) < \infty$ entonces existe un valor de λ tal que $\text{Med}[\Psi_\lambda(X)] = 0$

Por lo tanto, para cada conjunto $X \in \mathbb{F}(\mathbb{R}^n)$, se obtiene una familia de parámetros $\text{Med}[\Psi_\lambda(X)]$, que forman una función decreciente con respecto a λ . Esta función depende de cada conjunto X y se llama *Distribución de Tamaños*.

$$\Omega(\lambda) = \Omega_X(\lambda) = \text{Med}[\Psi_\lambda(X)] \quad \text{para cada } X \in \mathbb{F}(\mathbb{R}^n) \quad (3-45)$$

Debido a las propiedades que presenta esta función, se puede obtener otra función, creciente respecto a λ y cuyos valores están entre 0 y 1.

$$G(\lambda) = G_{\lambda}(X) = 1 - (\Omega_X(\lambda) / \Omega_X(0)) = 1 - (\text{Med}[\Psi_{\lambda}(X)] / \text{Med}(X)) \quad (3-46)$$

Esta nueva función es una Función de Distribución y se la conoce como *Distribución Normalizada de Tamaños* (Ballarin, V. et al., 2001).

3.6.2.3 Granulometrías generadas por un elemento estructurante simple

Las granulometrías han sido aplicadas para caracterizar información acerca de la forma y tamaño en imágenes binarias granulares. Esto se lleva a cabo teniendo en cuenta el modo en que pasan por un “tamiz” de diferentes formas y tamaños. Es decir, si se considera a la imagen como un conjunto de granos, el hecho de que un grano individual pase o no a través del colador depende de la forma y el tamaño relativo de los orificios del mismo. A medida que se incrementa el tamaño de los orificios, la cantidad de granos de la imagen que pasan a través de ellos es mayor, hasta que llega un punto en que no quedan más granos. (Ver figura 3-13)

Recordando que el múltiplo escalar u homotecia del conjunto B por el número real λ se define como:

$$\lambda B = \{ \lambda b / b \in B \} \quad (3-47)$$

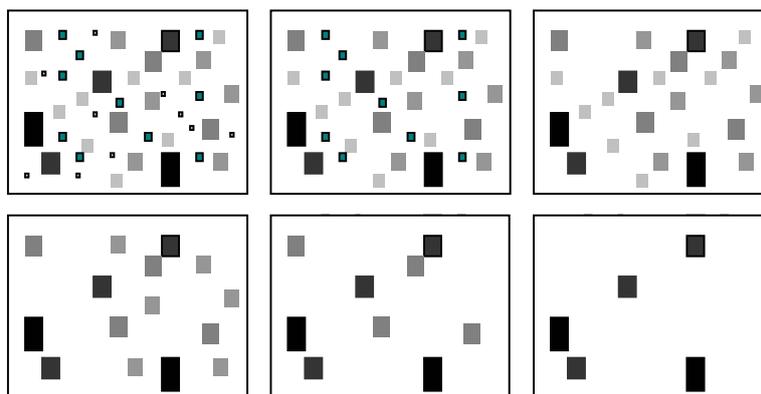


Fig. 3-13 Imagen aperturada con elementos estructurantes de tamaños crecientes.

un resultado fundamental de la morfología matemática, establece que un conjunto compacto B es convexo si y sólo si se cumple $\lambda > \mu > 0$, λB es μB -abierto, lo que significa que, $\lambda B \circ \mu B = \lambda B$, en donde \circ denota la apertura morfológica.

Otra propiedad básica de la apertura morfológica es que si E es B-abierto, para cualquier conjunto A se cumple que $A \circ E$ es un subconjunto de $A \circ B$. Por lo tanto si B es convexo, $\lambda > \mu > 0$, significa que $A \circ \lambda B$ es un subconjunto de $A \circ \mu B$.

Si imaginamos a la imagen A como constituida por granos que caen a través de los orificios λB y μB , pasarán mayor cantidad a través del orificio λB , produciendo una imagen filtrada más reducida. Además de que $A \circ \lambda B$ es un subconjunto de $A \circ \mu B$, se puede demostrar que:

$$(A \circ \lambda B) \circ \mu B = (A \circ \lambda B) \circ \lambda B = A \circ \lambda B \quad (3-48)$$

de manera que, realizar aperturas consecutivas en cualquier orden, es equivalente a realizar solamente la apertura por λB .

Dada la variable $\lambda > 0$ y siendo B un conjunto convexo, se denomina granulometría a la familia de imágenes con aperturas $\{A \circ \lambda B\}$. Si $\Omega(\lambda)$ es el área de $A \circ \lambda B$, $\Omega(\lambda)$ es una función decreciente de λ , que se conoce con el nombre de distribución de tamaños. La misma comienza con el área de A en si misma, $\Omega(0)$, y si se supone que A está limitada, $\Omega(\lambda)=0$ para un valor de λ suficientemente grande.

Teniendo en cuenta estas consideraciones, se puede definir una distribución de tamaños normalizada como:

$$G(\lambda) = 1 - \frac{\Omega(\lambda)}{\Omega(0)} \quad (3-49)$$

Esta función es una función de distribución de probabilidad, tal como la distribución de tamaño granulométrica de A con respecto al generador B. $G(\lambda)$ es creciente desde 0 a 1 y es continua desde la izquierda.

La derivada de $G(\lambda)$

$$G'(\lambda) = \partial G(\lambda) / \partial \lambda \quad (3-50)$$

es una densidad de probabilidad, a veces llamada distribución de tamaños granulométrica o también *espectro de muestra de la imagen A* relativo al generador B.

Para poder aplicar este método en la práctica, primero se lo debe adaptar para imágenes digitales, a las cuales se las considera como subconjuntos de la grilla cartesiana cuadrada Z^2 . Esta transformación no puede efectuarse directamente, debido a que la grilla cartesiana presenta dos dificultades:

- la falta de un concepto apropiado de convexidad
- la incapacidad para aplicar la multiplicación escalar por números reales arbitrarios.

El método de generación granulométrica que se va a detallar, es aplicable a imágenes euclidianas e imágenes discretas.

Se considera una secuencia de elementos estructurantes de tamaño creciente E_1, E_2, \dots . Además $E_{\lambda+1}$ es E_λ -abierto para todo valor de λ . Al cumplirse estas dos condiciones, si S es una imagen, entonces $S \circ E_{\lambda+1}$ es una subimagen de $S \circ E_\lambda$. Como consecuencia, las aperturas sucesivas por elementos estructurantes crecientes producen una secuencia de imágenes decrecientes, como se puede apreciar en la Fig. 3-12.

$$S \circ E_1 \supseteq S \circ E_2 \supseteq S \circ E_\lambda \supseteq \dots \quad (3-51)$$

Para cada λ , se toma $\Omega(\lambda)$, el número de pixels de $S \circ E_\lambda$, por lo tanto $\Omega(\lambda)$ es una función decreciente de λ . Suponiendo que E_1 es un pixel simple, y que S es finito, $\Omega(1)$ cuenta los pixels de la imagen original S y $\Omega(\lambda)=0$ para un valor de λ lo suficientemente grande.

Si se aplica la normalización

$$G(\lambda) = 1 - \frac{\Omega(\lambda)}{\Omega(1)} \quad (3-52)$$

con λ en lugar de λ y 1 en lugar de cero, se obtiene una distribución de tamaños normalizada $G(\lambda)$. Como se trata de una función distribución de probabilidad discreta, se puede obtener su derivada discreta:

$$G'(\lambda) = \partial G(\lambda) = G(\lambda+1) - G(\lambda) \quad (3-53)$$

la cual es una función de densidad discreta. Nuevamente la densidad es llamada *distribución de tamaños granulométrica* o *espectro de muestras*.

La siguiente es una manera sencilla para formar las secuencias $\{E_\lambda\}$ de forma tal que $E_{\lambda+1}$ sea E_λ -abierto. Se elige una primitiva E y se toma:

$$\begin{aligned} E_1 & \text{ un pixel simple} \\ E_2 & = E \\ E_3 & = E \oplus E \\ E_4 & = E \oplus E \oplus E \dots \end{aligned} \quad (3-54)$$

Se sabe que $E_{\lambda+1}$ es E_λ -abierto. Además $E_{\lambda+1} = E_\lambda \oplus E$ y la dilatación de dos conjuntos es abierto con respecto a ambos. De todas maneras ésta no es la forma más adecuada para encontrar la secuencia de elementos estructurantes.

Dada la granularidad de las texturas en las imágenes de RMN y que no se obtienen resultados satisfactorios en la segmentación de los diferentes tejidos al aplicar los enfoques tradicionales, se consideró en esta tesis extender los conceptos de granulometría a imágenes con niveles de gris. En el próximo capítulo se demostrará que este enfoque es más eficiente lográndose segmentaciones con menor error y acortándose los tiempos de procesamiento.

3.7 Algoritmos de Clasificación de Texturas: Reconocimiento de Patrones

En general, se relaciona al concepto de patrón con un modelo que sirve de muestra para sacar otra cosa igual. Se puede definir al Reconocimiento de Patrones como la categorización de los datos de entrada en clases identificables a través de la extracción de características significativas de los datos desde un fondo de la escena de irrelevante detalle. El objetivo de la extracción de características es llevar a cabo una reducción de dimensionalidad. El dato original es convertido a una forma adecuada, o vectores

característicos, para poder ser usado como entrada al procesador de decisión para su posterior clasificación.

Los vectores característicos pueden representarse como:

$$x_i^T = (x_{i1}, x_{i2}, \dots, x_{in}) \quad \text{con } i=1, 2, \dots, m \quad (3-55)$$

y como $r < n$, se encuentran en una dimensión menor.

El procesador de decisión opera sobre el vector patrón y produce una decisión de clasificación. Como se mencionó con anterioridad, los vectores patrón se ubican en el espacio patrón como puntos, y los patrones pertenecientes a la misma clase se agruparán juntos. Cada cluster representa una clase diferente y clusters de puntos representan clases diferentes de patrones.

El clasificador de decisión implementado con un conjunto de funciones decisión sirve para definir la clase a la cual pertenece un patrón particular. La salida del procesador decisión estará en el espacio clasificación. Este espacio clasificación en M-dimensional, en donde M indica la cantidad de clases en que van a ser clasificados los patrones de entrada. Para el caso de esta tesis el espacio de clasificación es de dimensión 4, las tres texturas a segmentar (líquido céfalo-ráquideo, materia gris y blanca) más el fondo.

3.7.1 Clasificación y Distancia

Como se indicó en el apartado anterior, cada patrón está representado por un vector de características. Para reconocer cada patrón, lo que se hace habitualmente es particionar el espacio de características. Esta aproximación es conocida como la aproximación a la teoría de la decisión. La misma está basada en la representación del conjunto de datos en forma vectorial.

El problema de la clasificación consiste en encontrar una superficie de separación que particione los prototipos conocidos dentro de las clases correspondientes. Es de esperarse que dicha superficie de separación pueda utilizarse para la clasificación de otros patrones desconocidos si se usa el mismo criterio en el clasificador.

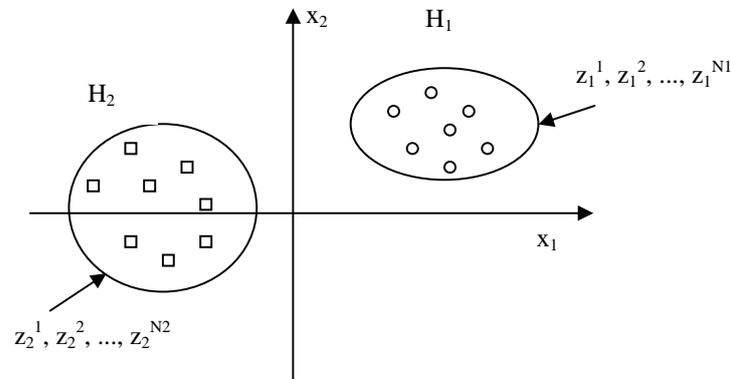


Figura 3-14 Espacio patrón bidimensional simple.

La figura 3-14 muestra un espacio patrón bidimensional simple. N_1 y N_2 representan el número de prototipos en las clases H_1 y H_2 respectivamente. Los prototipos $Z_1^1, Z_1^2, \dots, Z_1^{N_1}$ son agrupados en ω_1 . Los prototipos de otra clase $Z_2^1, Z_2^2, \dots, Z_2^{N_2}$ son agrupados en otra región del espacio patrón ω_2 (Cernuschi Frías, B. Belausteguigoitia, C., 1987).

Debido a que los patrones que pertenecen a clases diferentes se agruparán en regiones diferentes en el espacio patrón, es posible usar como una medida de similitud entre patrones en el espacio n-dimensional a la medida de distancia.

3.7.2 Clasificación No Supervisada

Una vez obtenido un vector de características para cada pixel de la imagen, se debe emplear un algoritmo de clasificación, que puede variar según el problema a resolver. Las distintas categorías en que pueden agruparse los objetos pueden estar definidas previamente, con lo que el objetivo es determinar a qué clase pertenece un objeto. Esto se conoce como Clasificación Supervisada (Duda, R. & Hart, P., 1973). De lo contrario, cuando el método mismo define las categorías en base a los datos observados, se denomina Clasificación No Supervisada. Estos métodos de clasificación son los aplicados para esta tesis.

3.7.3 Medidas de Similitud

Cuando es necesario agrupar una determinada cantidad de muestras en grupos, se hace uso de métodos determinísticos denominados *clustering*. El *clustering* es la clasificación no supervisada de objetos (Cernuschi Frías, B. & Belausteguigoitia, C., 1987) y permite generar clases sin ningún conocimiento a priori de la clasificación del prototipo. Los clusters se definen como grupos de puntos que tienen características similares de acuerdo a una medida determinada.

Dados M patrones $X_1, \dots, X_2, \dots, X_m$ contenidos en el espacio patrón S, el proceso de clustering puede ser enunciado como buscar las regiones $S_1, \dots, S_2, \dots, S_k$ tal que cada X_i con $i=1, 2, \dots, m$ cae dentro de una de esas regiones y ningún X_i cae en dos regiones, es decir:

$$S_1 \cup S_2 \cup \dots \cup S_k = S \quad (3-56)$$

$$S_i \cap S_j = \emptyset \quad \forall i \neq j \quad (3-57)$$

en donde los símbolos \cup y \cap significan unión e intersección respectivamente.

Los algoritmos derivados de *clustering* clasifican objetos en clusters por asociación natural de acuerdo a algunas medidas de similitud. El grado de asociación debería ser alto entre miembros que pertenecen a la misma clase, y bajo entre miembros de categorías diferentes.

A partir de la definición de clustering lo que se hace es agrupar, o formar dentro de cada clase, aquellos patrones X_i que sean tan parecidos como sea posible. Por lo tanto es necesario obtener alguna medida de similitud o disimilitud entre patrones.

Si ξ denota la medida de disimilitud entre dos patrones es de esperarse que

$$\begin{aligned} \xi(x_i, x_i) &= 0 && \text{pero} \\ \xi(x_i, x_j) &\neq 0 && \forall i \neq j \end{aligned} \quad (3-58)$$

Usualmente la medida de similitud o de disimilitud se da en un formato numérico para indicar el grado de asociación natural o grado de semejanza entre patrones en un grupo, entre un patrón y un grupo de patrones, o entre grupos de patrones. La medida de similitud más simple y la usada más frecuentemente es la distancia Euclidea.

Dados dos patrones X_i y X_j , se define a la distancia euclídea en el espacio euclideo multidimensional como:

$$d^2(x_i, x_j) = (x_i - x_j)^t (x_i - x_j) = |x_i - x_j|^2 \quad (3.59)$$

y a menor distancia, mayor será la similitud.

Por ejemplo, en la figura 3-15 si se quisiera saber si la muestra x pertenece a la clase W_i o W_j , se asignaría dicha muestra a la clase W_i ya que la misma se encuentra más cercana a los patrones de esta clase.

Si el tamaño relativo de la dimensión es importante, resulta adecuado usar esta distancia como una medida de similitud. En caso contrario, se debería utilizar una distancia euclidea pesada, la cual se representa como:

$$d_2(x_i, x_j) = \sum_{k=1}^n \alpha_k (x_{ki} - x_{kj})^2 \quad (3-60)$$

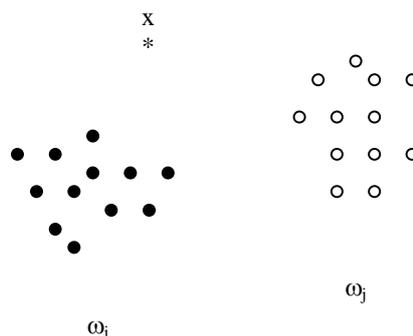


Fig. 3-15 Ejemplo de patrones asignados a dos clases.

donde $x_i = [x_{1i}, x_{2i}, \dots, x_{ni}]^T$, x_{ki} y x_{kj} son las componentes k-ésimas de x_i y x_j respectivamente y α_k es el coeficiente de peso.

Como en este caso particular se supone que la clase es desconocida, se toma valor medio del cluster m-ésimo como $m_m = [m_{1m}, m_{2m}, \dots, m_{nm}]^T$.

Sea $\alpha_k = 1/\sigma_{km}^2$ donde $\sigma_m = [\sigma_{1m}, \sigma_{2m}, \dots, \sigma_{nm}]^T$ y σ_{km}^2 es la varianza del cluster m-ésimo en la dirección k-ésima. Se puede escribir la distancia euclídeana pesada desde x_i al cluster m-ésimo como:

$$d_m^2(x_i, m_m) = \sum_{k=1}^n (x_{ki} - m_{km})^2 / \sigma_{km}^2 \quad (3-61)$$

Las formas de cluster que se obtienen cuando se utiliza esta medida, tienen lugares geométricos de igual d_m^2 , que son hiperelipsoides alineadas con los ejes del espacio patrón n-dimensional.

3.7.4 Distancia dentro de un Conjunto y distancia entre Conjuntos

Matemáticamente, la distancia entre dos conjuntos separados es:

$$D_{12} = \overline{D^2([x_1^i], [x_2^j])} \quad (3-62)$$

$i = 1, 2, \dots, N_1$

$j = 1, 2, \dots, N_2$

o bien

$$D_{12} = \frac{1}{N_1 N_2} \sum_{i=1}^{N_1} \sum_{j=1}^{N_2} D^2(x_1^i, x_2^j) \quad (3-63)$$

lo cual representa la distancia al cuadrado promedio entre puntos de clases separadas. Los subíndices 1 y 2 en los conjuntos patrón $[x_1^i]$ y $[x_2^j]$ representan clases ω_1 y ω_2 , respectivamente. N_1 y N_2 son el número de muestras patrón de las clases ω_1 y ω_2 , respectivamente.

La distancia en el interior de un conjunto, para un conjunto de N patrones que pertenecen a la misma clase, se puede encontrar en forma similar (Leguizamón, S., 1989).

Dado que

$$D^2(x^i, x^j) = \sum_{k=1}^n (x_k^i - x_k^j)^2 \quad (3-64)$$

la distancia cuadrática media desde un x^i fijo a los otros $N - 1$ patrones en el mismo conjunto es:

$$\overline{D^2(x^i, x^j)} = \frac{1}{N-1} \sum_{j=1}^N \sum_{k=1}^n (x_k^i - x_k^j)^2 \quad (3-65)$$

Por lo tanto la distancia dentro de un conjunto o el promedio sobre el total de los N patrones en el conjunto es:

$$D_{ii} = \overline{D^2(x^i, x^j)} = \frac{1}{N} \sum_{i=1}^N \left[\frac{1}{N-1} \sum_{j=1}^{N-1} \sum_{k=1}^n (x_k^i, x_k^j)^2 \right] \quad (3-66)$$

o

$$D_{ii} = \frac{1}{N-1} \sum_{k=1}^n \left[\frac{1}{N} \sum_{j=1}^{N-1} \sum_{i=1}^N (x_k^i - x_k^j)^2 \right] \quad (3-67)$$

Expandiendo los términos dentro de los corchetes se obtiene:

$$\begin{aligned} D_{ii} = \overline{D^2(x^i, x^j)} &= \frac{N}{N-1} \sum_{k=1}^n \left[\frac{1}{N} \sum_{j=1}^N \frac{1}{N} \sum_{i=1}^N (x_k^i)^2 - \frac{2}{N} \sum_{i=1}^N x_k^i \frac{1}{N} \sum_{j=1}^N x_k^j + \frac{1}{N} \sum_{i=1}^N \frac{1}{N} \sum_{j=1}^N (x_k^j)^2 \right] \\ &= \frac{N}{N-1} \sum_{k=1}^n \left[\frac{1}{N} \sum_{j=1}^N \overline{(x_k^i)^2} - 2 \overline{x_k^i x_k^j} + \frac{1}{N} \sum_{i=1}^N \overline{(x_k^j)^2} \right] \end{aligned} \quad (3-68)$$

Como se está trabajando en el mismo conjunto patrón,

$$\overline{(x_k^j)^2} = \overline{(x_k^i)^2} \quad (3-69)$$

quedando

$$D_{ii} = \overline{D^2(x^i, x^j)} = \frac{2N}{N-1} \sum_{k=1}^n [\overline{(x_k^i)^2} - \overline{(x_k^j)^2}] \quad (3-70)$$

Por definición, la varianza de la componente k-ésima de N patrones está dada por:

$$(\sigma_k)^2 = \frac{1}{N} \sum_{k=1}^N (x_k^i - \overline{x_k^i})^2 = \frac{1}{N} \sum_{k=1}^N (x_k^i)^2 - \frac{2}{N} \sum_{k=1}^N x_k^i \overline{x_k^i} + \frac{1}{N} \sum_{k=1}^N \overline{x_k^i}^2 \quad (3-71)$$

recordando

dado que $\overline{x_k^i}$ es un valor constante, entonces:

$$= \frac{1}{N} \sum_{i=1}^N (x_k^i)^2 - 2 \cdot \overline{x_k^i} \cdot \frac{1}{N} \sum_{i=1}^N x_k^i + \frac{1}{N} \cdot N \cdot \overline{x_k^i}^2 \quad (3-72)$$

recordando la definición de valor medio y reemplazando en 3-72,

$$= \overline{(x_k^i)^2} - [\overline{x_k^i}]^2 \quad (3-73)$$

Por lo tanto, la distancia dentro de un conjunto resulta:

$$D_{ii} = \overline{D^2(x^i, x^j)} = \frac{2N}{N-1} \sum_{k=1}^n \sigma_k^2 \quad (3-74)$$

$$\text{o } D_{ii} = 2 \sum_{k=1}^n (\sigma_k^*)^2 \quad (3-75)$$

donde

$$(\sigma_k^*)^2 = \frac{N}{N-1} (\sigma_k)^2 \quad (3-76)$$

Como se espera que el grado de asociación natural entre miembros que pertenecen a la misma categoría sea alto y bajo entre miembros de categorías diferentes, se deduce que la distancia intraconjunto debe ser pequeña, mientras que la distancia interconjunto debe ser grande.

Cuando se aplica *clustering*, generalmente se trata de ubicar los modos, es decir, se obtiene el máximo local de la densidad de probabilidad dado que el número de clases M es conocido.

3.7.5 Algoritmos elegidos

Dado que no se tiene un conocimiento previo de las clases, los algoritmos utilizados fueron de clasificación no supervisada. Dado que tampoco se tiene conocimiento de las funciones de densidad de probabilidad de los niveles de gris, para agrupar las muestras en grupos se utilizaron métodos determinísticos. Estos métodos consisten en formar agrupamientos de puntos en el espacio de mediciones de acuerdo a una medida de similitud (Tou, J. & Gonzalez, R., 1974; Sing-Tze, B., 1992). Esta similitud usualmente está determinada por la proximidad de los puntos de acuerdo a una función distancia Euclídea.

