

**MODELADO Y CORRECCIÓN
DE INHOMOGENEIDADES DE CAMPO
EN IRM**

Tesis que presenta
Obeth Hernández Díaz
Para obtener el grado de
Maestro en Ciencias en Ingeniería Biomédica



Casa abierta al tiempo

UNIVERSIDAD AUTÓNOMA METROPOLITANA
UNIDAD IZTAPALAPA División de Ciencias Básicas e Ingeniería

**MODELADO Y CORRECCIÓN
DE INHOMOGENEIDADES DE CAMPO
EN IRM**

Tesis que presenta
Obeth Hernández Díaz
Para obtener el grado de
Maestro en Ciencias en Ingeniería Biomédica

Asesor: M. I. OSCAR YÁÑEZ SUÁREZ

Jurado Calificador:

Presidente: DRA. NIDIYARE HEVIA MONTIEL

UNAM-CCADET

Secretario: M.I. OSCAR YÁÑEZ SUÁREZ

UAM-I

Vocal: DRA. RAQUEL VALDÉS CRISTERNA

UAM-I

México, D. F. junio 2010

**MODELADO Y CORRECCIÓN
DE INHOMOGENEIDADES DE CAMPO
EN IRM**

Tesis que presenta
Obeth Hernández Díaz
Para obtener el grado de
Maestro en Ciencias en Ingeniería Biomédica

Asesor: M. I. OSCAR YÁÑEZ SUÁREZ

Jurado Calificador:

Presidente: DRA. NIDIYARE HEVIA MONTIEL UNAM-CCADET

Secretario: M.I. OSCAR YÁÑEZ SUÁREZ UAM-I

Vocal: DRA. RAQUEL VALDÉS CRISTERNA UAM-I

México, D. F. junio 2010

AGRADECIMIENTOS

Agradezco a Dios por poner todos los medios y por la hermosa familia que tengo.

Cuando logramos una meta planteada y volteamos hacia atrás nos damos cuenta que en realidad es un logro compartido por el apoyo de muchas personas, quienes nos motivan a seguir adelante. Es por ello, que quiero agradecer la realización de esta tesis a todas esas valiosas personas que he encontrado en mi vida:

- Agradezco en primer lugar a mi asesor M. I. Oscar Yáñez Suárez, por sus enseñanzas, dedicación y paciencia, de verdad no me hubiera sido posible concluir los estudios de maestría sin haberme encontrado más que a un maestro de posgrado a un maestro de vida. Gracias Oscar por escucharme en esos años difíciles y más que preocuparte por ocuparte en ayudarme a salir adelante.
- A mi mamá Eufemia, porque tu ejemplo de vida me ha enseñado a persistir hasta alcanzar lo que uno se proponga, “Ojitos” gracias por tu apoyo, amor y cariño.
- A mi hermana Ibeth, porque de ti he aprendido el espíritu de lucha y tenacidad que fortalece las acciones, “Chapis” gracias por enseñarme a tener el valor de afrontar cualquier adversidad.
- A mi esposa María Leticia, porque eres la “Dulce Alegría” que llegó a mi vida, gracias amor por tus desvelos, apoyo incondicional, paciencia y comprensión.
- A mis hijos Obeth y Paola, porque son el motor que me impulsa a ser mejor, “Kilines” todo lo que soy es para ustedes, gracias por esas caritas de ternura y sonrisas cuando todo me agobia.
- A mis sobrinos David y Andrea, porque es maravilloso tener a unos “Güerejos” que al verlos disfruto tanto su compañía y me entusiasma ser parte de sus vidas.
- A mis amigos Julio César, Johan y Miguelangel, quienes siempre me han apoyado y ayudado a ser mejor profesionalista y persona.
- A mis sinodales de tesis Dra. Raquel Valdés y Dra. Nidiyare Hevia, quienes me han ayudado a concluir y mejorar ésta tesis.
- A mis maestros de la Universidad Autónoma Metropolitana... Casa abierta al tiempo. Por la dedicación a la formación de profesionistas comprometidos con la mejora del entorno.
- Al CONACYT, por el apoyo recibido a través de la beca de posgrado, ahora me congratulo informarles que soy parte del grupo que desarrollará el Sistema Regional de Innovación en Michoacán, invertir en los jóvenes es invertir en el futuro de México.

RESUMEN

Las imágenes de RMN cobran cada vez mayor importancia en la práctica médica, se emplean para generar atlas anatómicos, estudios funcionales, análisis de patologías, como guía pre e intra operatoria y en la fusión con otras técnicas de estudio de las variables fisiológicas. Por otra parte, cada vez se usan más equipos de IRM en los centros médicos, por lo que se requieren métodos eficientes para analizar grandes cantidades de información.

La técnica de IRM presenta diversas dificultades para obtener resultados útiles para el diagnóstico o la investigación. En este trabajo se abordan tanto los aspectos de la segmentación de IRM como el modelado y la corrección de las inhomogeneidades del campo magnético, que altera los datos a lo largo de todo el conjunto de imágenes en un estudio de IRM, dificultando la segmentación.