Las imágenes procesadas están representadas por matrices iguales de $N_c \times N_f$, donde N_c y N_f son el número de columnas y filas respectivamente. Los elementos de las matrices son los niveles de gris de los píxeles. El vector de características $X = (x_1, x_2, \dots, x_n)$ se conforma por los niveles de gris de las imágenes T_1 , T_2 y P_d respectivamente y los valores de los momentos (Ver figura 3-16). Cada coordenada del vector X representa un punto (o patrón) en el hiperplano de dimensión n . El objetivo es formar con estos puntos, cuatro clusters o grupos H_1 , H_2 , H_3 y H_4 que representan las tres texturas a segmentar más el fondo. Todos los píxeles de las imágenes cuyo vector X pertenezca a H_i son asignados a la clase W_i , obteniéndose de esta forma la imagen segmentada. A continuación se desarrollan los algoritmos ya existentes utilizados en las pruebas de segmentación, el de Mínima Distancia, el Maximin, el K-medias. El algoritmo propuesto, K-medias ponderado, es una variante del K-medias, en el cual se pondera la cantidad de píxeles que se corresponden con cada vector de niveles de gris o vector de parámetros. Este se desarrollará en el capítulo siguiente.

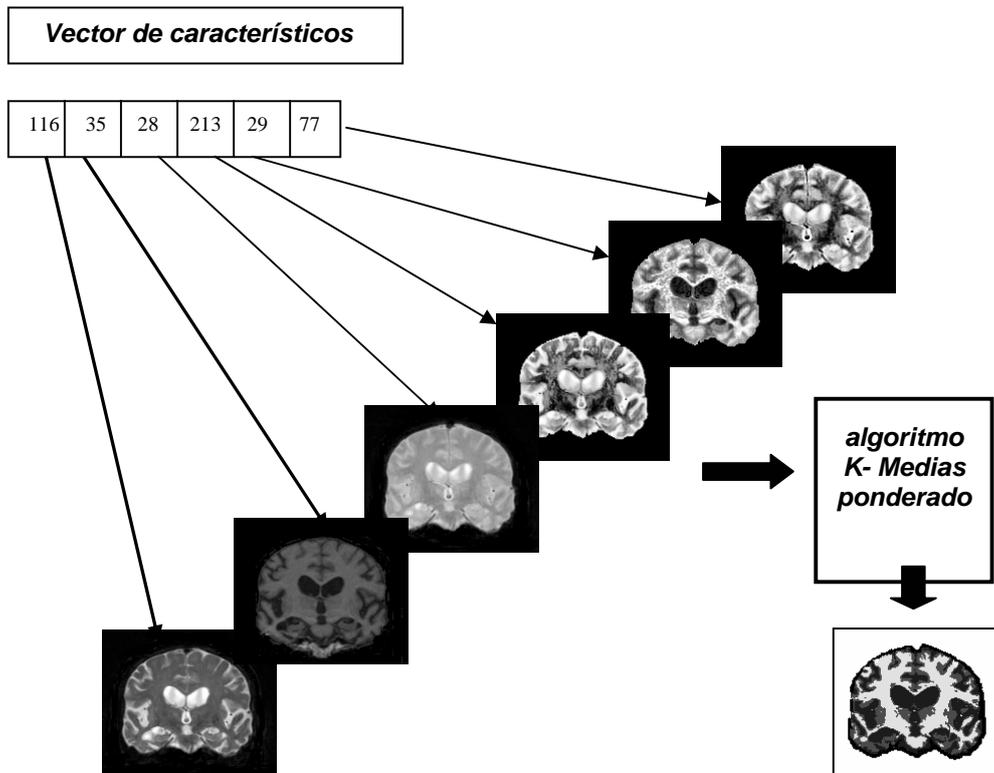


Fig. 3-16 Ejemplo de vector de características que se utilizó con entrada al algoritmo de reconocimiento de patrones. De izquierda a derecha imagen T₂, imagen T₁, imagen Pd, y las imágenes de los momentos.

3.7.5.1 Clasificador de Mínima Distancia

La regla de decisión que se utiliza en este método es la siguiente (Leguizamón, S., 1989):

$$x \in \omega_j \quad \text{si } D(x, z_j) = \min_{1 \leq k \leq M} D(x, z_k) \quad (3-77)$$

donde $D(\bullet)$ es una medida que se denomina distancia euclídea de un patrón desconocido x a partir de z_k , y z_k es el centro de clase o promedio del prototipo para la clase ω_k .

$$D(x, z_k) = \|x - z_k\| \quad (3-78)$$

Si $D(x, z_k) > D(x, z_j) > 0 \quad \forall j, \forall k$, se cumple que $D^2(x, z_k) > D^2(x, z_j)$. Reemplazando en la regla de decisión queda:

$$D^2(x, z_k) = \|x - z_k\|^2 \quad (3-79)$$

en forma de matriz,

$$D^2(x, z_k) = (x - z_k)^T (x - z_k) = x^T \cdot x - 2x^T \cdot z_k + z_k^T \cdot z_k \quad (3-80)$$

Por lo que la regla de decisión queda dada por:

$$\min_{1 \leq k \leq M} D(x, z_k) = \min_{1 \leq k \leq M} (x^T \cdot x - 2x^T \cdot z_k + z_k^T \cdot z_k) \quad (3-81)$$

que es equivalente a:

$$\max_{1 \leq k \leq M} (x^T \cdot z_k - \frac{1}{2} z_k^T \cdot z_k) \quad (3-82)$$

Esta es la regla de decisión para el clasificador de mínima distancia. La función discriminante que utiliza este clasificador por lo tanto es:

$$d_k(x) = x^T \cdot z_k - \frac{1}{2} z_k^T \cdot z_k = x^T - \frac{1}{2} |z_k|^2 = \mathbf{x}^T \cdot \mathbf{w} \quad (3-83)$$

donde

$$\mathbf{w} = \begin{bmatrix} z_k^1 \\ z_k^2 \\ \vdots \\ z_k^n \\ -\frac{1}{2} |z_k|^2 \end{bmatrix} \quad (3-84)$$

y \mathbf{x} es un vector patrón incrementado.

3.7.5.2 Algoritmo Maximin

El algoritmo Maximin es un procedimiento heurístico simple que permite determinar la clase o cluster a la cual pertenece un pixel determinado, basándose en la definición de Distancia Euclídea (Leguizamón, S., 1989). Recordando que la Distancia Euclídea se define como:

$$D = \|\mathbf{x} - \mathbf{z}\| = \sqrt{(\mathbf{x} - \mathbf{z})^T (\mathbf{x} - \mathbf{z})} \quad (3-85)$$

siendo \mathbf{x} y \mathbf{z} dos patrones diferentes.

Para implementar este algoritmo se establece un centro de cluster en forma arbitraria. Luego, se elige como segundo centro al punto más alejado del primero. A continuación se calculan las distancias de las muestras restantes a ambos centros y se elige la mínima de las dos asignándose la muestra al cluster más cercano. De todas las distancias mínimas se elige la máxima y la muestra correspondiente se toma como tercer centro de cluster. Se recalculan las distancias del resto de las muestras a los tres centros y se asigna cada muestra a la clase cuyo centro se encuentra más cercano.

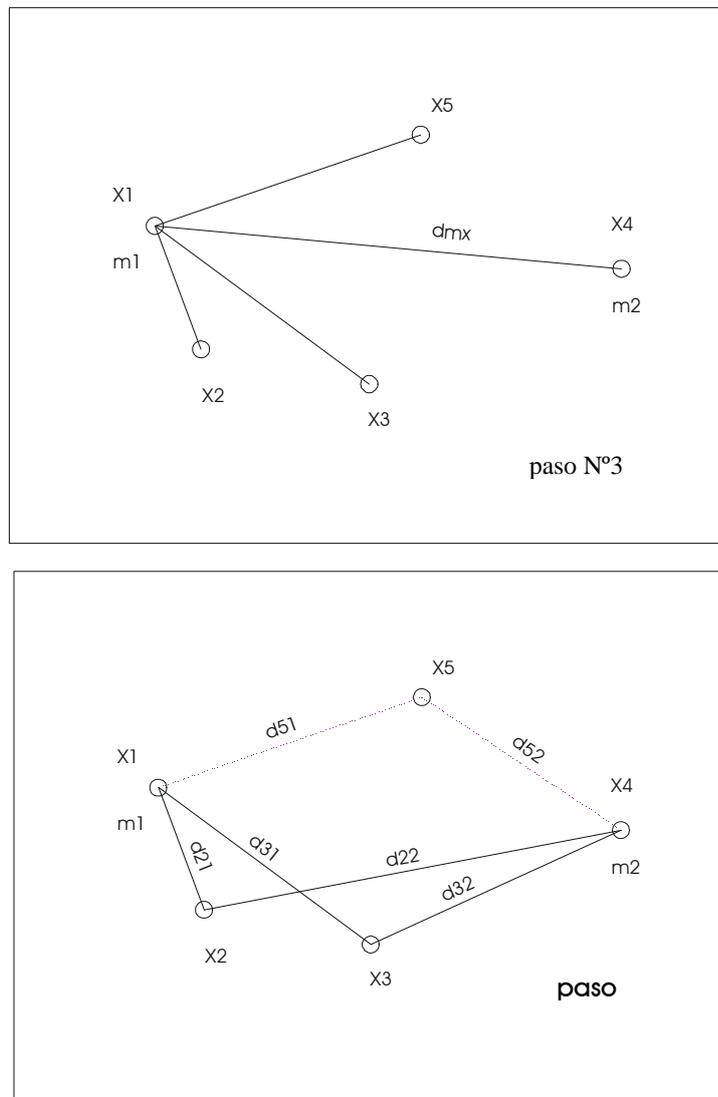


Fig. 3-17 Pasos 3 y 4 del algoritmo Maximin. En el paso 4 los valores mínimos están dados por d_{21} , d_{31} y d_{52} .

A modo de resumen se presentan los pasos para la implementación del algoritmo Maximin:

Dado un conjunto de N muestras o patrones $\{ x_1, x_2, \dots, x_n \}$.

1. Se define una tabla de centros inicialmente vacía.
2. Se asigna arbitrariamente $m_1 = x_1$ (el primer centro de un cluster se hace igual a uno de los patrones dados).
3. Se determina el punto más alejado de m_1 y se lo llama m_2 , agregándolo a la tabla de centros.
4. Se calculan las distancias desde las muestras restantes a m_1 y m_2 . De cada par de distancias se toma en cuenta la mínima. Se toma la distancia de cada muestra al centro más cercano. (Ver figura.3-17)
5. Se selecciona la máxima de estas distancias mínimas (d_{31}). Si esta distancia es mayor que la mitad de la distancia entre m_1 y m_2 ($d_{31} > \frac{1}{2} \cdot d_{m_1 m_2}$) se llamará a la muestra correspondiente m_3 , y será un nuevo centro de cluster. De lo contrario termina el algoritmo.
6. Repetir desde 4. El procedimiento se repite hasta que la nueva distancia máxima en un paso en particular, no cumple la condición requerida para la creación de un nuevo centro de cluster.

3.7.5.3 Algoritmo K-Medias

Este algoritmo se basa en la minimización de la función criterio de errores cuadráticos. Esta se define como la suma de los cuadrados de las distancias de todos los puntos de un cluster al centro del mismo cluster. El nombre de este algoritmo proviene de la forma en que los centros de los clusters son secuencialmente actualizados (Leguizamón, S., 1989).

Para implementar el algoritmo k-medias se procede de la siguiente manera:

Dado un conjunto de n muestras o patrones $\{x_1, x_2, \dots, x_n\}$.

1. Se toman k centros de clusters iniciales arbitrarios $z_1(h), z_2(h), \dots, z_K(h)$, en donde h es el número de iteración. Estos centros son arbitrarios pero habitualmente se eligen las k primeras muestras del conjunto.
2. En la iteración k-ésima se distribuyen las muestras X entre los K dominios del cluster, asignando cada muestra al dominio cuyo centro sea el más cercano. Para esto se utiliza la relación:

$$x \in S_j(k) \quad \text{si} \quad \|x - z_j(k)\| < \|x - z_i(k)\| \quad (3-86)$$

$\forall i=1, 2, \dots, K \quad i \neq j$, donde $S_j(k)$ indica el conjunto de muestras cuyo centro de cluster es $z_j(k)$.

3. A partir de los resultados obtenidos en el paso anterior se calculan los nuevos centros de cluster $z_j(k+1)$ con $j = 1, \dots, K$ de modo de hacer mínima la suma del cuadrado de las distancias de todos los puntos de la clase j, $S_j(k)$, al nuevo centro de cluster. En otras palabras, se calcula el nuevo centro de cluster $z_j(k+1)$ de forma tal que se haga mínimo el índice:

$$J_j = \sum_{x \in S_j(k)} \|x - z_j(k+1)\|^2 \quad (3-87)$$

con $j=1, 2, \dots, K$.

El valor de $z_j(k+1)$ que minimiza este índice de performance será el nuevo centro de cluster, el cual resulta ser el X medio de las muestras del cluster $S_j(k)$ y está dado por:

$$z_j(k+1) = \frac{1}{N_j} \sum_{x \in S_j(k)} x \quad (3-88)$$

con $j=1, 2, \dots, K$ y donde N_j es el número de muestras en la clase de centro $z_j(h)$, es decir de $S_j(k)$.

4. Si $z_j(k+1) = z_j(k)$ para $j=1,2, \dots, K$, finaliza el algoritmo debido a que hay convergencia. De lo contrario se vuelve al paso 2.

La ventaja del algoritmo *Maximin* reside en que es independiente del orden en que se encuentran las muestras. La desventaja es que necesita recorrerlas tantas veces como centros obtiene. Del algoritmo *K-medias* puede decirse que su comportamiento está influenciado por la elección de los centros iniciales de los clusters. A pesar de esto tiene la ventaja de que no se necesitan prototipos de cada clase, sino que los mismos se obtienen de los mismos datos. Sin embargo para que exista convergencia se deben recorrer los datos varias veces. Teniendo en cuenta que hay muchos pixeles en la imagen con los mismos valores de (x_1, x_2, \dots, x_n) como por ejemplo el fondo, mientras que hay patrones que sólo aparecen en un pixel, es que se propone en el próximo capítulo, una modificación del tradicional algoritmo de K-medias ponderando de alguna manera la cantidad de veces que el vector patrón aparece en la imagen.

Capítulo IV

MATERIALES Y MÉTODOS

4.1 Técnicas empleadas: Morfología Matemática

Inicialmente, la Morfología Matemática estaba basada en operaciones geométricas sobre conjuntos del espacio euclídeo \mathbb{R}^n sujetas a ciertas restricciones, pero actualmente se ha generalizado para abarcar transformaciones dentro de reticulados completos, habiéndose convertido en una gran herramienta para procesar imágenes con niveles de gris (Serra, J. 1982; Serra, J., 1988).

Una de las grandes ventajas de la Morfología Matemática reside justamente en que posee un sólido fundamento teórico y además es de muy sencilla aplicación a imágenes digitales, por lo que se han desarrollado gran cantidad de algoritmos orientados a la solución de diversos problemas, tales como filtrado, realce, clasificación y representación de formas. Se pueden definir dos clases diferentes clases de imágenes binarias (en blanco y negro) e imágenes con niveles de gris. Así como las imágenes binarias se pueden representar como subconjuntos del plano \mathbb{R}^2 o de \mathbb{Z}^2 según sean imágenes euclídeas o digitales, las imágenes con niveles de gris se pueden representar como funciones de \mathbb{R}^2 en \mathbb{R} o funciones de \mathbb{Z}^2 en \mathbb{R} , según sean euclídeas o las digitales.

Así como en el caso de las imágenes binarias, un subconjunto A de \mathbb{R}^2 o de \mathbb{Z}^2 puede representarse por su función característica $h_A: \mathbb{R}^2 \rightarrow \{0,1\}$ o $h_A: \mathbb{Z}^2 \rightarrow \{0,1\}$ (esta función vale 1 si el punto está en el conjunto A y 0 si no lo está); en el caso de las imágenes Euclídeas, \mathbb{R}^2 será considerado siempre como \mathbb{R} -espacio vectorial y con la estructura usual de espacio topológico.

4.1.1 Operaciones básicas en niveles de gris

Cuando se quiere aplicar las transformaciones morfológicas a imágenes con niveles de gris, el problema es que, a diferencia de las imágenes binarias, éstas no son representadas como subconjuntos de \mathbb{R}^3 ; sino como funciones con dominio en \mathbb{R}^2 y rango en \mathbb{R} (Heijmans, H., 1991).

Sobre estas funciones no es posible utilizar directamente las herramientas desarrolladas en la morfología matemática binaria, por estar definidas solamente para conjuntos. La solución adoptada es considerar el subconjunto de \mathbb{R}^3 formado por todos los puntos que están por debajo de la superficie determinada por la función. Sobre este conjunto se pueden aplicar transformaciones morfológicas y de los conjuntos resultantes obtener nuevamente una función, que sería la imagen resultante.

Para facilitar el cálculo de las transformaciones en \mathbb{R}^3 , se ha desarrollado una extensión de la morfología para conjuntos, llamada morfología para funciones. Las operaciones básicas de esta nueva morfología son la dilatación y la erosión de funciones por funciones, a partir de las cuales se pueden definir todas las demás transformaciones en forma equivalente a como se hizo en la morfología binaria.

Estas transformaciones heredan las propiedades de sus equivalentes para imágenes binarias, por lo que se puede también definir granulometrías y distribuciones de tamaño sobre funciones, manteniendo la validez de los principios de la Morfología Matemática.

Se llama imagen con niveles de gris, a diferencia de imagen binaria, a una función $F(x)$ positiva semicontinua superior definida sobre un subconjunto de \mathbb{R}^2 y con rango en \mathbb{R} (o un subconjunto acotado de \mathbb{R}). Como una imagen con niveles de gris es una función, muchas definiciones y propiedades se harán con respecto a funciones (de \mathbb{R}^2 en \mathbb{R}), siendo directa su aplicación a imágenes con niveles de gris. En la mayoría de los ejemplos se usarán funciones con dominio en \mathbb{R} por su simplicidad.

Una *sombra* o *umbra* es el conjunto cerrado $\mathbf{U} \subset \mathbb{R}^3$ tal que si un punto (x,y,z) pertenece a \mathbf{U} entonces todos los puntos de la forma (x,y,t) con $t \leq z$ también pertenecen a \mathbf{U} (Jain, A., 1989). Si Ψ es una función, se llama *sombra* de Ψ , notada $\mathbf{U}(\Psi)$, al conjunto de

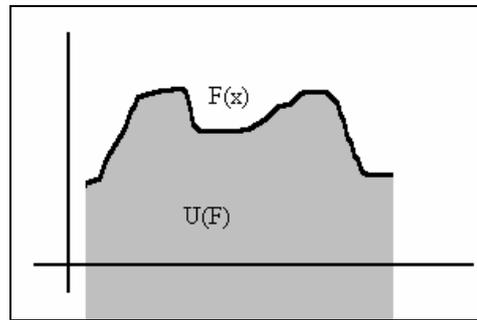


Fig.4-1 Imagen F(x) y su sombra U(F)

puntos de \mathbb{R}^3 que están directamente debajo de la superficie de Ψ , o sea, el conjunto de puntos (x,y,z) tales que (x,y) pertenecen al dominio de Ψ y $z \leq \Psi(x,y)$. (En la figura 4-1 se puede observar que la *sombra* de una función es una *sombra* en si misma).

Dado un conjunto cerrado $U \subset \mathbb{R}^3$, se puede definir la función superficie superior de U , notada $T(U)$, de la siguiente manera. Dados $(x,y) \in \mathbb{R}^2$ tales que existe un valor $z \in \mathbb{R}$ con $(x,y,z) \in U$, se define $T(U)(x,y)$ como el supremo de los valores z tales que $(x,y,z) \in U$. El dominio de esta función será el conjunto $\{ (x,y) \in \mathbb{R}^2 : \exists z \in \mathbb{R} : (x,y,z) \in U \}$ (Wang D., Ronsin J., 1996).

Con las definiciones anteriores se tiene una relación que asocia a cada imagen con niveles de gris, con su *sombra*, que es un conjunto cerrado en \mathbb{R}^3 . Pero esta relación es biunívoca, por lo que la operación de obtener la *sombra* y la de obtener la superficie superior son operaciones inversas (sobre la familia de imágenes y la de las *sombras* respectivamente). Esto significa que si F es una imagen y $A \subset \mathbb{R}^3$ es una *sombra*, entonces $T(U(F)) = F$ y $U(T(A)) = A$. Esta propiedad será la base a partir de la cual se definirán las transformaciones básicas para funciones.

4.1.1.1 Erosión en niveles de gris

Un resultado importante respecto a las sombras es que para cualquier par de sombras $A, B \subset \mathbb{R}^3$, los conjuntos $A \oplus B$ y $A \ominus B$ son también sombras. Con este resultado

se pueden definir las transformaciones sobre funciones definiéndolas sobre su sombra asociada (Dougherty, E., 1992).

Sean f , g dos imágenes con niveles de gris, entonces se define la *suma de Minkowsky* de f por g como

$$f \oplus g = T[U(f) \oplus U(g)] \quad (4-1)$$

Esto significa realizar una *suma de Minkowsky* en \mathbb{R}^3 entre las *sombras* de f y g , obteniendo posteriormente la función asociada a la *sombra* resultante.

La *erosión* de una imagen $f(x,y)$ con un elemento estructurante $g(x,y)$ puede interpretarse a partir de la figura 4-2.

El elemento estructurante se desplaza por debajo de la superficie de la imagen, de forma tal que haga contacto y no sobrepase hacia arriba la parte superior de esta superficie. La trayectoria que describe el centro del elemento estructurante, determina la imagen erosionada.

En la figura 4-3 se muestra el resultado de erosionar con un estructurante plano a una imagen de resonancia magnética de cerebro como las utilizadas en esta tesis.

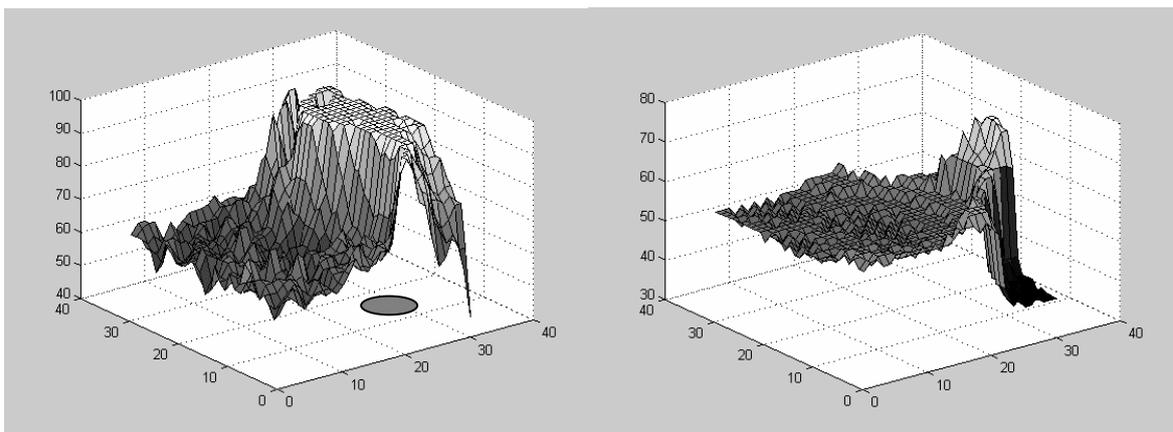


Fig.4-2 Ejemplo de erosión en niveles de gris con elemento estructurante plano.

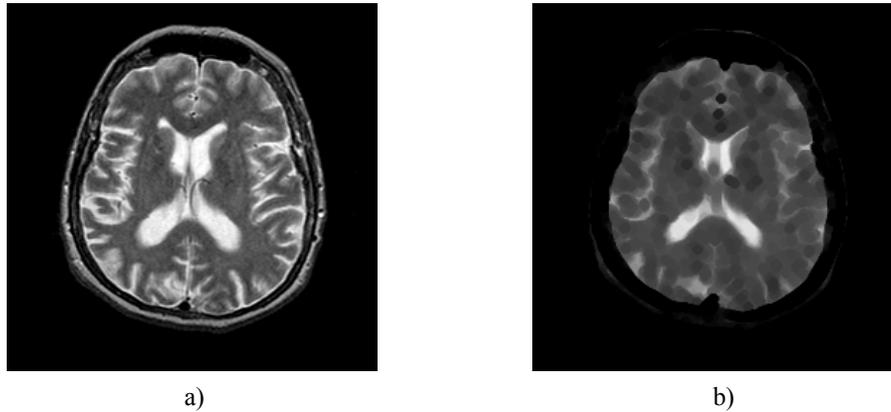


Fig.4-3 a) Imagen original de 256 niveles de gris b) imagen erosionada con un elemento estructurante plano en forma de disco.

Cuando se aplica la operación erosión a una imagen con niveles de gris se aprecian los siguientes efectos:

- Debido a que punto a punto la intensidad de cada pixel es menor o igual que la intensidad del pixel original, la imagen dilatada resulta más oscura que la imagen original.
- El área que ocupa una zona clara de la imagen rodeada por zonas más oscuras, tiende a reducirse. Si el tamaño de la zona clara es menor que el tamaño del elemento estructurante desaparece, quedando sólo la zona oscura.

4.1.1.2 Dilatación en niveles de gris

En la *resta de Minkowsky* para niveles de gris no se puede utilizar $U(g)$ como en el caso anterior. Si se utilizara $U(g)$, la condición $U(g)'_x \subset U(f)$ no se cumpliría nunca, pues para cualquier punto x de R^2 $U(f)$ está acotado superiormente por $f(x)$ y $U(g)'_x$ no está acotado superiormente. Esto se puede evitar trasponiendo previamente la sombra $U(g)$ con respecto al eje z (vertical).

Sea $U \subset R^3$, se define el traspuesto de U , i.e. el conjunto rejejado de B respecto al origen (Serra, J.1982), como:

$$\hat{U} = \{ (x,y,-z) : (x,y,z) \in U \} \quad (4-2)$$

De esta forma se puede definir la *resta de Minkowsky* entre dos imágenes con niveles de gris f y g como

$$f \ominus g = T[U(f) \ominus \hat{U}(g)] \quad (4-3)$$

Aquí también se puede aplicar la Resta de Minkowsky definida sobre $P(\mathbb{R}^3)$ entre la *sombra* de f y la *sombra* de g , esta última traspuesta.

La *dilatación* de una imagen $f(x,y)$ con un elemento estructurante $g(x,y)$ puede interpretarse a partir de la figura 4-4.

El elemento estructurante reflejado se desplaza por encima de la superficie de la imagen, de forma tal que haga contacto y no sobrepase hacia abajo la parte superior de ésta superficie. La trayectoria que describe el centro del elemento estructurante reflejado, determina la imagen dilatada.

En la figura 4-5 se muestra el resultado de dilatar con un estructurante plano una imagen de resonancia magnética de cerebro como las utilizadas en esta tesis.

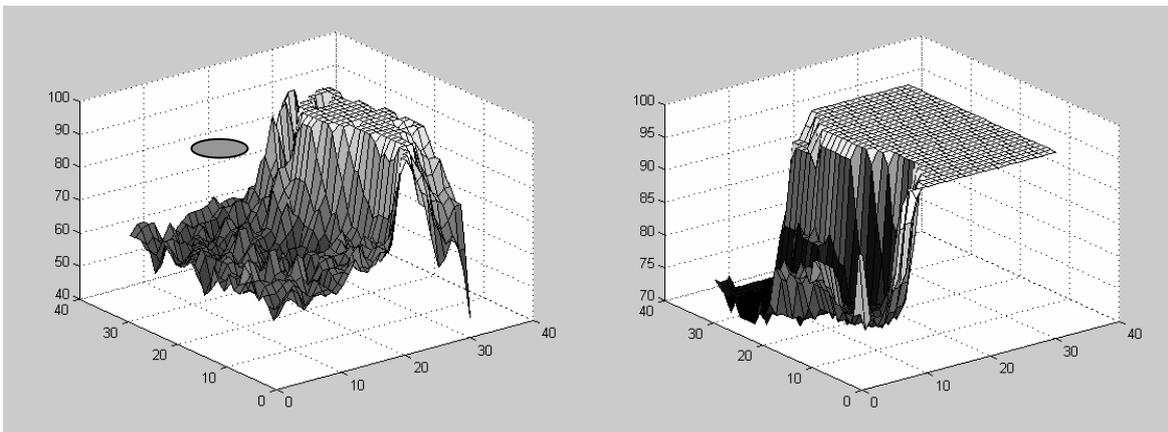


Fig.4-4 Ejemplo de dilatación en niveles de gris con elemento estructurante plano.

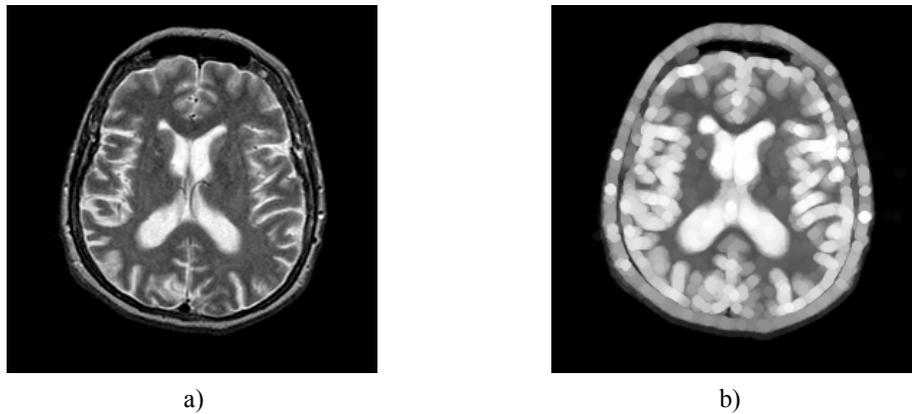


Fig.4-5 a) Imagen original de 256 niveles de gris b) imagen dilatada con un elemento estructurante plano en forma de disco.

Cuando se aplica la operación dilatación a una imagen con niveles de gris se aprecian los siguientes efectos:

- Debido a que punto a punto la intensidad de cada pixel es mayor o igual que la intensidad del pixel original, la imagen dilatada resulta más clara que la imagen original.
- El área que ocupa una zona clara de la imagen rodeada por zonas más oscuras, tiende a ampliarse. Si el tamaño de la zona oscura es menor que el tamaño del elemento estructurante, la zona oscura desaparece, quedando sólo la zona clara.

A efecto de realizar el cálculo de estas transformaciones, las fórmulas anteriores implicarían realizar dilataciones o erosiones de conjuntos no acotados en \mathbb{R}^3 . El siguiente teorema permite obtener una fórmula equivalente pero sencilla para calcular la suma y resta de Minkowsky de funciones (Serra, J. 1982).

Teorema: Sean f , g dos funciones con dominio en D y E respectivamente, entonces la suma de Minkowsky y la resta de Minkowsky de f por g cumplen con las siguientes propiedades:

$$(f \oplus g)(x) = \supr \{ f(x-b)+g(b) : b \in E, x-b \in D \} \quad (4-4)$$

$$(f \ominus g)(x) = \inf \{ f(x-b) -g(b) : b \in E, x-b \in D \} \quad (4-5)$$

4.1.1.3 Apertura y cerradura en niveles de gris

Una vez definidas la suma y resta de Minkowsky para niveles de gris, se puede definir una extensión para la apertura y cerradura, aplicando las transformaciones sobre las sombras de las funciones y trasponiendo la sombra de la segunda función cuando sea necesario.

Previamente se debe definir la simetría de una función respecto al origen, que estará dada por $g'(x) = g(-x)$. Aquí hay que diferenciar entre las expresiones $U(g')$ y $U(g)'$, pues la primera es la *sombra* de la función $g(-x)$ y la segunda es el simétrico respecto del origen (en \mathbb{R}^3) de la *sombra* de $g(x)$. Esta diferencia puede apreciarse en la figura 4-6.

Sean f y g dos imágenes con niveles de gris, se puede definir la *apertura* y *cerradura* entre funciones como:

$$f \circ g = T \{ [U(f) \ominus U(g)'] \oplus U(g) \} \quad (\text{apertura}) \quad (4-6)$$

$$f \bullet g = T \{ [U(f) \oplus U(g')] \ominus [U(g')]' \} \quad (\text{cerradura}) \quad (4-7)$$

Resulta más natural definir estas dos operaciones en función de la suma y resta de Minkowsky para funciones, sin embargo la siguiente proposición afirma que ambas definiciones son equivalentes (Serra, J. 1982).

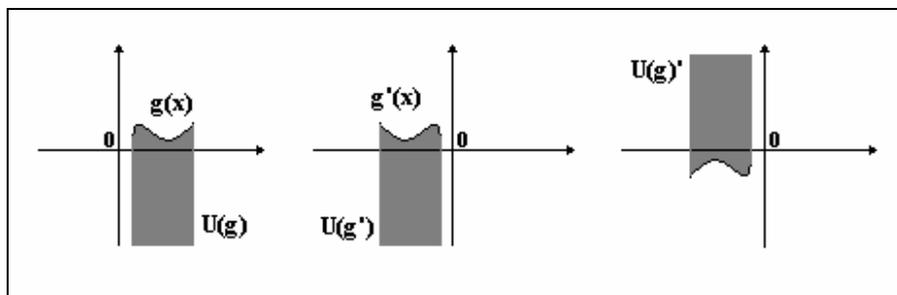


Fig.4-6 Diferencias entre $U(g')$ y $U(g)'$

Prop: Sean f , g dos funciones con dominio en D y E respectivamente, entonces

$$(f \circ g) = (f \ominus g') \oplus g \quad (4-8)$$

$$(f \bullet g) = (f \oplus g') \ominus g \quad (4-9)$$

La apertura generalmente suaviza el contorno de la imagen, elimina las partes angostas y las salientes delgadas. Es de utilidad para eliminar detalles luminosos pequeños en relación al elemento estructurante, quedando el resto de la imagen relativamente sin modificaciones.

Desde el punto de vista de filtrado, la apertura por un disco produce un redondeo de las esquinas, es decir es un filtro que suaviza desde adentro produciendo un efecto pasabajos.

Si bien la posición del origen relativo al elemento estructurante tiene importancia en los casos de dilatación y erosión, no juega ningún papel en el caso de aperturas y cerraduras.

Cuando se erosiona una imagen, el área de una zona clara rodeada de zonas más oscuras, se ve reducida. En particular, si el tamaño del elemento estructurante es mayor que el área de la zona clara, ésta desaparece, se reducen los detalles luminosos pequeños y sólo queda la zona oscura.

Al dilatar la imagen resultante, el área de una zona clara rodeada de zonas más oscuras, tiende a ampliarse y por lo tanto la imagen recupera su intensidad o tamaño anterior, excepto que los detalles eliminados por la erosión previa, no vuelven a aparecer.

En la figura 4-7 se muestra el resultado de aperturar con un estructurante plano a una imagen de resonancia magnética de cerebro.

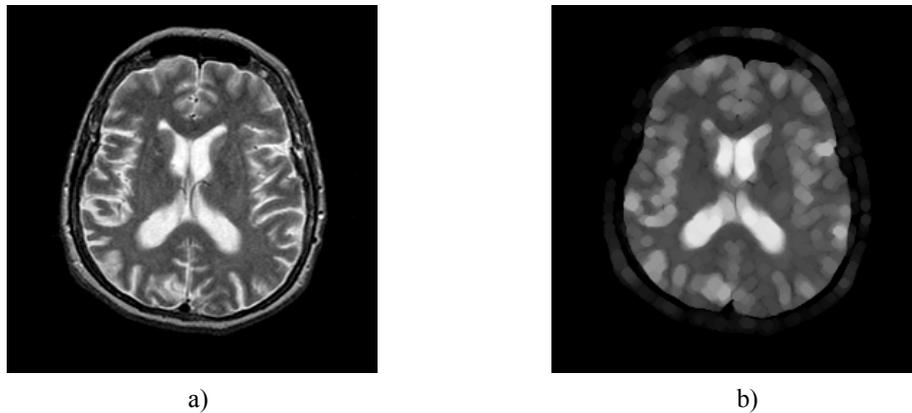


Fig.4-7 a) Imagen original b) Apertura de una imagen de 256 niveles de gris con un elemento estructurante plano en forma de disco.

La cerradura también tiende a suavizar secciones de los contornos, pero a diferencia de la apertura, fusiona espacios angostos, y entradas largas y delgadas, elimina huecos pequeños y rellena espacios en el contorno. Es de utilidad para eliminar detalles oscuros pequeños en relación al elemento estructurante, quedando el resto de la imagen relativamente sin modificaciones.

Cuando se dilata una imagen, el área de una zona clara rodeada de zonas más oscuras, se ve ampliada. En particular, si el tamaño del elemento estructurante es mayor que el área de la zona oscura, ésta desaparece, se reducen los detalles oscuros pequeños.

Al erosionar la imagen resultante, el área de una zona clara rodeada de zonas más oscuras, tiende reducirse y por lo tanto la imagen recupera su intensidad o tamaño anterior, excepto que los detalles eliminados por la dilatación previa, no vuelven a aparecer. En la figura 4-8 se muestra el resultado de aplicar una cerradura con un estructurante plano a una imagen de resonancia magnética de cerebro.

4.1.1.4 Elementos Estructurantes

Mientras que la morfología binaria se basa en las operaciones de unión e intersección, en la morfología en niveles de gris juegan un papel clave los máximos y los mínimos de una función y la dimensión de los elementos estructurantes.

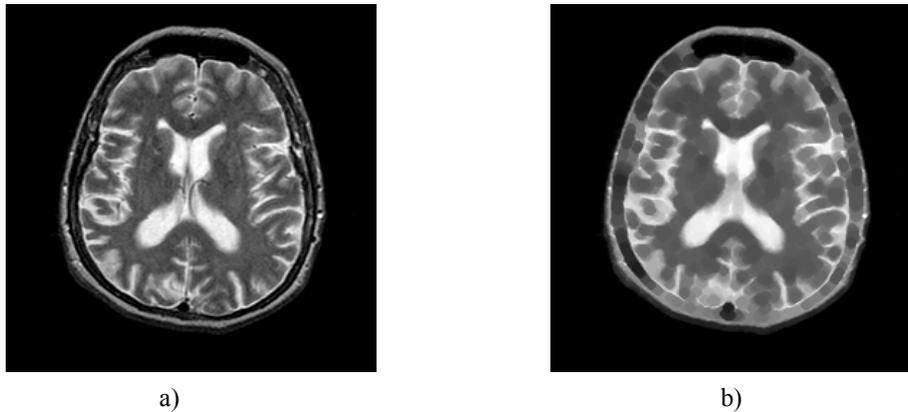


Fig.4-8 a) Imagen original b) ceradura de una imagen de 256 niveles de gris con un elemento estructurante plano en forma de disco.

Para el caso de la morfología en niveles de gris existen dos tipos de elementos estructurantes posibles, los planos y los no-planos (Heijmans, H., 1991; Serra J., 1992). No hay que pensar en los elementos estructurantes 3D como bolas paseando por el espacio 3D. Recordando que una imagen tridimensional se puede representar como una superficie sobre una base en dos dimensiones, que es el dominio, se puede pensar a los elementos estructurantes como pequeñas pirámides que se trasladan en el espacio bidimensional y suben y bajan para tocar la superficie de la imagen.

Cuando se efectúa la erosión de una imagen con niveles de gris y se trabaja con elementos estructurantes planos, lo que se hace es tomar el ínfimo alrededor de cada punto de la imagen. La región donde se toma el ínfimo está definida por el elemento estructurante, que es en este caso, una región del espacio 2D.

Cuando se define el elemento estructurante plano en realidad se define solamente una región del espacio 2D, por ejemplo $B = \{ (0,-1) , (0,0) , (0,1) \}$ es un elemento estructurante con 3 puntos, que puede ser representado por la siguiente matriz:

$$B = \begin{bmatrix} 0 & 0 & 0 \\ 1 & 1 & 1 \\ 0 & 0 & 0 \end{bmatrix} \quad (4-10)$$

Si $f(x, y)$ es una imagen, en la cual $f(x, y)$ es el nivel de gris en (x, y) , entonces de acuerdo a la ecuación 4-5:

$$\begin{aligned} (f \ominus g)(x) &= \inf \{ f(x-b) - g(b) : b \in E, \dots x-b \in D \} \\ &= \inf (f(x, y-1), f(x, y), f(x, y+1)) \end{aligned} \quad (4-11)$$

En el caso de elementos estructurantes no planos éstos deben representarse de la siguiente forma:

$$B = (D, g) \quad (4-12)$$

donde D es el dominio y g la función

Si por ejemplo

$$D = \{(0, -1), (0, 0), (0, 1)\} \quad \text{y} \quad g(0, -1)=1 \quad g(0, 0)=2 \quad g(0, 1)=1 \quad (4-13)$$

En éste caso la erosión se define también acorde a la ecuación 3-39:

$$\begin{aligned} (f \ominus g)(x) &= \inf (f(x, y-1)-g(0, -1), f(x, y)-g(0, 0), f(x, y+1)-g(0, 1)) \\ &= \inf (f(x, y-1)-1, f(x, y)-2, f(x, y+1)-1) \end{aligned} \quad (4-14)$$

El caso de elementos estructurantes planos puede ser considerado como un caso particular de los no planos:

$$D = \{(0, -1), (0, 0), (0, 1)\} \quad \text{y} \quad g(0, -1)=0 \quad g(0, 0)=0 \quad g(0, 1)=0 \quad (4-15)$$

y la erosión queda definida como

$$\begin{aligned} (f \ominus g)(x) &= \inf (f(x, y-1)-g(0, -1), f(x, y)-g(0, 0), f(x, y+1)-g(0, 1)) \\ &= \inf (f(x, y-1)-0, f(x, y)-0, f(x, y+1)-0) \\ &= \inf (f(x, y-1), f(x, y), f(x, y+1)) \end{aligned} \quad (4-16)$$

que es la misma expresión que en el caso de los elementos estructurantes planos.

Al dilatar un pixel claro, o al erosionar un pixel oscuro con respecto al fondo con un elemento estructurante plano, el pixel toma la forma del elemento estructurante. Si se realiza el proceso con una zona del mismo valor en vez de un pixel, los bordes de la zona tienden a seguir la forma del elemento estructurante usado.

En la Figura 4-9 se puede observar una imagen de resonancia magnética a la que se le efectuó una erosión con un elemento estructurante en forma de disco y con un elemento estructurante en forma de cruz. Como era de esperarse el resultado de la operación morfológica da como resultado una imagen en forma de mosaicos, dependiendo del tamaño de la imagen y del elemento estructurante usado. Este efecto puede reducirse utilizando elementos estructurantes en forma de disco.

De todas formas la elección del elemento estructurante a utilizar en las operaciones morfológicas, se basa principalmente en las experiencias obtenidas en la práctica y en el caso de su aplicación a análisis de texturas, del tipo de *texels* que presenten las texturas a discriminar en las imágenes en cuestión. Para este trabajo y dado los *texels* predominantes en las imágenes de resonancia magnética se utilizaron elementos estructurantes en forma de disco. En la Figura 4-10 se pueden observar diferentes tipos de elementos estructurantes.

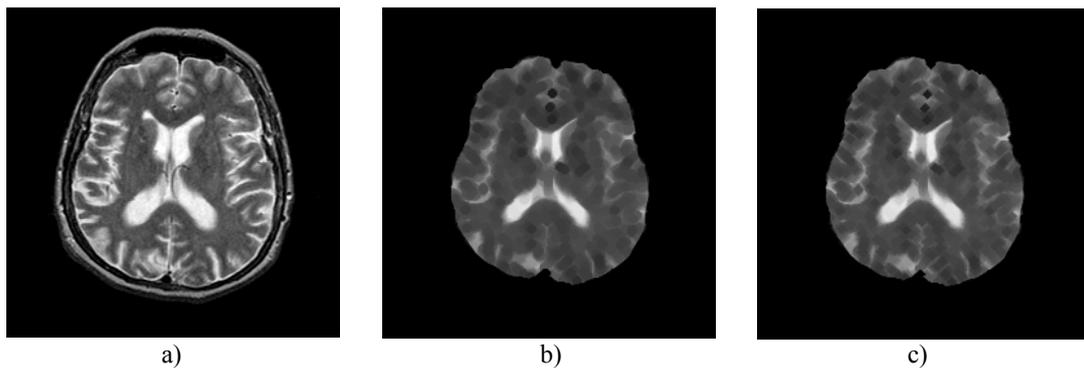


Fig.4-9 a) Imagen de RMN original b) imagen erosionada con un elemento estructurante en forma de disco c) imagen erosionada con un elemento estructurante en forma de cruz.

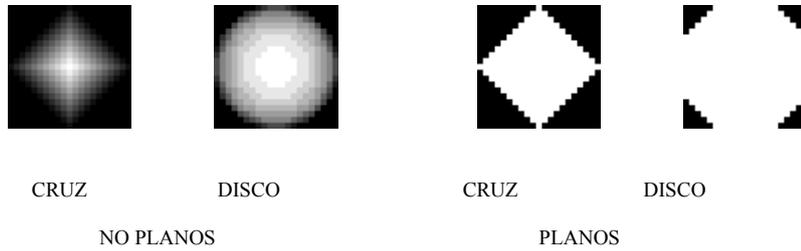


Fig.4-10 Diferentes tipos de elementos estructurantes planos y no-planos..

4.1.1.5 Propiedades Algebraicas

Def. Una transformación Ψ es una *apertura algebraica* si cumple las siguientes propiedades (Dubreil, M.L. 1964):

$$1. \Psi(X) \subset X \quad (\text{antiextensiva}) \quad (4-17)$$

La apertura es antiextensiva, es decir $A \text{ o } B \subseteq A$. Esto se debe a que la operación de apertura es una unión de traslaciones que siempre quedan incluidas en la imagen de entrada.

La cerradura por el contrario es extensiva:

$$X^1 \subset X^2 \Rightarrow \Psi(X^1) \subset \Psi(X^2) \quad (\text{incremental}) \quad (4-18)$$

$$\Psi(\Psi(X)) = \Psi(X) \quad (\text{indempotente}) \quad (4-19)$$

La importancia de esta última propiedad reside en que una vez que a una imagen se le han efectuado aperturas o cerraduras, las aperturas o cerraduras posteriores no producen efectos adicionales (Serra, J. 1992).

Se puede demostrar que la apertura morfológica por un elemento estructurante B cumple con estas tres propiedades, por lo que se puede enunciar lo siguiente:

Prop: La *apertura morfológica* es una *apertura algebraica*

$$1. X \circ B \subset X \quad (4-20)$$

$$2. X^1 \subset X^2 \Rightarrow X^1 \circ B \subset X^2 \circ B \quad (4-21)$$

$$3. (X \circ B) \circ B = X \circ B \quad (4-22)$$

También se puede ver que la *cerradura* no es una *apertura algebraica*, pues cumple con las propiedades segunda y tercera, pero no con la primera propiedad necesaria para ser una *apertura algebraica*:

Prop: La *cerradura* es extensiva, incremental e idempotente.

$$1) X \subset X \bullet B \quad (\text{extensiva}) \quad (4-23)$$

$$2) X^1 \subset X^2 \Rightarrow X^1 \bullet B \subset X^2 \bullet B \quad (\text{incremental}) \quad (4-24)$$

$$3) (X \bullet B) \bullet B = X \bullet B \quad (\text{idempotente}) \quad (4-25)$$

Una propiedad muy importante de la *apertura morfológica* es que cualquier *apertura algebraica* que sea invariante bajo traslaciones puede escribirse como unión de *aperturas morfológicas*, y está dada por la siguiente proposición:

Prop: Sea $\Psi : P(\mathbb{R}^n) \rightarrow P(\mathbb{R}^n)$ una *Apertura Algebraica* invariante bajo traslaciones, entonces Ψ puede escribirse como :

$$\Psi(X) = \bigcup_{\substack{B \subset \mathbb{R}^n \\ \Psi(B)=B \\ 0 \in \Psi(B)}} X \circ B \quad (4-26)$$

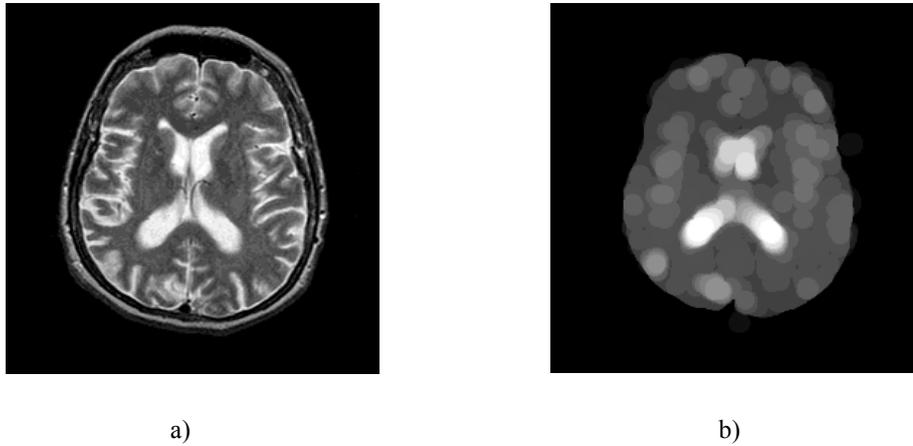


Fig. 4-11. a) Imagen de RMN T₂, corte horizontal de cerebro de un paciente con probable enfermedad de Alzheimer. b) La misma imagen luego de aplicarle una apertura morfológica con un elemento estructurante en forma de disco de diámetro 6 píxeles.

Resumiendo, la apertura como filtro es creciente, invariante a la traslación, antiextensivo e idempotente. Estas propiedades hacen, que la apertura, sea la mejor elección para la granulometría.

4.1.2 Segmentación de los ventrículos laterales

Para este caso particular primero se aplica una apertura morfológica con un elemento estructurante con forma de disco. (Ver figura 4-11.) Al aplicar una apertura morfológica se logra intensificar parte del ventrículo pero también se borrea la imagen como resultado de la erosión y la dilatación sucesiva.

Para contrarrestar el efecto no deseado del resultado de la apertura, se le aplica una dilatación morfológica condicionada a la imagen original, obteniendo así una reconstrucción en la que se consigue intensificar el ventrículo (Fig. 4-12 a). La dilatación condicionada consiste en dilatar la imagen con el mismo elemento estructurante utilizado en la apertura morfológica y luego realizar una intersección entre la imagen resultado con la original:

$$Y = (X \oplus B) \cap X \quad (4-27)$$



Fig. 4 -12 a)) Imagen de RMN T_2 , corte horizontal de cerebro de un paciente con probable enfermedad de Alzheimer. b) Mediante una dilatación condicionada a la imagen original se consigue reconstruir el ventrículo intensificado y finalmente a través de la aplicación de un algoritmo de umbralamiento se segmenta el ventrículo.

De esta manera la forma del ventrículo de la imagen original no se ve afectada, permitiendo una reconstrucción exacta de su perímetro y su área.

Finalmente a la imagen con el ventrículo resaltado se le aplica un algoritmo de umbralamiento que conserva los valores superiores en la imagen obteniendo así la segmentación del ventrículo (Fig. 4-12 b).

En las imágenes de las Figuras 4-13, 4-14 y 4-15 se observan algunos de los resultados obtenidos de la segmentación propuesta (Ballarin, V. et al. 2001). Si bien las imágenes pesadas en T_2 presentan poco contraste entre la materia gris y la materia blanca (esto se puede atribuir a que el tiempo T_2 está directamente relacionado con las interacciones spin-spin); presentan un buen contraste de la materia gris respecto del LCR (líquido céfalo-raquídeo) permitiendo la mejor segmentación del ventrículo.

Las imágenes de RMN del cerebro contienen también información que no es útil a los fines de la segmentación de tejidos. Este tipo de algoritmos basados en morfología matemática, al considerar a la imagen como un conjunto de píxeles, hace innecesario el uso de rutinas adicionales para la extracción del cráneo, la grasa circundante y las meninges.



Fig. 4-13 a) Imagen de RMN T₂, corte horizontal de cerebro de una paciente de 72 años con probable enfermedad de Alzheimer. b) Segmentación de los ventrículos laterales a partir de la imagen anterior utilizando operaciones Morfológicas.



Fig. 4-14 a) Imagen de RMN T₂, corte horizontal de cerebro de una paciente de 74 años con atrofia cerebral y un ensanchamiento de la fisura sulcal. b) Segmentación de los ventrículos laterales a partir de la imagen anterior utilizando operaciones Morfológicas.



Fig. 4-15 a) Imagen de RMN T₂, corte horizontal de cerebro de una mujer de 71 años con una historia de alucinaciones visuales. b) Segmentación de los ventrículos laterales a partir de la imagen anterior utilizando Operaciones Morfológicas.

La ventaja principal de la segmentación obtenida es la reconstrucción exacta del ventrículo original, ya que involucra una reconstrucción condicionada a la imagen original, asegurando de esta manera exactitud en los cálculos posteriores para la medición del aumento relativo del área ventricular. Además, los algoritmos de implementación de estos procesos morfológicos son veloces con respecto a cualquier otro algoritmo de segmentación tradicional ya que las operaciones básicas involucradas son de carácter lógico y no algebraico, lo que significa un menor número de cálculos.

Una vez segmentado el ventrículo, el paso siguiente es la segmentación de la materia gris respecto de la blanca.

4.1.3 Extensión de la Granulometría a niveles de gris

La idea central de esta tesis es segmentar regiones por textura tomando para cada pixel un vector de características obtenidas a través de operaciones morfológicas, que indican una medida de textura presente en dicho punto. Las características asociadas a cada pixel se obtienen de aplicar el Criterio de Tamaños de Aperturas Sucesivas sobre una máscara centrada en un pixel. El Criterio de Tamaños, involucra las transformaciones morfológicas básicas erosión, dilatación, apertura y cerradura. Con ello se obtiene una Función de Distribución de Tamaños asociada a cada máscara.

Derivando esta Función de Distribución se obtiene una Función de Densidad, con la cual se puede calcular estadísticos tales como el valor medio y la varianza que pasan a formar parte del vector de características. Este vector de características es la variable de entrada para distintos algoritmos de clasificación.

Estos algoritmos normalmente se utilizan para imágenes binarias. La propuesta de esta tesis es incursionar en la granulometría para imágenes con niveles de gris. En el siguiente capítulo se ahondará más en el tema específico de la Granulometría en niveles de gris, el Criterio de Tamaños y las estadísticas asociadas a éste.

4.1.3.1 Textura y distribución granulométrica de tamaño local

Hasta ahora se supuso que la textura ocupa el marco entero de la imagen. Como un caso más general en esta tesis se propone considerar un proceso de imagen S definido en un marco F de forma tal que ese marco se puede particionar en n submarcos:

$$F = F_1 \cup F_2 \cup \dots \cup F_n \quad (4-28)$$

F_i y F_j son disjuntos si $i \neq j$.

Si se restringe a F_i , S está definida por el proceso de textura T_i . Para $i \neq j$, T_i y T_j no tienen una distribución idéntica. De esta forma, S queda compuesta por texturas que se originan en la clase $T = \{T_1, T_2, \dots, T_n\}$, y el dominio de T_i es F_i . El problema de la segmentación consiste en observar una realización de S y estimar las regiones F_1, F_2, \dots, F_n . Usando una aproximación basada sobre los pixels, la tarea consiste en asociar un descriptor de características con cada pixel y entonces clasificar al pixel dentro de una de las regiones de acuerdo al valor del descriptor observado. Dado que la clasificación está basada en la textura y dado que ésta es regional, el descriptor de características en un pixel x debe ser función de alguna vecindad (ventana) que contenga a x .

En la aproximación global clásica a las granulometrías, se le practican aperturas sucesivas a la imagen entera y en cada etapa se registra la cantidad de pixels de la imagen. Para medir la textura local de la imagen en un pixel dado, más que contar la cantidad de pixels en la imagen completa se toma la cuenta en una ventana W_x sobre el pixel x . Para esta tesis se trabajó con ventanas variables que van desde los 3 pixeles y los 11 pixeles.

Sea una granulometría $\{X \circ E\}$ y una ventana W centrada en el origen. La distribución de tamaños local $G_x(\lambda)$ en un pixel x generado por la granulometría, se obtiene contando el número de pixels de $X \circ E\lambda$ en la ventana trasladada $W_x = W + x$ para cada valor de λ . Normalizando de acuerdo con la ecuación siguiente:

$$G(\lambda) = 1 - \frac{\Omega(\lambda)}{\Omega(1)} \quad (4-29)$$

se obtiene una distribución de tamaños granulométrica local $G_x(\lambda)$ y diferenciando, se obtiene una densidad del espectro patrón local $G'_x(\lambda)$.

Para cada espectro patrón local se pueden calcular sus momentos estadísticos. Si una subregión de la imagen presenta una textura homogénea es probable que los momentos permanezcan más o menos estables a través de dicha subregión mientras que subregiones, diferentes caracterizadas por texturas diferentes, se pueden diferenciar teniendo en cuenta los momentos locales del espectro patrón.

Para cada pixel x se obtiene una media m_x^1 y basándose en diferenciar valores de medias se pueden segmentar distintas regiones de pixels. De acuerdo al modelo de proceso aleatorio, cada media es una variable aleatoria y la exactitud de la segmentación depende de las distribuciones de probabilidad de las medias a través de las distintas regiones de textura.

La partición de la Eq. 3-53 produce a su vez una partición secundaria, basada en la ventana W , a la que se puede considerar como un elemento estructurante binario, a saber:

$$F = \left(\bigcup_{i=1}^n (F_i \ominus W) \right) \cup \left(F \setminus \bigcup_{i=1}^n (F_i \ominus W) \right) \quad (4-30)$$

Esta nueva partición puede ser escrita como:

$$F = F_h \cup F_b \quad (4-31)$$

Si $x \in F_h$, existe un valor de i tal que $W_x \subseteq F_i$. Si $x \in F_b$, no existe tal valor de i . Así para $x \in F_h$ e $y \in F_h$, si $x \in F_i \ominus W$, $y \in F_i \ominus W$ entonces m_x^1 tendrá una distribución idéntica a m_y^1 . Si x e y no caen en la misma región, m_x^1 y m_y^1 no tendrán una distribución idéntica. La segmentación de las subregiones de F_h resulta de considerar los valores de las medias locales.

En lo que se refiere a la región residual F_b , los pixels que se encuentran dentro de ella tienen ventanas que están incluidas en una región de más de una textura única. Como consecuencia, las medias locales en esos pixels resultan de procesos mixtos. Estas medias también se usan para la clasificación, pero con esto se pierde exactitud en la estimación. F_b

se compone de regiones de borde y el tamaño de estas regiones es una función del tamaño de la ventana.

Una ventana pequeña disminuye el tamaño de las regiones de borde, pero tiende a disminuir la exactitud de la estimación dentro de regiones debido a que hace que las medias se vuelvan más susceptibles de realizar fluctuaciones.

Para clasificar un pixel, se requiere alguna otra característica además de la media local, como ser la varianza y otros momentos del espectro patrón de orden más alto. Para segmentar imágenes reales, se requiere la aplicación de métodos de clasificación estadísticos para los momentos del espectro patrón local.

La aproximación general se puede describir a través de la familia de texturas $T = \{T_1, T_2, \dots, T_n\}$. Si x_i es un pixel arbitrario en la región $F_i \ominus W$, de manera tal que $W_{x_i} \subseteq F_i$, para una granulometría dada entonces existe un espectro patrón local asociado con x_i , el cual como una función aleatoria, está distribuido idénticamente con el espectro patrón local para cualquier otro pixel en $F_i \ominus W$. Este espectro patrón local tiene momentos $m_{x_i}^1$, $m_{x_i}^2$ y $m_{x_i}^3$, de forma tal que se puede asociar un vector de características aleatorio con x_i o con F_i . A este vector se lo designa $F_i = (m_{x_i}^1, m_{x_i}^2, m_{x_i}^3)$. Si se emplean m granulometrías diferentes, entonces F_i tendrá $3xm$ componentes características.

Si se supone conocida la distribución de probabilidad de F_i para $i=1, 2, \dots, n$, se observa una realización del proceso sobre la imagen y se selecciona un pixel x , las mismas características granulométricas que componen los vectores de características F_i se calculan localmente para x resultando así un vector de características F_x . Empleando alguna medida estadística de similitud, se puede determinar a cuál de los vectores de características F_1, F_2, \dots, F_n se encuentra más cercano el vector F_x observado. Si F_x está más cerca de F_i , entonces x se clasifica como perteneciente a una región de textura del tipo T_i es decir, se clasifica dentro de la región F_i . La aplicación del método depende de la elección del método de clasificación como se explica en el capítulo siguiente.

4.1.3.2 Elección del elemento estructurante

Cuando se realiza un análisis de texturas, se debe tener en cuenta que el efecto de la apertura depende tanto del tamaño como de la forma del elemento estructurante. La apertura está determinada por un elemento estructurante, el cual es elegido por su capacidad para detectar estructuras particulares que presenta la imagen de interés.

Una granulometría particular mide textura en relación a la forma del elemento estructurante generador. Sólo en muy pocos casos es suficiente tomar una única forma generadora. La elección de la secuencia de elementos estructurantes es importante para obtener una buena segmentación. Para lograr mejores resultados es necesario disponer de un número de distribuciones de tamaños locales generadas por varias secuencias de elementos estructurantes.

Sin embargo, aunque en principio se debería usar un número grande de características granulométricas, algunas pueden ser redundantes y los conjuntos de características grandes requieren tiempos de cálculo elevados. Esto se puede solucionar en parte por medio de procedimientos de minimización aunque para cierto tipos de textura, se puede obtener una buena exactitud usando sólo seis características.

El método es bastante robusto con respecto al ruido, debido a que las aperturas lo filtran. Además mientras las componentes de ruido sean lo suficientemente pequeñas, se esperaría que las mismas fueran filtradas con anterioridad en el proceso granulométrico.

4.1.3.3 Extensión a niveles de gris

En términos de erosión y dilatación, las aperturas en binario y en niveles de gris comparten la misma definición. En el caso binario, la apertura de un conjunto X por un elemento estructurante B queda determinada por la unión de todas las traslaciones de B que son subconjuntos de X . La apertura en niveles de gris de una función f por una función estructurante g queda determinada por el valor más alto de todas las traslaciones de niveles de gris de g que caen debajo de f . Del mismo modo que las aperturas en binario, las aperturas en niveles de gris presentan las propiedades de invarianza a la traslación, monotonidad creciente, antiextensiva e idempotencia.

Como ya demostrara Serra para la apertura binaria (Serra, J. 1982), la apertura morfológica en niveles de gris también es una *apertura algebraica* porque verifica las siguientes propiedades básicas:

1. $f \circ g \leq f$ (Antiextensividad) (4-32)
2. Si $f_1 \leq f_2 \Rightarrow f_1 \circ g \leq f_2 \circ g$ (Incrementalidad) (4-33)
3. $(f \circ g) \circ g = f \circ g$ (Idempotente) (4-34)

Para construir una granulometría en niveles de gris, se comienza con una forma primitiva g y luego se define una secuencia de funciones estructurantes g_1, g_2, g_3, \dots por:

$$\begin{aligned} g_1 &= g \\ g_2 &= g \oplus g \\ g_3 &= g \oplus g \oplus g \dots \end{aligned} \quad (4-35)$$

en donde \oplus significa dilatación en niveles de gris. La granulometría en niveles de gris basada en g es entonces la secuencia de imágenes a las que se le han practicado aperturas $\{ f \circ g_k \}$.

Las imágenes con aperturas forman una secuencia de imágenes decrecientes

$$f \circ g_1 \geq f \circ g_2 \geq f \circ g_3 \dots \quad (4-36)$$

La granulometría euclídeana se extiende así a señales con niveles de gris, pudiéndose construir distribuciones de tamaño granulométricas para el análisis de texturas.

Análogamente un criterio de tamaños queda definido por:

$$\Psi_n(X) = f \circ g_n \quad (4-37)$$

Para definir la función distribución de probabilidad ahora se utiliza el parámetro $\Omega(f \circ ng)$ que representa el volumen bajo la imagen en cuestión, también se puede escribir como $V_x(n)$.

En el caso de imágenes con niveles de gris, no es tan directo encontrar un valor n_0 que cumpla $f \circ g_{n_0} = 0$. Además, si se encontrara dicho valor, habría que realizar aperturas con elementos estructurantes de tamaño muy grande, a pesar de que la información relevante se encuentra para los primeros valores de $\Omega(f \circ ng)$.

Se propone terminar el proceso para algún valor predefinido de n_0 y redefinir la Distribución Normalizada de tamaños de la siguiente forma:

$$G(n) = G_n(f) = 1 - \frac{\Omega(f \circ ng) - \Omega(f \circ n_0 g)}{\Omega(f) - \Omega(f \circ n_0 g)} = 1 - \frac{V_f(n) - V_f(n_0)}{V_f(0) - V_f(n_0)} \quad (4-38)$$

Esta función presenta las siguientes propiedades:

$$\begin{aligned} G(0) &= 0 \\ G(n_0) &= 1 \\ G(n+1) &\geq G(n) \quad n=0 \dots n_0-1 \end{aligned} \quad (4-39)$$

Esta nueva función se puede utilizar como parámetro de textura y es la diferencia entre el volumen de la función antes y después de cada apertura. Para llevar a cabo la clasificación de los pixels de una imagen, se debe asignar a cada uno de ellos la función $G'(n)$ que caracterizará a la textura en el entorno de dicho pixel permitiendo el posterior cálculo de sus momentos estadísticos.

$$\begin{aligned} G(n) &= G_n(f) \quad n=0 \dots n_0 \\ G'(n) &= g(n) = G(n+1) - G(n) \quad n=0 \dots n_0-1 \end{aligned} \quad (4-40)$$

4.1.3.4 Implementación práctica

Una imagen en niveles de gris f es una función de dos variables. Un elemento estructurante en niveles de gris es un área de imagen g definida sobre un dominio bidimensional pequeño. La apertura de f por g en niveles de gris, denotada $f \circ g$, se obtiene encontrando todas las traslaciones del gráfico de g que calzan debajo del gráfico de f y entonces tomando en cada pixel el máximo valor de gris de todas las traslaciones del gráfico de g .

Para implementar los algoritmos que permiten encontrar los característicos de la textura, se procedió siguiendo los pasos que se detallan a continuación:

- Primero se elige el tamaño de la ventana para calcular el volumen debajo de un entorno del pixel así como el elemento estructurante.
- A continuación se realiza la apertura de la imagen con el elemento estructurante elegido.
- Luego se calcula el volumen debajo de la ventana como la sumatoria de los niveles de gris en la máscara.
- Se dilata el elemento estructurante consigo mismo.
- Se repite el segundo paso.

Esta secuencia debe realizarse un número de veces igual al número de aperturas elegido. Como resultado de estas operaciones se obtiene una serie de matrices que coincide con la cantidad de aperturas. La cantidad de elementos de cada matriz coincide con el número de pixels de la imagen y en cada posición de cada matriz se encuentra el volumen correspondiente al entorno de cada pixel. (Ver Figura 4-16)

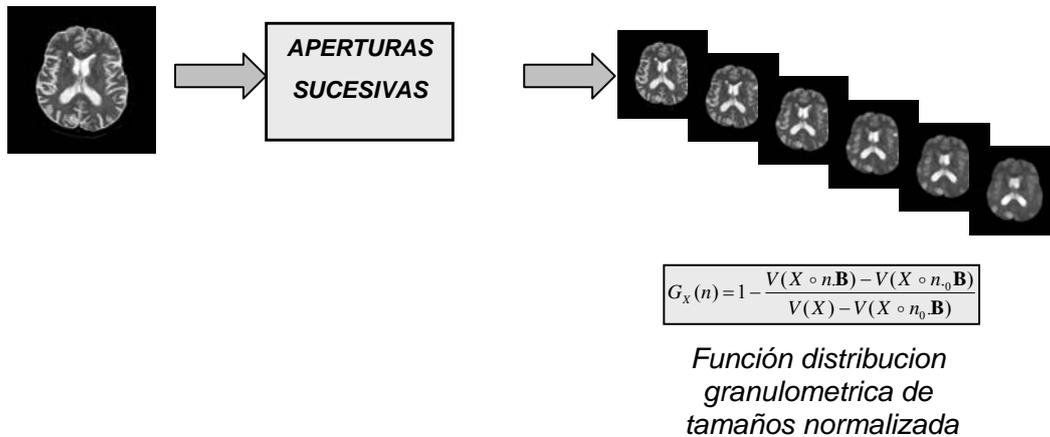


Figura 4-16 Diagrama de la construcción de la función distribución granulométrica de tamaños.

Una vez que se dispone de todas las matrices, se procede a calcular las funciones distribución, densidad y los momentos correspondientes, los cuales serán nuevamente un conjunto de matrices.

A partir de las funciones de distribución, las funciones densidad de probabilidad $g_x(n)$ y sus momentos pueden ser obtenidos para una posterior clasificación de los subconjuntos de la imagen X.

Dado que no se tiene un conocimiento previo de las regiones H_i (ver sección 3.7.1), los algoritmos utilizados fueron de clasificación no supervisada. Dado que tampoco se tiene conocimiento de las funciones de densidad de probabilidad de los niveles de gris, para agrupar las muestras en grupos se utilizaron métodos determinísticos. Estos métodos consisten en formar agrupamientos de puntos en el espacio de mediciones de acuerdo a una medida de similitud. Esta similitud usualmente está determinada por la proximidad de los puntos de acuerdo a una función distancia definida, aunque puede basarse en otras propiedades.

Las imágenes procesadas están representadas por matrices iguales de $N_c \times N_f$, donde N_c y N_f son el número de columnas y filas respectivamente. Los elementos de las matrices son los niveles de gris de los pixeles. El vector de características $X = (x_1, x_2, \dots, x_n)$ se conforma por los niveles de gris de las imágenes T_1, T_2 y P_d respectivamente y

los valores de los momentos (Ver figura 4-17). Cada coordenada del vector X representa un punto (o patrón) en el hiperplano de dimensión n. El objetivo es formar con estos puntos, cuatro clusters o grupos H1 , H2, H3 y H4 que representan las tres texturas a segmentar mas el fondo. Todos los pixeles de las imágenes cuyo vector X pertenezca a H_i son asignados a la clase W_i , obteniéndose de esta forma la imagen segmentada.

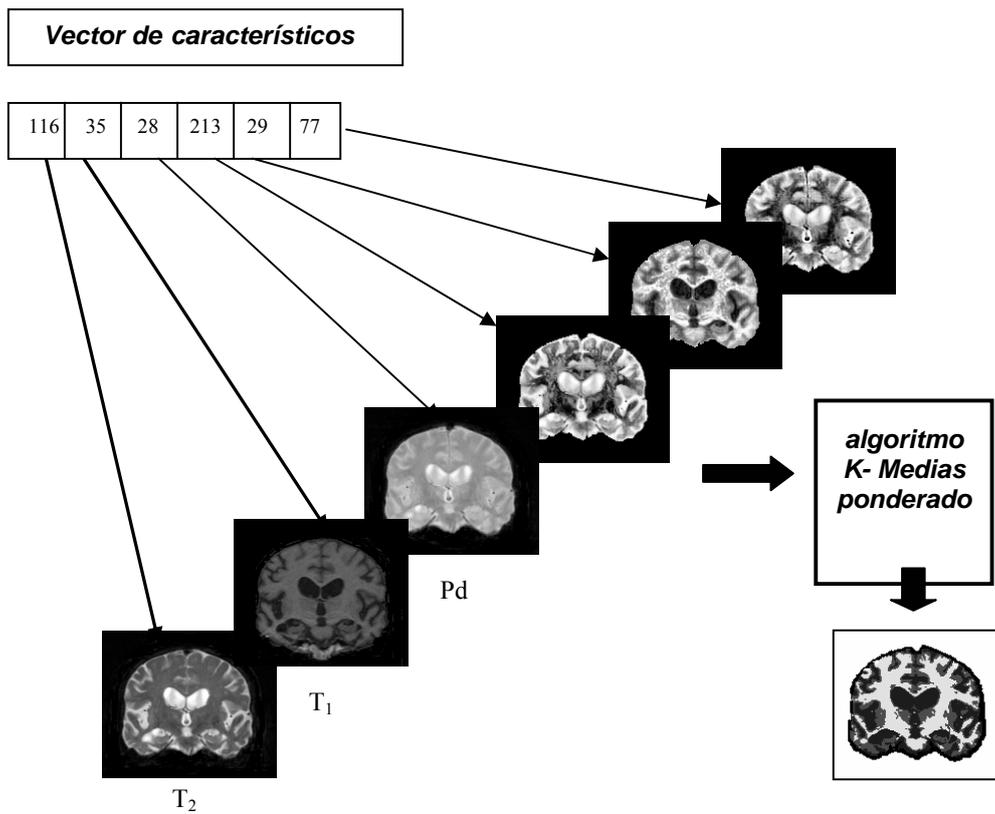


Fig. 4-17 Ejemplo de vector de característicos que se utiliza con entrada al algoritmo de reconocimiento de patrones. De izquierda a derecha imagen T_2 , imagen T_1 , imagen P_d , y las imágenes de los momentos.

4.1.4 Algoritmo de K-medias Ponderado

Para este trabajo se desarrolló una nueva variante del algoritmo K-medias, en el cual se tiene en cuenta para el cálculo de los centros de *cluster*, la cantidad de veces que aparece un determinado patrón X en las imágenes. Es decir, se utiliza una media ponderada en el cálculo de los centros.

Los pasos de este algoritmo son:

1. Se eligen 3 centros de *cluster* $m_1(1)$, $m_2(1)$ y $m_3(1)$.
2. En el paso h-ésimo se distribuyen las muestras X entre los tres dominios de *cluster*, asignando cada muestra al dominio cuyo centro sea el más cercano.
3. Del resultado del paso 2 se calculan los nuevos centros de cluster $m_1(h+1)$, $m_2(h+1)$ y $m_3(h+1)$ tal que:

$$J_j = \sum_{X \in S_j(h)} \|X - Z_j(h+1)\|^2 \quad (4-41)$$

siendo $j = 1, 2, 3$. El valor $Z_j(h+1)$ que minimiza este índice es simplemente el nuevo centro de cluster dado por

$$Z_j(h+1) = \frac{1}{N_j} \sum_{X \in S_j(h)} nX \quad (4-42)$$

siendo $j = 1, 2, 3$; donde N_j es el número de píxeles cuyos X pertenecen a la clase de centro $Z_j(h)$ y n es el número de píxeles en la imagen que tienen el patrón X.

4. Si $Z_j(h+1) = Z_j(h)$ para $j = 1, 2, 3$ el algoritmo termina pues hay convergencia, de lo contrario se vuelve al paso 2.

Se hicieron pruebas con los distintos algoritmos en varias imágenes. Los resultados evidencian que el algoritmo K-medias ponderado permite obtener la mejor segmentación de la imagen del cerebro. En primer lugar, evita que características con muy poca presencia en las imágenes tengan una importante incidencia en la determinación de las

clases. Por otro lado, el método conserva la ventaja del K-medias respecto al de mínima distancia ya que las clases obtenidas dependen totalmente de los prototipos, los cuales se seleccionan de la propia imagen.

4.2 Imágenes utilizadas

Se utilizaron diferentes bancos de imágenes. Para el primer tramo de la tesis que corresponde a la segmentación de los ventrículos laterales, se utilizaron imágenes del banco de imágenes de la Cátedra de Radiología y Neurología de la Harvard Medical School. En esta etapa se emplearon imágenes de RMN pesadas en T_2 de pacientes con probable diagnóstico de Alzheimer. Si bien las imágenes pesadas en T_2 presentan poco contraste entre la materia gris y la materia blanca, muestran sin embargo un buen contraste entre la materia gris y el LCR (líquido céfalo-raquídeo) permitiendo la mejor segmentación de los ventrículos.

Posteriormente para la etapa de la segmentación de texturas en niveles de gris, se utilizaron imágenes facilitadas por el Instituto de Investigaciones Neurológicas perteneciente a la Fundación para la Lucha contra las Enfermedades Neurológicas de la Infancia (FLENI). Para esta etapa era necesario contar con imágenes multispectrales, es decir pesadas en T_1 , T_2 e imágenes de densidad de protones PD, siendo las tres parte del vector de características utilizado para segmentación a través de la granulometría de grises. Todas las imágenes suministradas son de $256 \times 256 \times 192$ píxeles y de 256 niveles de gris.

En la última etapa, y con el fin de comparar los resultados de la clasificación obtenida a través de la segmentación propuesta en esta tesis respecto a imágenes clasificadas por expertos, se trabajó con los radiólogos del Instituto Radiológico de la ciudad de Mar del Plata.

Capítulo V

RESULTADOS

En este Capítulo se muestran los resultados obtenidos en las tres principales etapas del procesamiento: la segmentación de los ventrículos laterales, la extensión de la granulometría a grises y finalmente los resultados de la aplicación de la variante propuesta del algoritmo de K-medias.

5.1 Segmentación de los ventrículos laterales

Esta sección se inicia con los resultados que se obtuvieron aplicando las técnicas standard. Se muestra que éstas no son adecuadas para la segmentación de los ventrículos laterales.

Posteriormente se muestran los resultados obtenidos con las técnicas de Morfología Matemática propuestas para este trabajo.

5.1.1 Segmentación de los ventrículos laterales con técnicas standard

5.1.1.1 Técnicas de umbralamiento

Esta técnica no permitió una segmentación satisfactoria de los ventrículos laterales ya que las formas a segmentar presentan pixeles con niveles de gris coincidentes con los de algunos pixeles de la corteza e inclusive del cráneo y de las meninges. Por otro lado, para poder elegir un umbral óptimo las imágenes a segmentar deberían ser bimodales y presentar marcados valles, las imágenes de resonancia magnética de cerebro presentan histogramas que no llegan a ser bimodales.

La Figura 5-1 muestra imágenes umbraladas con el óptimo valor en cada caso. Se observa que la segmentación obtenida no es satisfactoria ya que aún con la elección del umbral óptimo no se logra separar los ventrículos laterales.

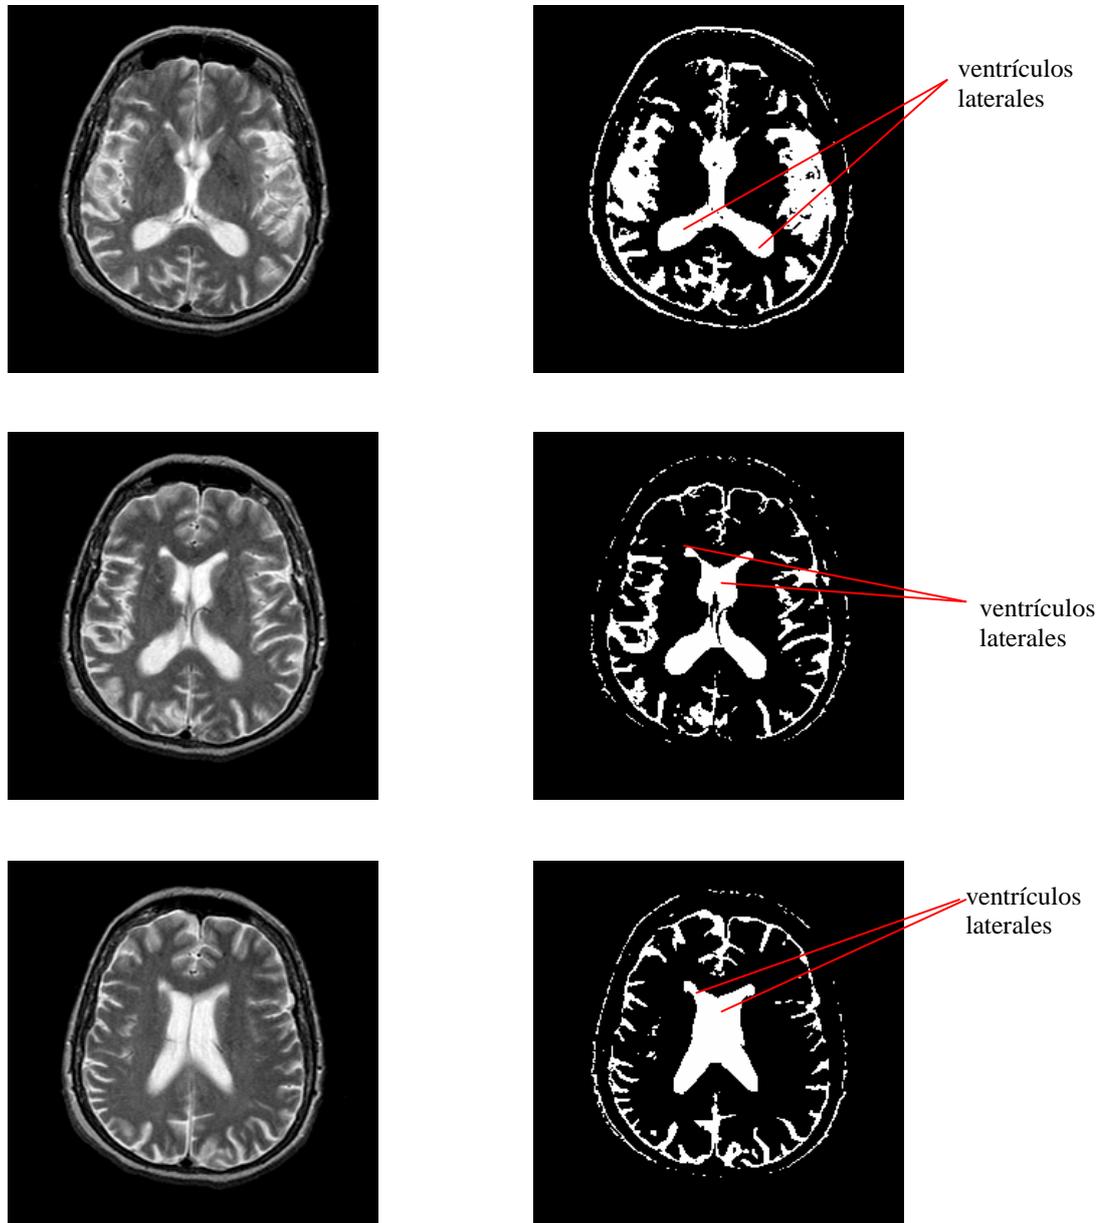


Fig.5-1 Diferentes cortes axiales de un cerebro. Imágenes de RMN T_2 y sus respectivas imágenes umbraladas con umbral óptimo.

A posteriori se intentó segmentar con doble umbral, es decir eligiendo una zona entre dos niveles de gris a fin de segmentar esa zona (ver Fig. 5-2).

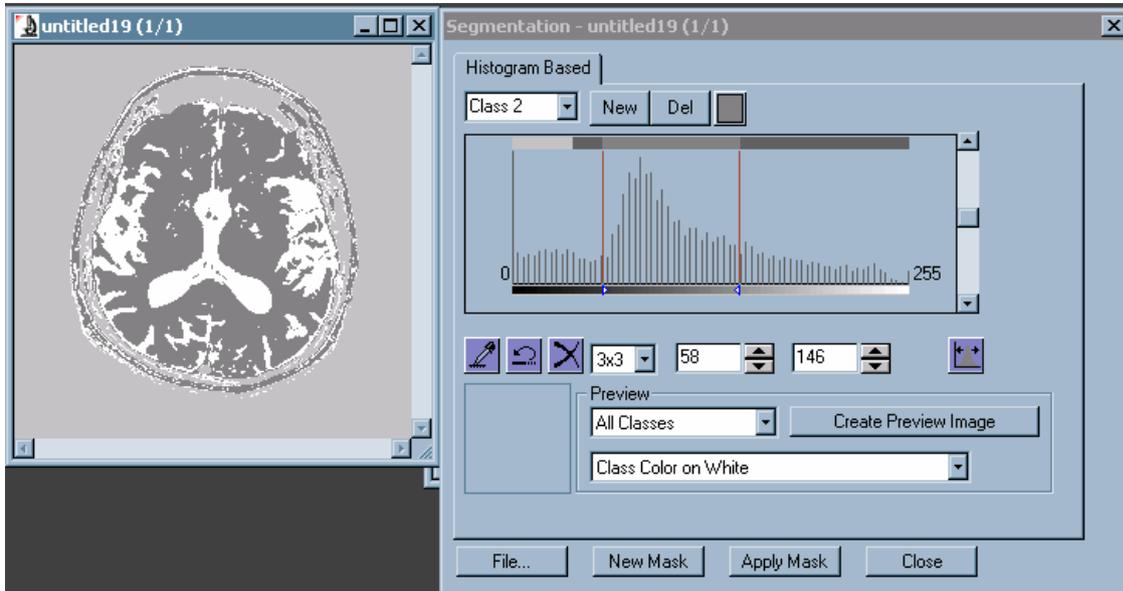


Fig.5-2 Imagen de RMN T₂ axial, elección del doble umbral.

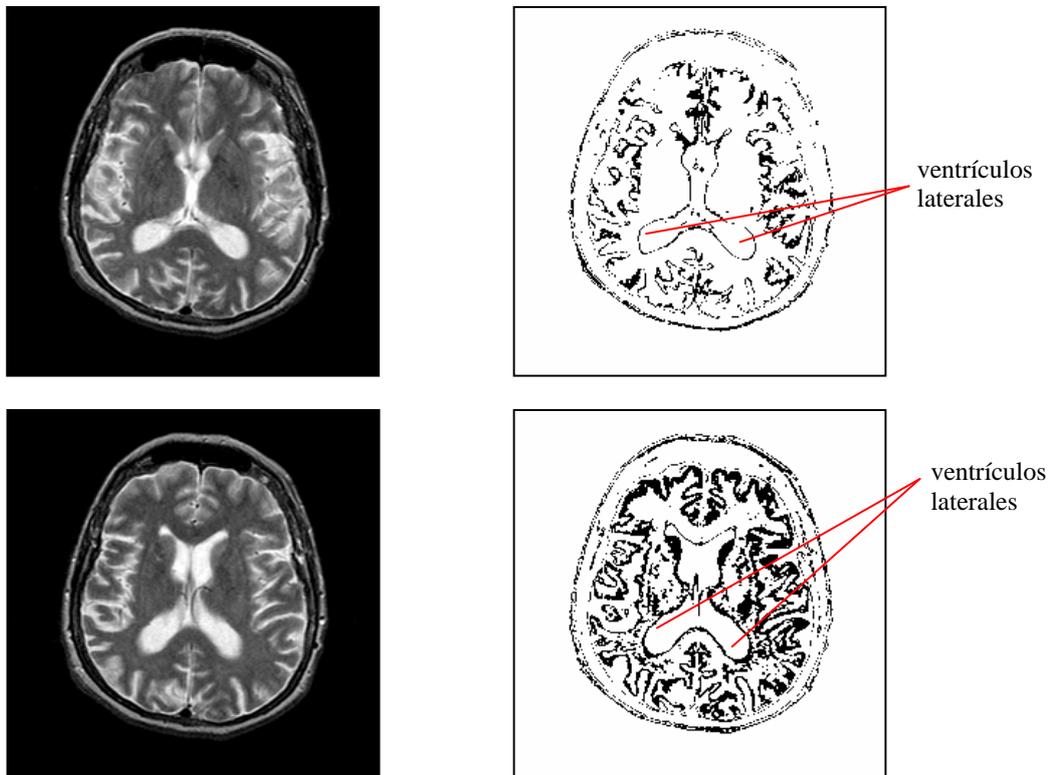


Fig.5-3 Imágenes de RMN T₂ axiales, y sus respectivas imágenes resultado mediante segmentación con doble umbral.

En la Figura 5-2 se observa cómo se eligen los umbrales óptimos en los valles del histograma. Como se puede observar en la Figura 5-3 la segmentación realizada con el doble umbral tampoco es satisfactoria. Esta técnica presenta el mismo inconveniente que el umbral standard ya que las formas a segmentar presentan pixeles con niveles de gris coincidentes con los de algunos pixeles de la corteza e inclusive del cráneo y de las meninges.

5.1.1.2 Técnicas de seguimiento de contornos

Se realizaron pruebas con esta técnica pero tampoco resultaron satisfactorias. El problema es que los pixeles del borde de los ventrículos no están siempre conectados. Esto significa que si bien debido a la textura, el ojo humano identifica claramente los bordes, los pixeles que lo conforman no tienen niveles de gris conexos, razón por la cual las técnicas de seguimiento automático de contorno o también conocidas como *autotrace* no funcionan. En la Figura 5-4 se observan los resultados de aplicar en diferentes cortes esta técnica.

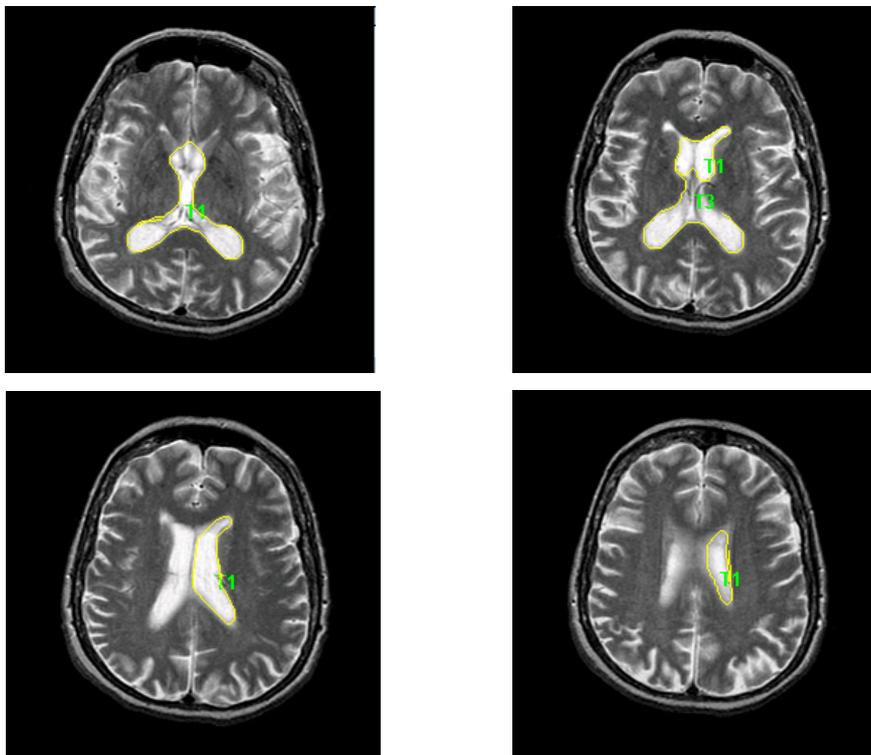


Fig.5-4 Imágenes de RMN T₂ cortes axiales segmentadas a través técnicas de seguimiento automático de contornos. Se observa en amarillo el perímetro segmentado con la técnica conocida como *autotrace*.

5.1.2 Segmentación de los ventrículos laterales utilizando Morfología Matemática

Finalmente se obtuvieron resultados satisfactorios en la segmentación de los ventrículos laterales utilizando técnicas de Morfología Matemática.

Se trabajó con imágenes pesadas en T_2 , ya que estas imágenes si bien presentan poco contraste entre la materia gris y la materia blanca, muestran sin embargo un buen contraste entre la materia gris y el LCR (líquido céfalo-raquídeo) permitiendo así la mejor segmentación de los ventrículos. Estas técnicas basadas en morfología matemática, al considerar a la imagen como un conjunto de píxeles, hacen innecesario el uso de rutinas adicionales para la extracción del cráneo, la grasa circundante y las meninges. Como se puede observar en los diferentes cortes de las imágenes de la Figura 5-5 la segmentación obtenida es muy superior a cualquiera de las obtenidas con las técnicas standard, ya que involucra una reconstrucción condicionada a la imagen original, asegurando de esta manera exactitud en los cálculos posteriores para la medición del aumento relativo del área ventricular (Ballarin, V. y Valentinuzzi, M., 2001). Por otro lado, los algoritmos de implementación de estos procesos morfológicos son veloces con respecto a cualquier otro algoritmo de segmentación tradicional ya que las operaciones básicas involucradas son de carácter lógico y no algebraico, lo que implica un menor número de cálculos (Ver Tabla 5-1). Además los valores incluidos en la tabla no tienen en cuenta los tiempos de intervención del experto en los algoritmos semiautomáticos como el de seguimiento de contornos.

Para evaluar la performance de los algoritmos de segmentación normalmente se calcula el número de píxeles clasificados erróneamente y se calcula un coeficiente conocido como *recognition rate* (tasa de reconocimiento) que permite evaluar la bondad de la clasificación en función de los píxeles clasificados correctamente. Para este caso particular, las técnicas standard no son apropiadas pues los porcentajes de píxeles erróneos superan el 100% y carece de sentido calcular el parámetro en cuestión (*recognition rate*).

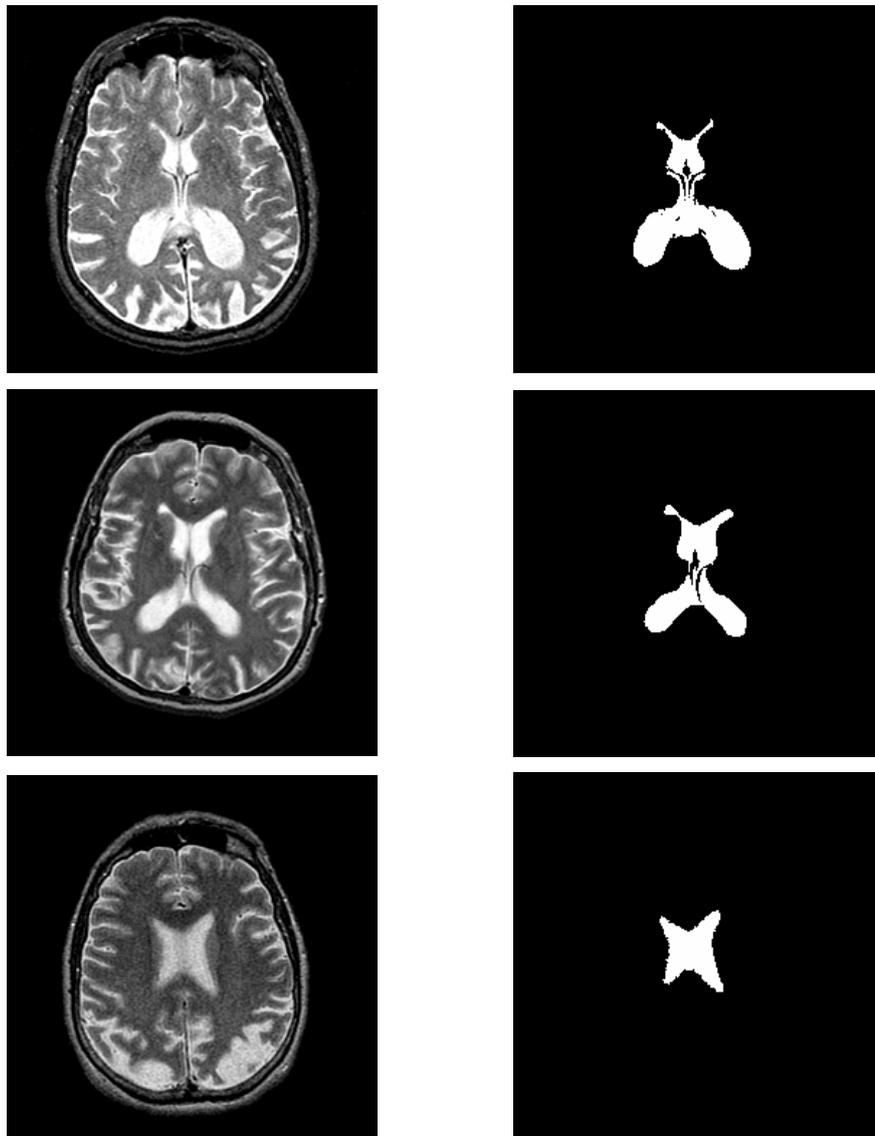


Fig.5-5 Imágenes de RMN T₂ cortes axiales, y sus respectivas imágenes resultado segmentadas mediante técnicas de morfología matemática.

Técnica empleada	Tiempo en seg. para 24 cortes	Tiempo en seg. para 192 cortes
<i>Umbralamiento standard</i>	2.76	26,98
<i>Doble umbralamiento</i>	7.23	67.84
<i>Seguimiento de contornos</i>	44.35	354.79
<i>Segmentación morfológica</i>	2.69	22.32

Tabla 5-1 Tiempos promedios medidos en segundos para cada volumen comprendido de 24 cortes horizontales de 256 x 256 pixeles cada uno.

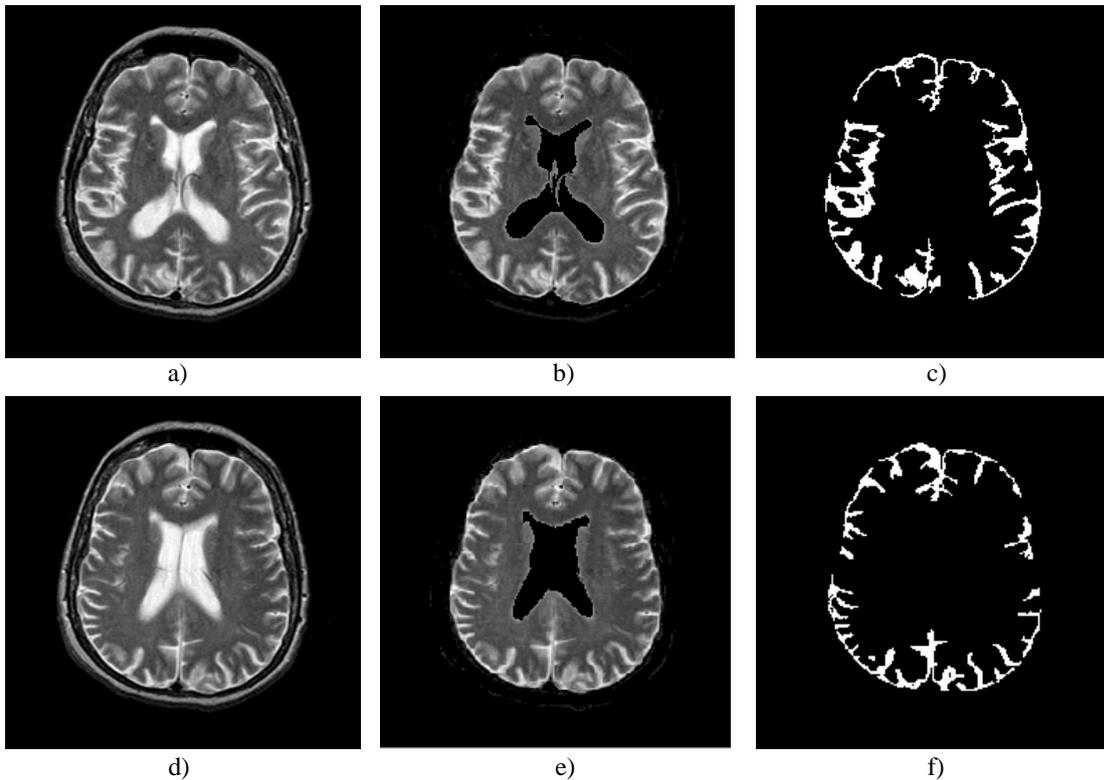


Fig.5-6 a) y d) Imágenes de RMN T₂ axiales originales; b) y e) imágenes parciales con el ventrículo segmentado y convertido al nivel de gris del fondo; c) y f) sus respectivas imágenes resultado de la segmentación de la corteza mediante técnicas de morfología matemática.

Una vez segmentados los ventrículos laterales con las técnicas morfológicas se intentó extender el uso de esta técnica para la clasificación también de la corteza cerebral sin éxito. Una vez clasificados los ventrículos se convirtieron dichos pixeles al nivel de gris del fondo de la imagen y se aplicaron nuevamente los algoritmos de apertura y dilatación condicionada pero con elementos estructurantes pequeños a fin de poder detectar la corteza.

Los resultados no fueron los deseados. Aún trabajando con los elementos estructurantes en forma de disco de un pixel de diámetro, el algoritmo no es capaz de separar la corteza cerebral del líquido cerebroespinal que lo rodea. Estos resultados pueden observarse en la Figura 5-6. Una técnica tan eficiente en la clasificación de los ventrículos quedó descartada entonces para la clasificación del resto de los tejidos.

5.2 Extensión de la Granulometría a niveles de gris

Al no funcionar la segmentación morfológica para separar la sustancia gris de la del líquido cefalo-raquídeo en la corteza cerebral y tener que utilizar una segmentación que involucre texturas, se planteó un nuevo problema: segmentar el cráneo y las meninges. Para que los algoritmos de texturas funcionen correctamente y no confundan al cráneo y las meninges con una cuarta textura o lo que es menos deseable como parte de una de las tres texturas a cuantificar, se debió buscar un algoritmo que permitiera separar previamente el cráneo y las meninges.

Esta sección se inicia con los resultados de la aplicación de las técnicas de *snakes* para la segmentación de contornos. A posteriori se muestran los resultados que se obtuvieron aplicando otros modelos para la clasificación de texturas basados en métodos geométricos, estadísticos y frecuenciales. Se muestra que los característicos definidos por estos enfoques no permiten una clasificación posterior adecuada.

Finalmente se muestran los resultados obtenidos con la técnica de Granulometría de Grises propuesta para este trabajo.

5.2.1 Extracción del cráneo y meninges mediante *snakes*

Se utilizaron las técnicas de segmentación mediante contornos activos (Snakes) que tienen una amplia aplicación en imágenes médicas para identificar estructuras anatómicas. Se aplicó una variante de la técnica paramétrica de *snakes* que introduce un nuevo modelo de fuerza externa llamado *flujo vectorial del gradiente* (campo GVF) que mejora los problemas asociados con la inicialización y la convergencia (Kass, M. et al., 1987). Las fuerzas internas están basadas en modelos físicos de elasticidad y rigidez, y por ser de característica dinámica varían a medida que el contorno de la curva se va modificando. Las fuerzas externas, en cambio, son estáticas ya que sólo dependen de la topología de la imagen y se calculan mediante el gradiente negativo de una función de potencial, las cuales atraen a la curva a las proximidades del borde, en el sentido de minimizar su energía. El equilibrio entre las fuerzas internas y externas permiten ceñir la

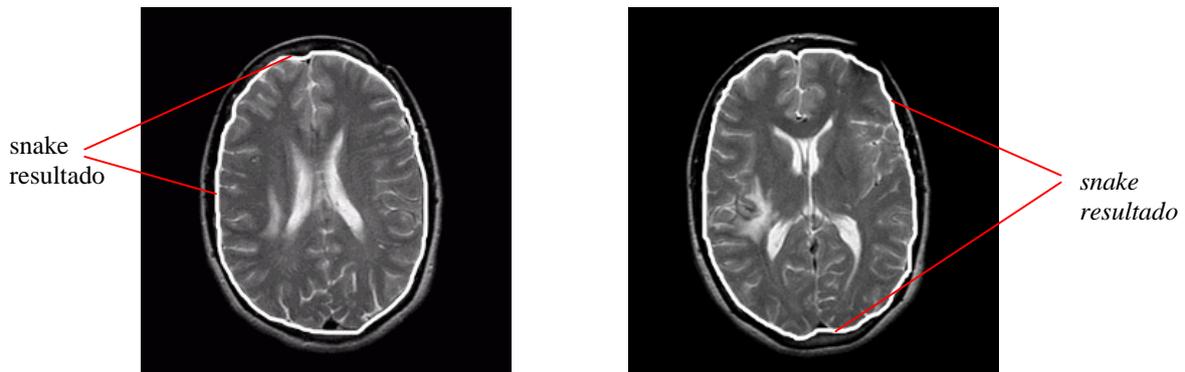


Fig.5-7 Diferentes imágenes de RMN T₂ axiales donde el cerebro es segmentado del cráneo y las meninges utilizando snakes.

curva alrededor del borde del objeto de estudio en la imagen, inclusive en aquellas zonas en donde la nitidez del mismo se pierda o no quede claramente definido.

Esta técnica permitió segmentar el cerebro del cráneo y de las meninges con muy buenos resultados como se puede observar en los ejemplos de la Figura 5-7 (Blotta, E., Moler E. y Ballarin, V., 2001). Aún en los casos de imágenes en donde falta nitidez el método sigue siendo eficiente.

5.2.2 Matriz Co-ocurrencia de niveles de gris

El enfoque de la dependencia espacial de los niveles de gris caracteriza a la textura a través de la co-ocurrencia de sus niveles de gris. Al definir la matriz de co-ocurrencia, como la matriz de frecuencia relativas, conformada con elementos que representan la cantidad de veces que una combinación dada de niveles de gris se repiten en una imagen, deben considerarse la distancia de los pixels a procesar, y también la dirección en la cual se analiza la imagen. Esto transforma a los algoritmos en terriblemente lentos, dado que las imágenes poseen 256 niveles de gris, la matriz de frecuencias relativas tiene una dimensión de 65636. Además luego de calcular dichas matrices se deben calcular diversos valores característicos que se utilizan como dato de entrada en algoritmos de Reconocimiento de Patrones.

Si bien el método de las matrices de co-ocurrencia caracteriza las interrelaciones espaciales de los niveles de gris en patrones de textura, éste no captura aspectos de la

forma de las primitivas de nivel de gris. Este método será más eficiente con imágenes que posean dependencia espacial de los niveles de gris y en las que la información que la textura aporta es sustancialmente alta. No es el caso de esta tesis. Las imágenes resultado de la clasificación realizada a partir de características obtenidos de las matrices de co-ocurrencia se pueden observar en la Figura 5-8.

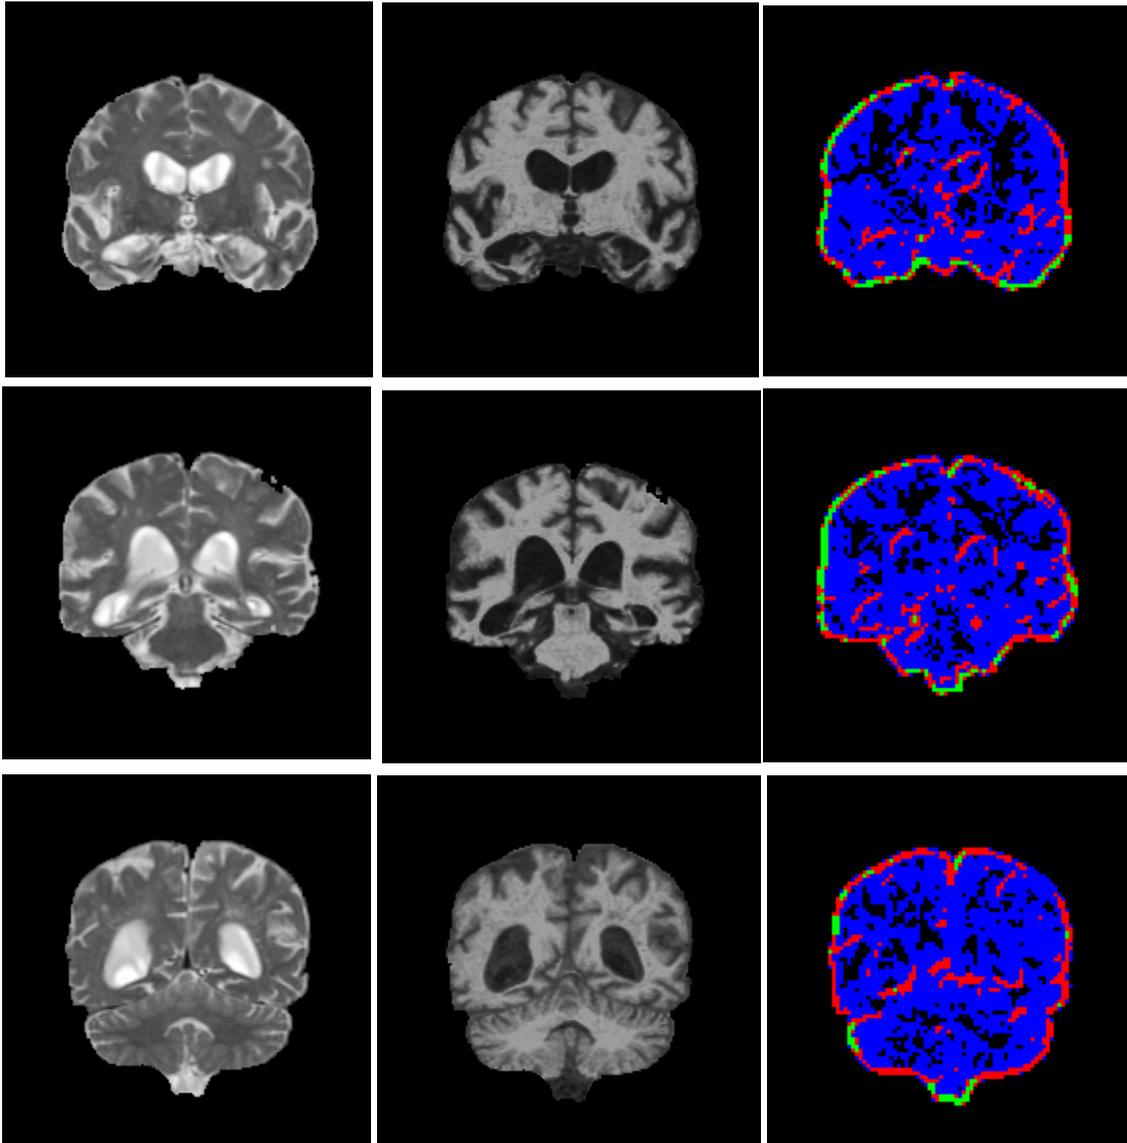


Fig.5-8 Imágenes coronales de RMN T_2 y T_1 , y sus respectivas imágenes resultado de la clasificación realizada a partir de características obtenidos de las matrices de co-ocurrencia.

Más allá de que la clasificación no es para nada satisfactoria, los tiempos de proceso tan altos, del orden de los 54 minutos, lo hacen un método absolutamente ineficiente (Ver tabla 5-3).

5.2.3 Métodos Frecuenciales

Los característicos de este enfoque se obtuvieron en términos del espectro de Fourier de la imagen. El grado de rugosidad o suavidad de una textura resulta proporcional al período espacial. Bajo este enfoque, se utilizó el valor de entropía para caracterizar las texturas presentes. Si una textura es espacialmente periódica o direccional, su espectro de potencia tiende a tener picos correspondientes a la distribución espacial de frecuencias. Por lo tanto estos picos aportan información relevante sobre la imagen y pueden caracterizarse por este parámetro. A partir de lo anterior se definió el vector de características de entropía formado por cada valor de entropía en la región. Este vector se utilizó como dato de entrada al aplicar un algoritmo de clasificación para separar las diferentes texturas de las imágenes.

Como se pueden apreciar en la Figura 5-9 y en Tabla 5-3, estos algoritmos resultaron lentos y la clasificación obtenida a partir de ellos, si bien es mejor que la obtenida con los parámetros de co-ocurrencia, no es satisfactoria. Como se puede observar en los ejemplos presentados, los parámetros frecuenciales clasifican con bastante error el L.C.R pero no pueden discernir entre la sustancia gris y la sustancia blanca. Esto se debe a que no existe periodicidad alguna en las texturas presentes en las imágenes de RMN.

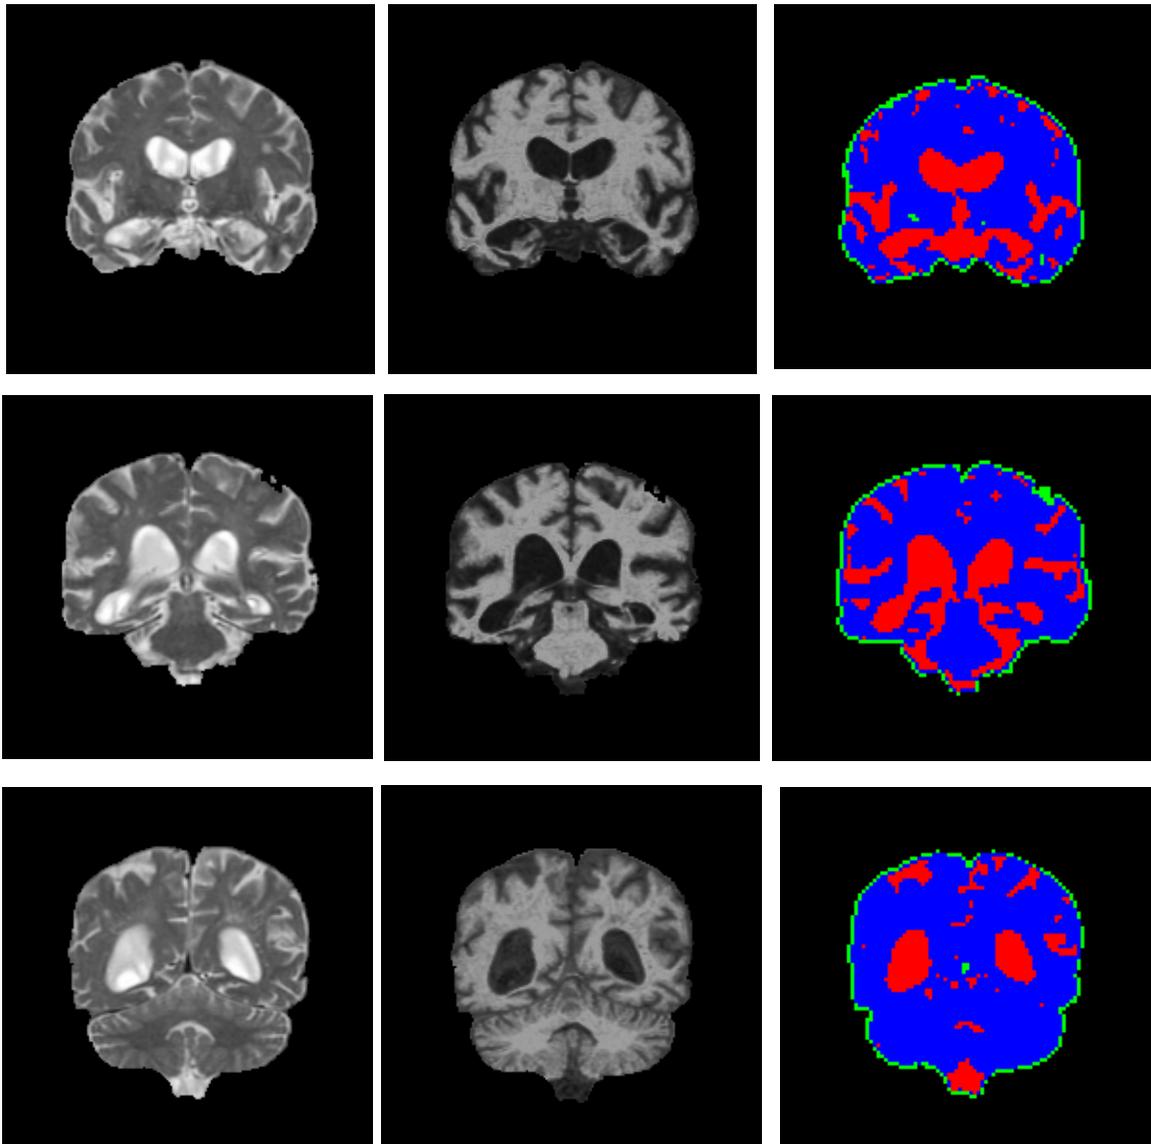


Fig.5-9 Imágenes coronales de RMN T₂ y T₁, y sus respectivas imágenes resultado de la clasificación realizada a partir de características obtenidos de los valores de la entropía frecuencial de las imágenes.

5.2.4 Granulometría en niveles de gris

La idea central de esta tesis es segmentar regiones por textura tomando para cada pixel un vector de características obtenidas a través de operaciones morfológicas, que indican una medida de textura presente en dicho punto. Las características asociadas a cada pixel se obtuvieron de aplicar el Criterio de Tamaños de Aperturas Sucesivas sobre una

máscara centrada en un pixel. Luego se obtuvo una Función de Distribución de Tamaños asociada a cada máscara. Derivando esta función de distribución se obtuvo una función de densidad, con la cual se puede calcular estadísticos como el valor medio y la varianza que se agregan a las tres imágenes originales (T_1 , T_2 y P_d) formando parte del vector de características. Este vector de características se utilizó como variable de entrada para los algoritmos de clasificación.

Dado que no se tiene un conocimiento previo de las diferentes regiones, los algoritmos seleccionados fueron de clasificación no supervisada. Dado que tampoco se tiene conocimiento de las funciones de densidad de probabilidad de los niveles de gris, para agrupar las muestras en grupos se utilizaron métodos determinísticos, agrupando puntos en el espacio de mediciones de acuerdo a la distancia euclídea entre ellos.

Las imágenes que se procesaron fueron matrices de $256 \times 256 \times 192$. Los elementos de las matrices son los niveles de gris de los pixeles. En una primera etapa el vector de características $X = (x_1, x_2, \dots, x_3)$ se conformó con las imágenes compuestas por los valores de los momentos estadísticos obtenidos a través de la función distribución de tamaños. Cada coordenada del vector X representa un punto (o patrón) en el hiperplano de dimensión tres. Los cuatro clusters o grupos, representan las tres texturas a segmentar más el fondo. Todos los pixeles de las imágenes, donde X es su vector de características asociado, se asignó a una clase, obteniéndose de esta forma la imagen segmentada.

Las imágenes así clasificadas se pueden observar en la Figura 5-10 y sus respectivos tiempos de procesamiento en la Tabla 5-3. Finalmente se contrastaron los tres métodos estudiados: matriz de co-ocurrencia, frecuencial y granulometría en grises, con la clasificación hecha por un experto. Se calculó el porcentaje de pixeles correctamente clasificados con los tres métodos de extracción de características, utilizando en todos los casos el mismo algoritmo de clasificación, a fin de poder evaluar el método de extracción de los características solamente.

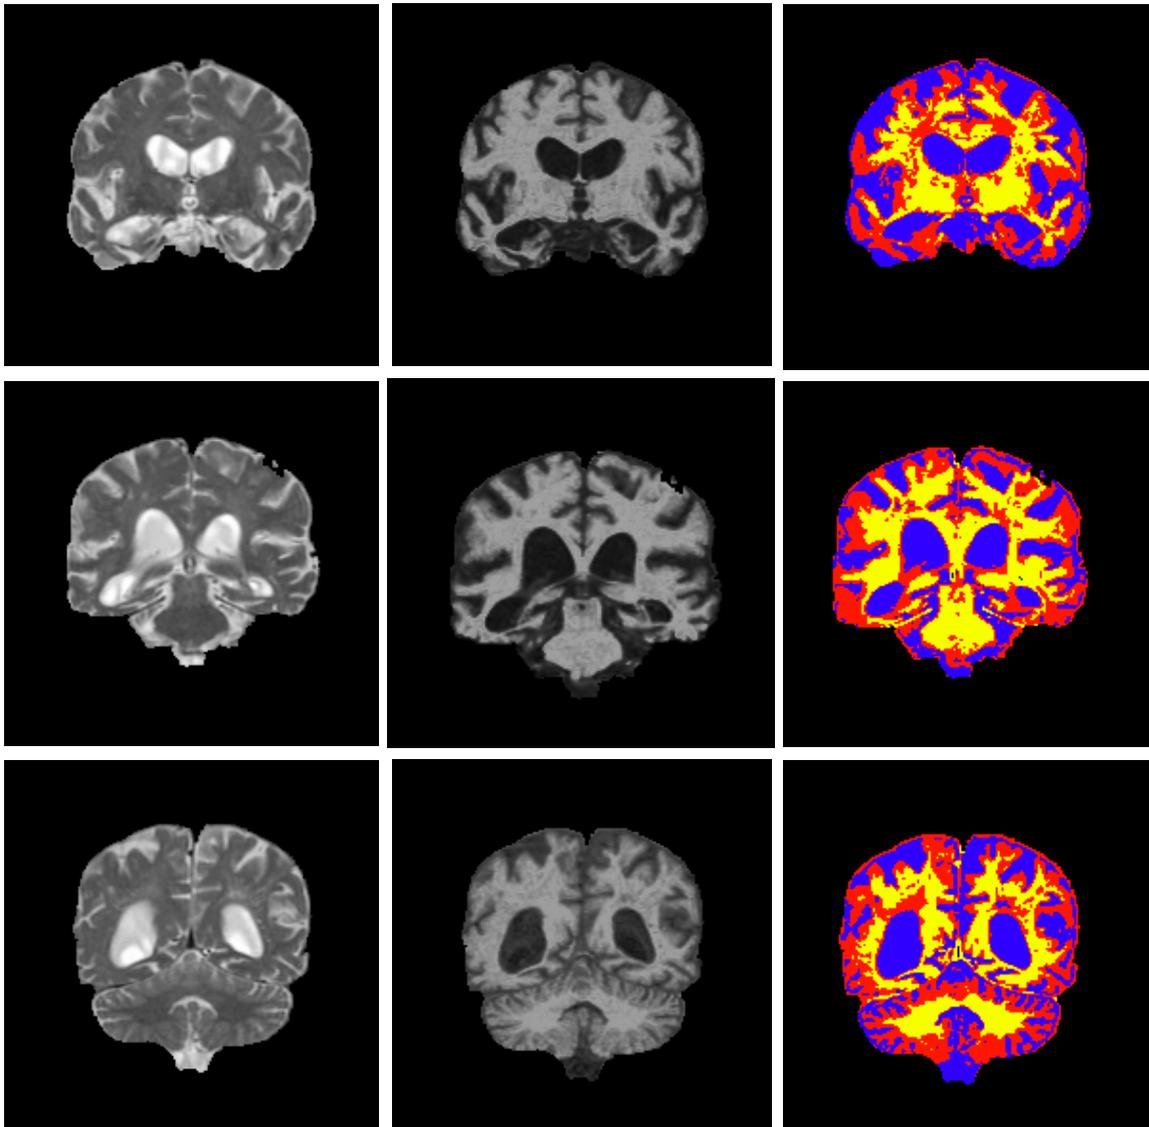


Fig.5-10 Imágenes coronales de RMN T₂ y T₁, y sus respectivas imágenes resultado de la clasificación realizada a partir de características obtenidos a través de granulometría de grises. Se indican en color azul los pixeles clasificados como LCR, en color rojo aquellos clasificados como sustancia gris y en color amarillo los pixeles clasificados como sustancia blanca.

clases	Método de extracción de características			BRAINS®
	matriz de co-ocurrencia	Fourier	granulometría	
<i>líquido cefaloraquídeo</i>	36.08 %	79.13 %	93.19 %	84.99%
<i>sustancia gris</i>	14.21%	16.39 %	88.55 %	90.01%
<i>sustancia blanca</i>	44.49%	48.00 %	83.25 %	93.51%

Tabla 5-2 Las primeras tres columnas indican el porcentaje de píxeles clasificados correctamente por los diferentes métodos de extracción de características con respecto a la clasificación realizada por los expertos, cuarta columna porcentajes de píxeles correctamente clasificados por el software BRAINS (MH-CRC, Iowa).

Como se puede observar en la Tabla 5-2, el porcentaje de píxeles correctamente clasificados (también conocido como *recognition rate*) es muy bueno en la segmentación del líquido cefaloraquídeo pero no los es tanto en la separación de la sustancia gris de la blanca. Esto todo si se lo compara con los resultados facilitados por el Instituto Fleni clasificados a través del software denominado BRAINS suministrado por el Mental Health Clinical Research Center de la Universidad de Iowa.

En una segunda etapa, y con el fin de mejorar estos resultados, se incorporaron las imágenes originales como características adicionales a los momentos estadísticos. Las imágenes que fueron procesadas en esta segunda etapa siguen siendo matrices iguales de 256 x 256 x 192. El vector de características, para esta segunda etapa, $X = (x_1, x_2, \dots, x_6)$ se conformó por los niveles de gris de las imágenes T_1 , T_2 y P_d respectivamente, más las imágenes compuestas por los valores de los momentos. Cada coordenada del vector X representó para esta nueva propuesta de segmentación, un punto (o patrón) en el hiperplano de dimensión seis. Nuevamente los cuatro clusters o grupos, representan las tres texturas a segmentar más el fondo. Todos los píxeles de las imágenes, donde X es su vector de características asociado, se asignó a una clase, obteniéndose de esta forma la imagen segmentada.

Como se puede observar en las imágenes resultado de la Figura 5-11 la clasificación de las sustancias gris y blanca mejora sensiblemente. Esto es confirmado al calcular nuevamente el porcentaje de píxeles correctamente clasificados.

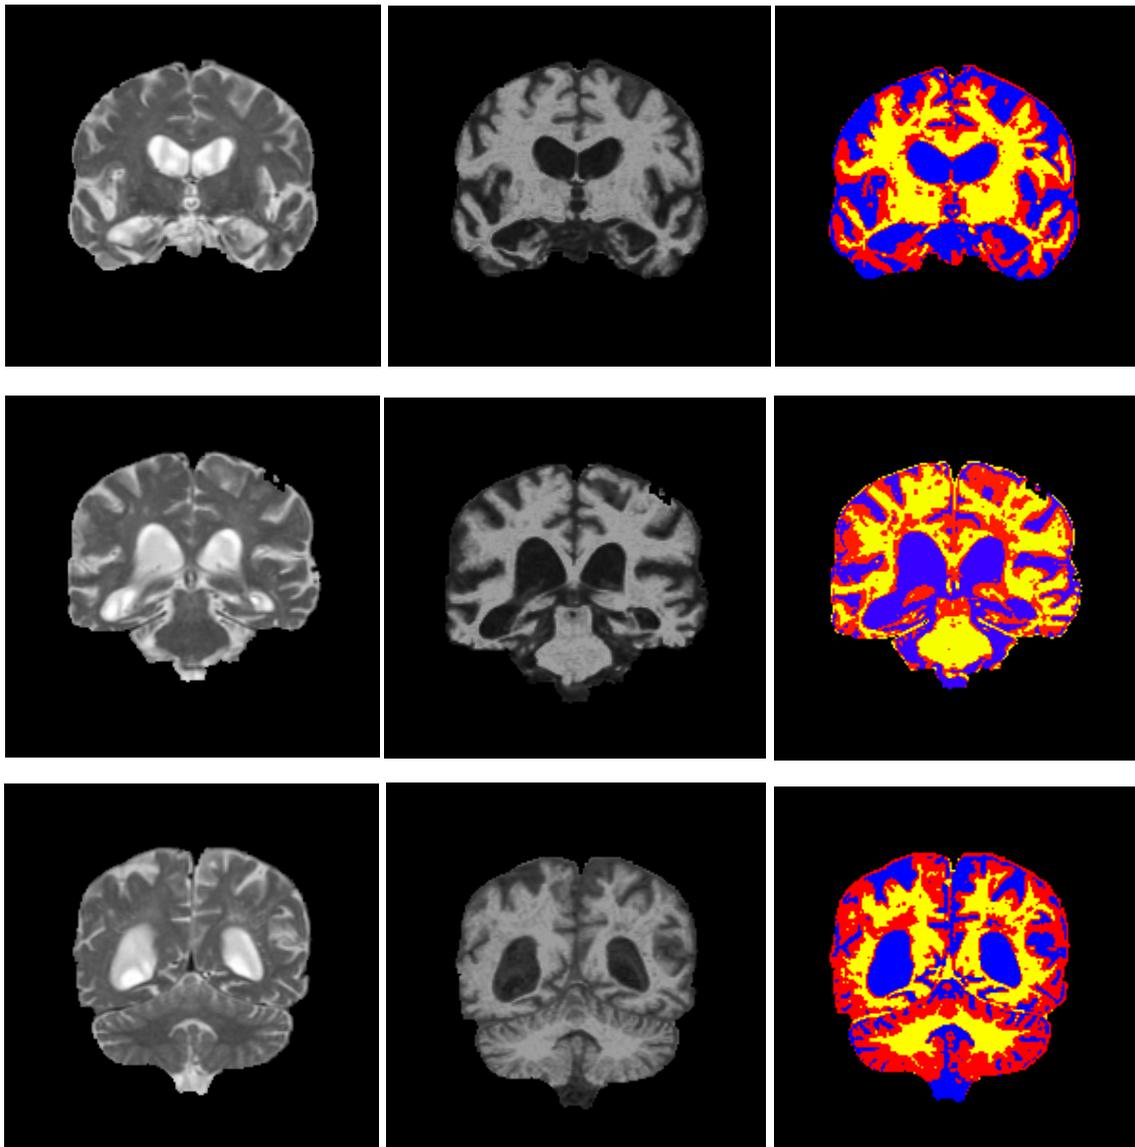


Fig.5-11 Imágenes coronales de RMN T_2 y T_1 , y sus respectivas imágenes resultado de la clasificación realizada tomando como característicos las imágenes compuestas por los valores de los momentos obtenidos a partir de la granulometría de grises más las imágenes T_1 , T_2 y Pd. Se indican en color azul los píxeles clasificados como LCR, en color rojo aquellos clasificados como sustancia gris y en color amarillo los píxeles clasificados como sustancia blanca.

característicos	Tiempo en seg.
<i>matriz de co-ocurrencia</i>	193670,42
<i>transformada de Fourier</i>	143916,10
<i>granulometría con 3 momentos</i>	316,84
<i>granulometría con 3 momentos + 3 imágenes</i>	6338,96

Tabla 5-3 Tiempos promedios medidos en segundos para cada volumen comprendido por 192 cortes horizontales de 256 x 256 pixeles cada uno.

Clases	característicos		
	T_1+T_2+Pd	momentos	momentos + T_1+T_2+Pd
<i>Líquido cefaloraquídeo</i>	79.13 %	91.19 %	93.89 %
<i>sustancia gris</i>	86.48 %	87.18 %	89.22%
<i>sustancia blanca</i>	74.91 %	89.77 %	92.84 %

Tabla 5-4 Porcentaje de pixeles clasificados correctamente por los diferentes característicos con respecto a la clasificación realizada por BRAINS.

En la Tabla 5-3 se comparan finalmente los tiempos de extracción de los diferentes característicos mientras que en la Tabla 5-4 se comparan los porcentajes de pixeles correctamente clasificados (recognition rate). Con esta nueva propuesta de complementar los momentos estadísticos con las imágenes pesadas en T_1 , en T_2 y PD la clasificación de las sustancias gris y blanca mejora. Se incorpora a la tabla, a fin de completar la comparación del método propuesto, también los valores para una segmentación tradicional realizada sólo con las tres imágenes T_1 , en T_2 y PD. Todos estos valores fueron calculados respecto a la clasificación realizada a través de BRAINS.

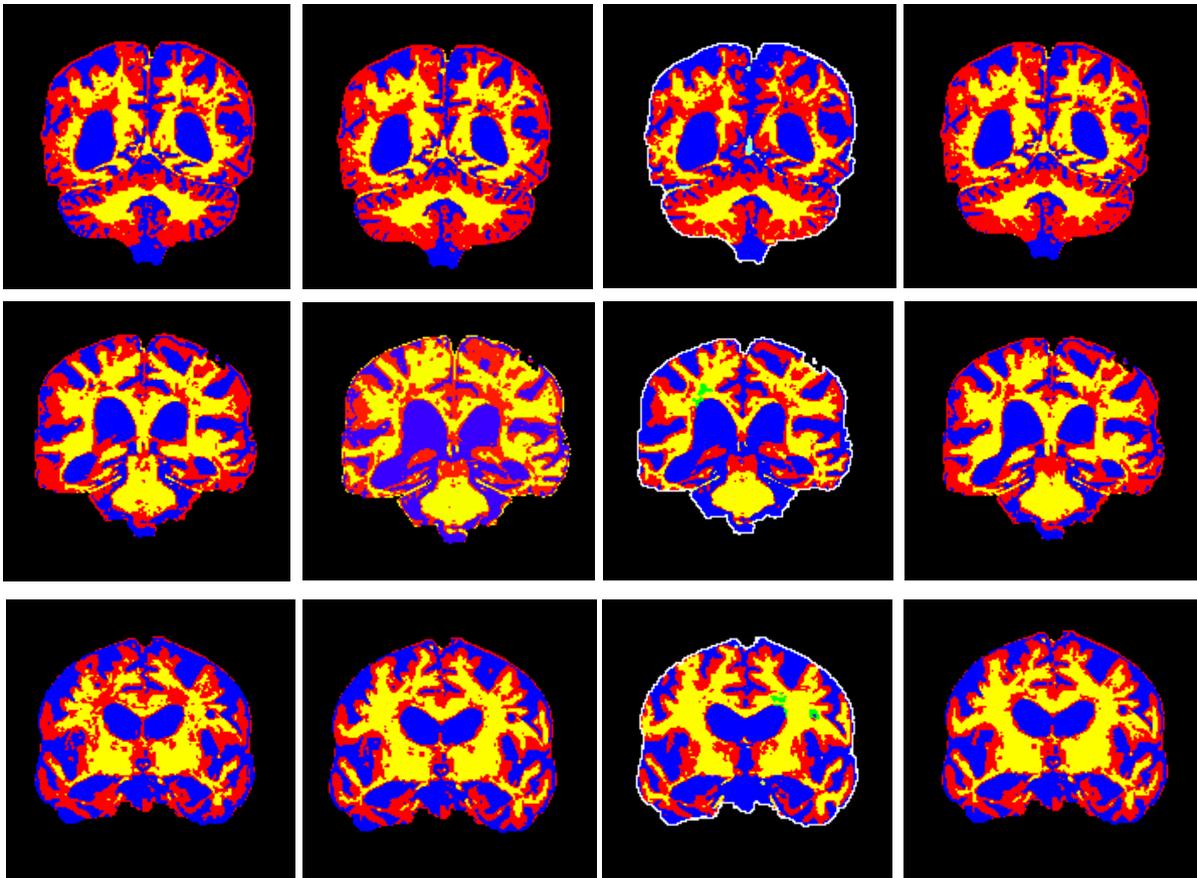


Fig.5-12 Imágenes de RMN coronales resultado de diferentes clasificaciones. Primera columna clasificación realizada utilizando como característicos sólo las imágenes compuestas por los valores de los momentos obtenidos a partir de la granulometría de grises, segunda columna imágenes resultado de la clasificación realizada tomando como característicos las imágenes de los momentos más las imágenes T1, T2 y Pd, tercera columna imágenes clasificadas con el software BRAINS (MH-CRC, Iowa) y cuarta columna clasificación realizada manualmente por los expertos. Se indican en color azul los pixeles clasificados como LCR, en color rojo aquellos clasificados como sustancia gris y en color amarillo los pixeles clasificados como sustancia blanca.

Estos resultados más las imágenes clasificadas por BRAINS fueron analizados por los expertos comprobando que la segmentación del LCR realizada a través de la granulometría de grises era visualmente más cercana a la realidad. Entonces se decidió que los expertos realizaran una segmentación manual de algunas imágenes testigo para posteriormente escanearlas y poder cuantificar nuevamente los volúmenes. A partir de esas

imágenes se recalcularon los porcentajes nuevamente. Los resultados son aún mejores como se puede observar en la Tabla 5-5 a la que se le incorpora, a fin de completar la comparación del método propuesto, los resultados de la segmentación realizada con el software BRAINS respecto a los expertos.

Observando los valores de la nueva tabla se confirma lo que se puede anticipar en las imágenes segmentadas (Ver Figura 5-12). La clasificación realizada a través de BRAINS es exagerada en la clase LCR en detrimento de las otras sustancias. Por otro lado utilizando sólo los momentos granulométricos como característicos, si bien la segmentación del LCR es bastante buena, la sustancia gris se clasifica en exceso en desmedro de la sustancia blanca.

5.3 Algoritmo de K-medias Ponderado

Para este trabajo se desarrolló una nueva variante del algoritmo K-medias, en el cual se tiene en cuenta para el cálculo de los centros de cluster, la cantidad de veces que aparece un determinado patrón X en las imágenes. Es decir, se utiliza una media ponderada en el cálculo de los centros.

clases	característicos			BRAINS®
	T_1+T_2+Pd	momentos	momentos + T_1+T_2+Pd	
<i>líquido cefaloraquídeo</i>	84.01 %	93.19 %	98.77 %	84.99%
<i>sustancia gris</i>	87.66 %	88.55 %	98.09 %	90.01%
<i>sustancia blanca</i>	71.66 %	83.25 %	97.52 %	93.51%

Tabla 5-5 Porcentaje de pixeles clasificados correctamente por los diferentes característicos con respecto a la clasificación realizada por los expertos.

Se realizaron pruebas con distintos algoritmos standard en varias imágenes. Los resultados evidencian que el algoritmo K-medias ponderado permite obtener la mejor segmentación de la imagen del cerebro. En primer lugar, porque evita que características con muy poca presencia en las imágenes, tengan una importante incidencia en la determinación de las clases. Además, el método conserva la ventaja del K-medias respecto al de mínima distancia ya que las clases obtenidas dependen totalmente de los prototipos, los cuales se seleccionan de la propia imagen.

Esto se ve claramente en la Tabla 5-8 donde se compara la performance de los algoritmos Mínima Distancia, Maximin, K-medias clásico y el algoritmo propuesto, K-medias ponderado. Además se calcularon las matrices confusión para los tres algoritmos utilizados. Estas matrices permiten evaluar el número de pixeles clasificados correctamente así como los asignados a una clase erróneamente. De esta manera, se comparan los algoritmos con más detalle que analizando sólo la tasa de reconocimiento (recognition rate).

A continuación en la Figura 5-13 se observan las imágenes resultado. Los característicos utilizados fueron siempre los mismos a fin de evaluar la performance del algoritmo independientemente de ellos.

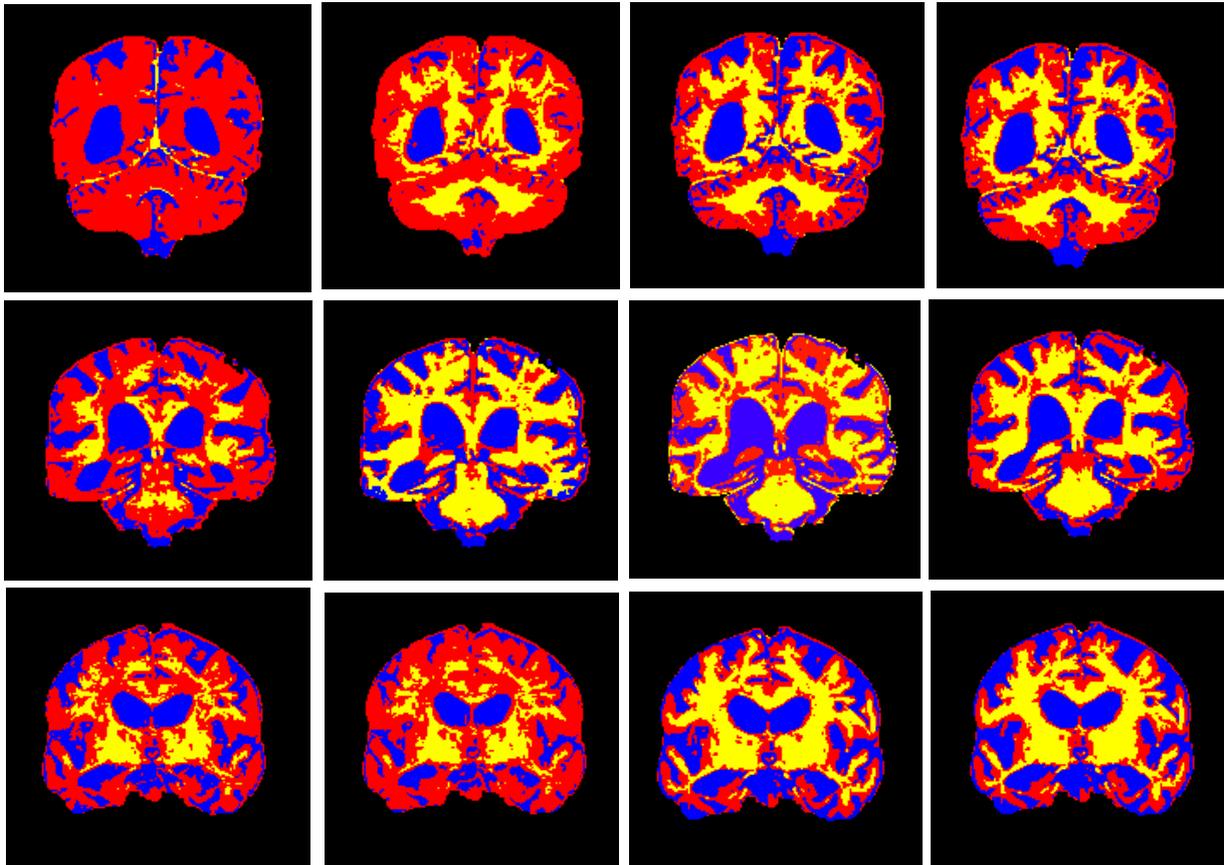


Fig.5-13 Imágenes de RMN coronales resultado de la clasificación realizada a partir de los tres diferentes algoritmos utilizados utilizando los mismos características (granulometría de grises). Primera columna algoritmos Maximin, segunda columna algoritmo Mínima Distancia, tercera columna algoritmo K-medias ponderado y cuarta columna clasificación realizada manualmente por los expertos. Se indican en color azul los pixeles clasificados como LCR, en color rojo aquellos clasificados como sustancia gris y en color amarillo los pixeles clasificados como sustancia blanca.

Algoritmo Maximin	<i>Nº de pixeles clasificados como clase LCR y ...</i>	<i>Nº de pixeles clasificados como clase MB y ...</i>	<i>Nº de pixeles clasificados como clase MG y ...</i>
<i>... que debieron ser clase LCR</i>	92.13 %	1.01 %	7.96 %
<i>... que debieron ser clase MB</i>	0.00 %	89.10 %	18.82 %
<i>... que debieron ser clase MG</i>	0.00 %	1.01 %	73.22 %

Tabla 5-6 Matriz Confusión para el algoritmo Maximin: distribución del porcentaje de pixeles clasificados evaluados con respecto a la clasificación realizada por los expertos.

En la Tabla 5-6 se observa la matriz confusión calculada para el algoritmo Maximin. A través de esta tabla se puede ver claramente que si bien el porcentaje de pixeles correctamente clasificados de LCR no es tan bajo (92.13%) hay un altísimo error en la clasificación de la sustancia gris que invade en casi un 8% parte del área que debiera haber sido clasificada como LCR y en un 18.82% el área que corresponde a la materia blanca (MB). El número de pixeles clasificados como materia blanca es de 89.10% en defecto. Por otro lado el algoritmo es poco independiente respecto a la elección de los puntos iniciales. Esto se puede apreciar en la Figura 5-13 donde una mala elección de parte del experto de los puntos iniciales da resultados realmente malos que salen fuera del promedio calculado en la tabla como *recognition rate*.

En la siguiente tabla se observa la matriz confusión calculada para el algoritmo Mindist. En este algoritmo los puntos de comienzo son elegidos al azar, debido a esto el algoritmo no es suficientemente estable, pasando de clasificaciones aceptables a algunas bastante malas como se puede observar en los ejemplos de la Figura 5-13. Por otro lado los porcentajes calculados en promedio para 10 imágenes no son nada buenos como se observa en su matriz confusión. El LCR es clasificado correctamente sólo en un 60.55% en defecto. La clasificación de materia blanca es pobre, apenas un 83%, y la materia gris (MG) en general está sobreclasificada. Sólo un 46.30% de los pixeles clasificados como MG son correctos mientras que un 37.06% debieran haber sido clasificados como LCR y cerca de un 5% como MB.

Algoritmo Mindist	<i>Nº de pixeles clasificados como clase LCR y ...</i>	<i>Nº de pixeles clasificados como clase MB y ...</i>	<i>Nº de pixeles clasificados como clase MG y ...</i>
<i>... que debieron ser clase LCR</i>	60.55 %	5.00 %	37.06 %
<i>... que debieron ser clase MB</i>	0.00 %	83.24 %	4.73 %
<i>... que debieron ser clase MG</i>	0.00 %	7.47 %	46.3 %

Tabla 5-7 Matriz Confusión para el algoritmo Mindist: distribución del porcentaje de pixeles clasificados evaluados con respecto a la clasificación realizada por los expertos.

Algoritmo K-medias	<i>Nº de pixeles clasificados como clase LCR y ...</i>	<i>Nº de pixeles clasificados como clase MB y ...</i>	<i>Nº de pixeles clasificados como clase MG y ...</i>
<i>... que debieron ser clase LCR</i>	98.77 %	0.00 %	0.00 %
<i>... que debieron ser clase MB</i>	0.00 %	97.52 %	1.91 %
<i>... que debieron ser clase MG</i>	0.00 %	2.48 %	98.09 %

Tabla 5-8 Matriz Confusión para el algoritmo K-medias ponderado: distribución del porcentaje de pixeles clasificados evaluados con respecto a la clasificación realizada por los expertos.

Por último en la Tabla 5-8 se calculó la matriz confusión para el algoritmo propuesto, K-medias ponderado. Los porcentajes de pixeles clasificados correctamente son altos, superiores al 97%. Se observa un 2.48% de pixeles clasificados como MB que debieron ser MG y casi un 2% de pixeles clasificados como MG que debieron ser MB. Por otro lado el algoritmo es realmente estable a los puntos iniciales. Se realizaron pruebas variando estos valores y las imágenes resultado prácticamente varían en menos de 0.02% en los cálculos de la matriz confusión. Además la variación propuesta del algoritmo tradicional de K-medias, tiene en cuenta para el cálculo de los centros de cluster, la cantidad de veces que aparece un determinado patrón X en las imágenes. Es decir, se utiliza una media ponderada en el cálculo de los centros. De esta manera el número de cálculos disminuye notablemente y por ende los tiempos, mejorando así el principal inconveniente que tenía el algoritmo tradicional y conservando su estabilidad.

clases	Algoritmo de Clasificación		
	Mínima Distancia	Maximin	K-medias ponderado
<i>líquido cefaloraquídeo</i>	60.55 %	92.13 %	98.77 %
<i>sustancia gris</i>	50.00 %	89.10 %	97.52 %
<i>Sustancia blanca</i>	46.33 %	81.22 %	98.09 %

Tabla 5-9 Porcentaje de pixeles clasificados correctamente por los diferentes algoritmos evaluados con respecto a la clasificación realizada por los expertos.

Por último, a manera de resumen, se presenta la Tabla 5-9 con los porcentajes de pixeles correctamente clasificados por los tres algoritmos. Todos los cálculos se realizaron utilizando como vector de característicos de entrada las tres imágenes T_1 , T_2 y P_d respectivamente, más las imágenes compuestas por los valores de los momentos granulométricos.

Capítulo VI

DISCUSIÓN

Históricamente el rol de las imágenes en la demencia ha sido excluir causas potencialmente reversibles. Esto sigue siendo importante, aunque la demencia debido a causas estructurales es baja (Alexander, E., Wagner E., et al. 1995). Las causas estructurales más frecuentes son tumores cerebrales, hidrocefalia y hematoma subdural. La mayoría de estas patologías son detectadas por rutina con el uso de Tomografía Computada o la RMN. Cuando un paciente se presenta con deterioro cognitivo, la hidrocefalia a presión normal (HPN) es frecuentemente considerada en el diagnóstico. Existía una tendencia a sobrediagnosticar HPN dado que las características típicas son la presencia de agrandamiento ventricular sin atrofia cortical junto a prominentes cambios en la sustancia blanca periventricular. Sin embargo en la Enfermedad de Alzheimer (EA), además del agrandamiento ventricular, aparece la atrofia cortical difusa y en el área del hipocampo atrofia desproporcionada con respecto al agrandamiento ventricular (Holodny, A., Waxman, R., George, A. Et al, 1998).

El mayor interés de la neuroradiología para el diagnóstico de la EA ha sido la evaluación de la atrofia del cerebro. La atrofia cortical, reducción del peso cerebral y agrandamiento ventricular son las características más prominentes en los pacientes que padecen la EA. Sin embargo existe una notable superposición en los resultados de la medición de la atrofia cuando se comparan con sujetos normales controlados por edad. Esto se debe a que el envejecimiento normal también trae aparejado una reducción en el peso cerebral y un incremento en el volumen ventricular (Coffey, C., Wilkinson, W. and Parashos, I. 1992). Es debido a esta superposición con el envejecimiento normal lo que lleva a un diagnóstico de envejecimiento normal cuando en realidad se trata de un estadio temprano de la EA.

El único método de análisis de imágenes que se practica en la clínica de rutina es la evaluación visual que consiste en la opinión del radiólogo o experto de si los surcos cerebrales y el tamaño ventricular están fuera del rango de la normalidad (Manes, F.,2000). La evaluación visual de la atrofia cerebral es limitada. *El Multicentre Consortium to Establish a Registry for Alzheimer's Disease* (CERAD) demostró que la evaluación visual de la atrofia generalizada era insatisfactoria y que la interpretación de las imágenes era altamente subjetiva. El CERAD determinó que se necesitaban técnicas de mayor precisión para medir la atrofia global (Davis, P., Gray, A., Albert, M. et al, 1992). Los esfuerzos apuntan entonces a cuantificar los diferentes tejidos cerebrales de una manera más automática, más sensible y sobre todo menos subjetiva.

La clasificación automática de tejido cerebral ofrece una aproximación alternativa. Permite procesar con una mayor sensibilidad, más rápido y por sobre todo se independiza del experto. Sin embargo, la automatización de los procesos, como se demostró a lo largo de este trabajo presenta aún algunas dificultades.

Antes de decidir trabajar con texturas se analizaron las técnicas estándar de procesamiento de imágenes a fin de lograr la segmentación y cuantificación de los diferentes tejidos cerebrales. Pocos ya proponen segmentación manual (Barlett, T., Vannier, M. et al., 1994) utilizando imágenes previamente escaneadas y realizando la segmentación a través del cursor con el mouse. Sin embargo, muchos radiólogos utilizan este método aún hoy para evaluar las dimensiones de tumores o de los mismos ventrículos laterales.

Muchos autores proponen segmentaciones semiautomáticas a través de técnicas de umbralamiento combinadas con seguimiento de contornos y análisis discriminante (Mizuno, K., Wakai, M., Takaeda, A. and Soue,G., 1999; Tanabe, J., Amend, D., Scuff, N. et al, 1997). Los resultados del umbralamiento y del seguimiento de contornos resultaron poco satisfactorios, además la intervención del usuario es excesiva, ya sea eligiendo el umbral a través del histograma o los pixeles semilla para el seguimiento de contornos. Todas estas intervenciones varían según las diferentes imágenes a procesar lo que lo hace operador-dependiente.

También se abordó, desde lo bibliográfico, el estudio de diferentes filtros de bordes como la integral de desplazamiento de bordes, en la bibliografía BBSI (Brain Boundary Shift Integral). Este modelo plantea la medición de la atrofia total del cerebro a través del desplazamiento de sus bordes en dos resonancias sucesivas (Fox, N., Freeborough, P., 1997). El equivalente de medir el desplazamiento de la posición de un borde en una dimensión, es medir el volumen total a través del desplazamiento de todos los bordes de una estructura. La registración exacta de una serie de resonancias permite determinar el volumen directamente por los niveles de gris de sus voxels. Esta técnica sirve fundamentalmente para determinar el volumen total del cerebro y se complica cuando se quiere determinar el volumen de la corteza sobre todo discriminando determinadas estructuras en particular. Por todo lo analizado se consideró que no era pertinente para el alcance de esta Tesis abordar este enfoque ya que la bibliografía existente es controvertida y había que realizar análisis con tecnologías de difícil alcance hoy en día en nuestro país.

Teniendo en cuenta que la segmentación tradicional requería demasiada intervención del usuario y que el modelo de la BBSI requería tecnología que no se disponía y sus resultados además eran dudosos, fue que se decidió aprovechar una herramienta poderosa: la Morfología Matemática (Serra, J., 1982; Serra, J., 1988). Se comenzó por segmentar los ventrículos laterales a través de operaciones morfológicas (apertura y dilatación condicionada) arribando a resultados satisfactorios y con buenos tiempos de procesamiento (Ballarin, V. y Valentinuzzi, M., 2001). Estas técnicas, basadas en morfología matemática, al considerar a la imagen como un conjunto de pixeles, hacen innecesario el uso de rutinas adicionales para la extracción del cráneo, la grasa circundante y las meninges.

Cuando se quisieron aplicar estas técnicas para la segmentación de la corteza los resultados no fueron los esperados. Una vez clasificados los ventrículos, se aplicaron nuevamente los algoritmos de apertura y dilatación condicionada pero con elementos estructurantes pequeños a fin de poder detectar la corteza. Los resultados no fueron los deseados. Aún trabajando con los elementos estructurantes en forma de disco de un pixel de diámetro, los algoritmos no son capaces de separar la corteza cerebral del líquido

cerebroespinal que lo rodea. Una técnica tan eficiente en la clasificación de los ventrículos quedó descartada entonces para la clasificación del resto de los tejidos.

En este punto se decidió optar por una segmentación a través de texturas. Este modelo permite muchos enfoques diferentes, desde los estadísticos hasta los espectrales (Moler, E., Ballarin, V. y González, M., 1999; Burrell, J., 2000). Al no obtener resultados satisfactorios con la clasificación de la corteza y tener que utilizar una segmentación que involucre texturas, se planteó un nuevo problema, segmentar el cráneo y las meninges. Para evitar que los algoritmos de texturas confundan cráneo y meninges con una de las tres texturas a cuantificar, se debió separar previamente el cráneo y las meninges.

Se utilizaron las técnicas de segmentación mediante contornos activos (*snakes*) que tienen una amplia aplicación en imágenes médicas para identificar estructuras anatómicas. Se aplicó una variante de la técnica paramétrica de *snakes* que introduce un nuevo modelo de fuerza externa llamado flujo vectorial del gradiente que mejora los problemas asociados con la inicialización y la convergencia (Kass, M. et al., 1987). Esta técnica permitió segmentar el cerebro del cráneo y las meninges con muy buenos resultados (Blotta, E., Moler E. y Ballarin, V., 2001).

Se abordaron los distintos enfoques para el análisis de texturas. Primero se aplicaron las técnicas basadas en las matrices de co-ocurrencia de niveles de gris (Argenti, F. et al., 1990; Argenti, F. et al., 1990). Si bien este método caracteriza las interrelaciones espaciales de los niveles de gris en patrones de textura, no captura aspectos de la forma de las primitivas de nivel de gris. Este método es más eficiente con imágenes que posean dependencia espacial de los niveles de gris en las cuales la información que la textura aporta es sustancialmente alta (Moler, E., Ballarin, V. y González, M., 1999). No es el caso de las imágenes de esta Tesis. Además el tamaño de las matrices de co-ocurrencia está determinado por el número de los diferentes niveles de gris de la imagen que se está analizando lo que hicieron los algoritmos exageradamente lentos.

Se abordó también el enfoque frecuencial a través de la transformada de Fourier con resultados similares a los anteriores. Bajo este enfoque, se utilizó el valor de entropía para caracterizar las texturas presentes. Los algoritmos resultaron lentos y la clasificación

obtenida a partir de ellos, si bien es mejor que la obtenida con los parámetros de co-ocurrencia, no es satisfactoria (Moler, E., Ballarin, V. y González, M., 1999; Burrell, J. 2000).

Por último se abordó el tema de texturas desde la Morfología Matemática (Serra, J., 1982; Serra, J., 1985). Basándose en trabajos anteriores en granulometría binaria (Dougherty, E., 1992; Dougherty, E. and Sand, F. 1995) y aprovechando sus propiedades de invariancia con respecto a la escala (Ballarin, V., Brun, M. y Moler, E., 2001) se extendió la granulometría a grises llegando a resultados ampliamente satisfactorios.

En esta última etapa todos los resultados se comparaban con los resultados que facilitara el Instituto Fleni clasificados a través del software denominado BRAINS que le suministrara el *Mental Health Clinical Research Center* de la Universidad de Iowa. Cuando los resultados comenzaron a ser satisfactorios se llevaron las imágenes clasificadas por BRAINS y las imágenes clasificadas por granulometría de grises a los expertos comprobando que la segmentación del LCR realizada a través de la granulometría de grises era visualmente más cercana a la realidad. Entonces se decidió que los expertos realizaran una segmentación manual de algunas imágenes testigo para posteriormente escanearlas y poder cuantificar volúmenes y recalcular las matrices confusión. Los resultados fueron aún mejores.

Además se realizó un estudio comparativo de los algoritmos no-supervisados de reconocimiento de patrones (Duda, R. & Hart, P., 1973; Fukunaga, K., 1985; Alfano, B., Brunetti, et al., 1997; Alfano, B. Quarantelli, M. et al., 1998). Se realizaron pruebas con los algoritmos tradicionales de Maximin, Mínima Distancia y K-medias. Finalmente se propuso una nueva variante, el K-medias ponderado que resultó ser la mejor según lo demostraron las matrices confusión calculadas. Esta variante tiene en cuenta para el cálculo de los centros de cluster, la cantidad de veces que aparece un determinado patrón en las imágenes y por ende disminuye los tiempos de procesamiento, mejorando así el principal inconveniente que tenía el algoritmo tradicional y conservando su estabilidad (Abrás, G., Ballarin, V. y González, M., 2001).

Todos los algoritmos desarrollados para esta tesis se encuentran a nivel de prototipo.

Capítulo VII

CONCLUSIONES

Se clasificaron los diferentes tejidos cerebrales con técnicas basadas en Morfología Matemática y Reconocimiento de Patrones en neuroimágenes con lesiones de tipo degenerativas a causa de la Enfermedad de Alzheimer.

Se obtuvieron resultados satisfactorios en la segmentación de los ventrículos laterales aplicando técnicas basadas en Morfología Matemática. Sin embargo, cuando se quiso extender el uso de estas técnicas para la clasificación de la corteza, los algoritmos no fueron capaces de separar la corteza cerebral del líquido céfalo-raquídeo que lo rodea.

Se aplicaron con éxito técnicas de segmentación de *snakes* para la segmentación de las meninges y el cráneo.

Se analizaron y compararon tanto analíticamente como computacionalmente diferentes modelos para la clasificación de texturas. Se demostró que los enfoques tradicionales de extracción de características de textura no permiten una segmentación adecuada de los diferentes tejidos en las imágenes de RMN.

Se analizó, a través de granulometría, el concepto de textura desde la Morfología Matemática.

Se extendió granulometría a niveles de gris a fin de extraer nuevos características de textura para la posterior clasificación de los tejidos. Se realizaron pruebas utilizando los momentos granulométricos y las imágenes multiespectrales como características.

Se propuso una nueva variante del algoritmo de K-medias, el K-medias ponderado, que permitió, junto con la granulometría de grises, la clasificación y el reconocimiento de texturas.

Se calcularon porcentajes de píxeles correctamente clasificados y matrices confusión a fin de evaluar los resultados obtenidos.

Se concluye que mientras los algoritmos standard no permiten una clasificación óptima en este tipo de imágenes de RMN, estas técnicas basadas en texturas logran un reconocimiento de los tejidos superior al 97% con una mínima intervención del experto.

Como trabajos futuros:

Aplicar estas técnicas de clasificación:

para medir la atrofia progresiva de la Enfermedad de Alzheimer y evaluar el efecto terapéutico de la medicación suministrada.

para medir la atrofia de sujetos añosos normales y compararla con las neuroimágenes de aquellos que padecen la Enfermedad de Alzheimer.

Teniendo en cuenta que la expectativa de vida se ha prolongado estos últimos 50 años, es importante que la continuidad de estos trabajos interdisciplinarios contribuya a mejorar la calidad de vida de la gente mayor.

Capítulo VIII

REFERENCIAS BIBLIOGRÁFICAS

- Abras, G., Ballarin, V. y González, M. (2001): 'Aplicación de Reconocimiento de Patrones en la Clasificación de Tejido Cerebral,' Actas del Congreso Argentino de Bioingeniería. Tafí del Valle. Septiembre 2001. (Publicadas en CD).
- Alexander, E., Wagner E., Bucher, D. et al. (1995): 'Do surgical brain lesions present as isolated dementia? A population study,' J. A. Geriat. Soc., 43, pp. 138-143.
- Alfano, B., Brunetti, et al. (1997): 'Unsupervised, automated segmentation of the normal brain using multispectral relaxometric magnetic resonance approach,' Magn. Reson. Med., 37, pp. 84-93.
- Alfano, B. Quarantelli, M. et al. (1998): 'Reproducibility of Intercranial Volume Measurement by Unsupervised Multispectral Brain Segmentation,' Magn. Reson. Med., 39, pp. 497-499.
- Argenti, F. et al., (1990): 'Fast calculation of co-occurrence matrix parameters for image segmentation,' Electronics Letters, 26, pp. 23-24.
- Argenti, F. et al., (1990): 'Fast algorithms for texture analysis using co-occurrence matrices,' IEE Proceedings for radar and Signal Processing, 137, pp. 443-448..
- Ballard, D. & Brown, C. (1992): 'Computer Vision,' (Prentice Hall, Englewood Cliffs, New York).
- Ballarin, V., Brun, M. y Moler, E. (2001): 'Scale invariant texture clasification with Mathematical Morphology,' J. Latin Am. App. Research, 31, pp. 79-82.

- Ballarin, V. y Valentinuzzi, M. (2001): 'Segmentación en imágenes de Resonancia Magnética de Cerebro utilizando Morfología Matemática,' Actas del Congreso Argentino de Bioingeniería. Tañ del Valle. Septiembre 2001. (Publicadas en CD).
- Barlett, T., Vannier, M. et al. (1994): 'Interactive segmentation of cerebral gray matter, white matter, and CSF: photographic and MR images,' *Comp. Med. Imag. Graphics*, 18, pp. 449-460.
- Bertin, E.; Parazza, F.; Chassery, J.M. (1993): 'Segmentation and Measurement Based on 3D Voronoi Diagram: Application to Confocal Microscopy,' *Comp. Med. Imag. Graphics*, 17(3), pp.175-182.
- Blotta, E., Moler E. y Ballarin, V. (2001): 'Extracción de contornos mediante flujo vectorial del gradiente en la técnica de snake,' Actas del XII Congreso Argentino de Bioingeniería II Jornadas de Ingeniería Clínica. Tucumán. Setiembre 2001, pp.121.
- Burril, J. (2000): 'Texture Mapping of Neurologica Magnetic Resonance Images,' Internet URL: <http://www.burril.demon.co.uk/meddoc/tmmri..html> (accedido el 4 de Octubre del 2000).
- Castleman, R. (1979): 'Digital Image Processing,' (Prentice-Hall, Englewood Cliffs, New Jersey).
- Cernuschi Frías, B. & Belausteguigoitia, C. (1987): 'Visión por computadoras' (II EBAI, Kapelusz).
- Coffey, C., Wilkinson, W. and Parashos, I. (1992): 'Quantitative cerebral anatomy of the aging human brain: a cross-sectional study using Magnetic Resonance Imaging,' *Neurology*, 42, pp. 527-536.
- Chen, Y.Q., Bi, G., (1999): 'On Texture Classification Using Fractal Dimension,' *IEEE Trans. on Pattern Recognition Artificial Intelligence* (13), No. 6, pp. 929.
- Davis, P., Gray, A., Albert, M. Et al. (1992): 'The Consortium to Establish a Registry for Alzheimer's Disease,' *Neurology*, 42, pp. 1676-1680.

- Dougherty, E. (1992): 'An Introduction to Morphological Image Processing,' (SPIE, Washington).
- Dougherty, E. and Sand, F. (1995): 'Represent of linear granulometric moments for deterministic and random binary Euclidean images,' *Visual Commun. Image Represent.* 6(1).
- Dubreil, M. L. (1964): 'Jacotin Images homomorphes d'un demi-groupe ordonné,' *Bull. Soc. Math. France* t. 92.
- Duda, R. & Hart, P. (1973): 'Pattern Classification and Scene Analysis,' (Wiley-Interscience, New York).
- Fox, N., Freeborough, P., (1997): 'Brain Atrophy Progression Measured from Registered Serial MRI: Validation and Application to Alzheimer Disease,' *J. Mag. Res. Imag.*, 7, pp. 1069-1075.
- Frohn, R. (1997): 'Remote Sensing for Landscape Ecology,' (Lewis Publishers).
- Fukunaga, K. (1985): 'Introduction to Statistical Pattern Recognition,' (2nd ed., Academic Press, London).
- Glasbey, C. and Horgan, G. (1995): 'Image Analysis for the Biological Sciences,' (John Wiley & Sons, New York).
- Gonzalez, R. & Woods, R. (1992): 'Digital Image Processing,' (Addison -Wesley, New York).
- Haralick, R. and Shapiro, L. (1992): 'Computer and Robot Vision,' (Addison-Wesley, New York).
- Heijmans, H. (1991): 'Theoretical aspects of gray-scale morphology,' *IEEE Trans. Pattern Anal. Mach. Intell.*, 13, pp.568-582.

- Holodny, A., Waxman, R., George, A. Et al. (1998): 'MR differential diagnosis of normal-pressure hydrocephalus and Alzheimer's disease: significance of perihippocampal features,' *Am. J. Neuroradiol.*, 19, pp. 813-819.
- Image Pro-Plus (1999): *The Proven Solution for Image Analysis. Image Pro-Plus Reference Guide for Windows™. Version 4.1 Media Cybernetics.*
- Jain, A. (1989): 'Fundamentals of Digital Image Processing,' (Prentice Hall, Englewood Cliffs, New Jersey).
- Kaplan, L.M. (1999): 'Extended Fractal Analysis for Texture Classification and Segmentation,' *IEEE Trans. on Imag. Processing* (8), No. 11, pp. 1572-1585.
- Kass, M. et al. (1987): 'Snakes: Active contour models,' *Int. J. Comput. Vis.*, 1, pp. 321-331.
- Keller, P. (1990): 'Basic principles of Magnetic Resonance Imaging,' (General Electric Medical Systems, Milwaukee, U.S.A.).
- Leguizamón, S., (1989): 'Análisis textural de imágenes mediante medición de entropía,' *Jornadas Internacionales sobre Uso de Computadoras en Investigaciones Científicas y Técnicas*, Mendoza, 1989, pp. 431-440.
- Leiguardia, R. (1992): 'Neurología,' (Biblioteca de Medicina, Semilogía, Patología y Clínica, Ed. Librería el Ateneo, Buenos Aires).
- Manes, F. (2000): 'Resonancia magnética nuclear en la Enfermedad de Alzheimer,' *Rev. Neurol. Arg.*, 25, pp. 29-37.
- Mather, P. (1976): 'Computational Methods of Multivariate Analysis in Physical Geography,' (Ed. Wiley & Sons, New York).
- Mizuno, K., Wakai, M., Takaeda, A. And Soue, G. (1999): 'Medial temporal atrophy and memory impairment in early stage of Alzheimer's disease: an MRI volumetric and memory assessment study,' *J. Neurolog. Sc.*, 173, pp. 18-24.

- Moler, E., Ballarin, V. y González, M. (1999): 'Características estadísticas, espectrales y morfológicas para clasificación de texturas: un análisis comparativo,' Actas de la VIII RPIC (Reunión de Trabajo en Procesamiento de la Información y Control). Mar del Plata. Setiembre 1999, pp. 59-67.
- Moler, E., Ballarin, V., Abras, A., Blotta, E., Meschino, G. y González, G. (2002): 'Segmentación automática de formas en imágenes médicas a través de técnicas de Procesamiento Digital de Imágenes,' Actas del Congreso de la Sociedad Argentina de Física Médica. Rosario. Noviembre 2002. (Publicadas en CD).
- Mojsilović, A., Popović, M. And Rakov, D. (2000): 'On selection of an optimal Wavelet Basis fo Texture Characterization,' IEEE Trans. Image Processing (9) 12 pp. 2043-2050.
- Rosenfeld, A. & Kak, A. (1976): 'Digital Picture Processing,' (Academic Press, London).
- Russ, J. (1995): 'The Image processing Handbook,' (2nd edition, CRC Press, USA).
- SDC (2001): SDC Morphology Toolbox for MATLAB 5. User's Guide. SDC Information Systems.
- Serra, J. (1982): 'Image Analysis and Mathematical Morphology,' (Academic Press, London).
- Serra, J. (1988): 'Image Analysis and Mathematical Morphology- Part II: Theoretical Advances,' (Academic Press, London).
- Sing-Tze, B. (1992): 'Pattern Recognition and Image Preprocessing,' (Marcel Dekker, Inc., New York).
- Snake (Demo Snake, V1.0 beta, 2000): Internet URL: <http://iacl.ece.jhu.edu/projects/gvf> (accedido el 15 de Agosto del 2000).
- Snell, R. (1999) : 'Neuroanatomía Clínica,' (Ed. Panamericana, Buenos Aires).

- Tanabe, J., Amend, D., Scuff, N. et al. (1997): 'Tissue segmentation of the brain in Alzheimer Disease,' *Am. J. Neuroradiol.*, 18, pp. 115-123.
- Tortora, G. & Grabowski, S. (1998): 'Principios de Anatomía y Fisiología,' (7^{ma} ed., Harcourt Brace, Madrid).
- Tou, J. & Gonzalez, R. (1974): 'Pattern Recognition Principles,' (Adisson- Wesley, New York).
- Vincent L., Dougherty E. (1994): 'Morfological Segmentation for Textures and Particles,' (Digital Image Processing Methods, Rochester, New York).
- Wang D. , Ronsin J. (1996): 'Bounded Gray-Level Morphology and Its Applications to Image representation,' *IEEE Trans. Image Processing*, 5(6), pp. 1067-1073.