Uno de los métodos más conocidos para obtener segmentaciones de IRM, considerando la inhomogeneidad del campo, es el método de restauración-segmentación propuesto por Wells. Sin embargo, asume un modelo paramétrico de mezcla de gaussianas para la distribución de las intensidades de la imagen. Este trabajo consiste en utilizar el método de restauración-segmentación con un modelado no paramétrico, mediante el uso de una Red Neuronal Probabilística que haga las estimaciones de las probabilidades posteriores, que se emplean tanto para la estimación del campo de ganancia y la corrección de la imagen como para la segmentación de la misma. Otra aportación de este trabajo es que para construir la red se emplean estimadores robustos de localización y dispersión asociados a cada pixel de la imagen, utilizando el algoritmo de Modas Realzadas, las clases principales en la imagen se obtienen mediante el uso del algoritmo de Corrimiento de Media, que hace una estimación del gradiente de la función de densidad de la imagen.

El método propuesto es evaluado utilizando imágenes sintéticas de RMN obteniendo las matrices de confusión y una medida de similitud de probabilidad (Kappa) promedio de 96%, respecto de las segmentaciones ideales.

ÍNDICE

	Página
CAPÍTULO 1. INTRODUCCIÓN	1
CAPÍTULO 2. MARCO TEÓRICO SOBRE IRM	4
2.1. GENERACIÓN DE IMÁGENES DE RESONANCIA MAGNÉTICA (IRM) Y SUS APLICACIONES.	4
2.1.1. Orígenes.	4
2.1.2. Principios Físicos.....	5
2.1.3. Obtención de Imágenes de RMN.....	6
2.1.4. Tipos de Imanes.....	8
2.1.5. Aspectos Técnicos en la Obtención de IRM.....	9
2.1.6. Ventajas e Inconvenientes de la IRM.....	12
CAPÍTULO 3. MARCO TEÓRICO SOBRE SEGMENTACIÓN E INHOMOGENEIDADES DE CAMPO EN IRM	16
3.1. DIFICULTADES PARA LA SEGMENTACIÓN DE IRM.....	16
3.1.1. Artefactos.....	16
3.1.2. Efecto del Volumen Parcial.....	23
3.1.3. Resultados Operador-Dependientes.....	23
3.1.4. Cantidad de Información a Analizar.....	24
3.2. INHOMOGENEIDADES DE CAMPO MAGNÉTICO Y SU MODELACIÓN MATEMÁTICA.....	25
3.3. REVISIÓN DEL ESTADO DEL ARTE.....	26
3.3.1. Corrección del Campo Magnético con las Bobinas de Compensación.....	26
3.3.2. Métodos de Segmentación de IRM.....	27
3.3.3. Método de Restauración-Segmentación.....	29
3.3.4. Modalidades del Método de Restauración-Segmentación.....	33
3.3.5. Limitaciones del Modelado Paramétrico.....	36
3.3.6. Modelado No Paramétrico.....	37

3.3.7. Procedimientos Automáticos para la Segmentación de IRM.....	41
CAPÍTULO 4. PLANTEAMIENTO DEL PROBLEMA.....	43
4.1. JUSTIFICACIÓN.....	43
4.2. OBJETIVO GENERAL.....	44
4.2.1. Objetivos Específicos.....	44
CAPÍTULO 5. METODOLOGÍA.....	46
5.1. RED NEURONAL PROBABILÍSTICA.....	46
5.2. CONSTRUCCIÓN DE LA RED NEURONAL PROBABILÍSTICA.....	53
5.2.1. Construcción de la Capa de Entrada.....	53
Estimadores Robustos de Localización ($\vec{\theta}_{EM}$) y de Dispersión (\vec{S}_{EM}).....	53
Algoritmo de Modas Realzadas, $\vec{\theta}_{EM}$ (Enhanced Mode).....	54
Vectores de Entrada.....	56
Construcción del Espacio de Características.....	59
5.2.2. Construcción de la Capa de Patrones.....	61
Selección de los Vectores de Entrenamiento.....	61
Cálculo de las Desviaciones Estándar Asociadas.....	65
5.2.3. Construcción de la Capa de Clases.....	70
Estimación de los parámetros del modelo vía modas realzadas.....	70
Algoritmo de Corrimiento de Media.....	70
Obtención de las Clases Principales en la Imagen Mediante la Estimación del Gradiente de la Función de Densidad.....	74
5.2.4. Interconexión Entre la Capa de Patrones y la Capa de Clases.....	77
Clasificador de Distancia de Mahalanobis.....	77
5.3. OBTENCIÓN DE LAS PROBABILIDADES A POSTERIORI E INCORPORACIÓN AL MÉTODO DE RESTAURACIÓN-SEGMENTACIÓN.....	79
5.4. ESTIMACIÓN DE LA IMAGEN ESTADÍSTICA.....	80
5.5. ESTIMACIÓN DEL CAMPO DE GANANCIA.....	82
5.6. SEGMENTACIÓN DE LA IMAGEN.....	87
5.7. EVALUACIÓN DEL MÉTODO.....	87

5.7.1. Estimados de las Probabilidades a Posteriori.....	89
5.7.2. Factor de Confianza en la Clasificación.....	89
5.7.3. Estadísticas de Clasificación.....	90
5.7.4. Matrices de Confusión de Clases.....	90
5.7.5. Medida de Similitud de Probabilidad Corregida (Kappa).....	92
CAPÍTULO 6. RESULTADOS.....	94
6.1. OBTENCIÓN DE LAS CLASES PRINCIPALES USANDO EL ALGORITMO DE CORRIMIENTO DE MEDIA.....	94
6.2. DESEMPEÑO DEL CLASIFICADOR DE DISTANCIA DE MAHALANOBIS.....	96
6.3. RESULTADOS DE LOS ESTIMADOS DE LAS PROBABILIDADES A POSTERIORI.....	96
6.4. RESULTADOS DEL FACTOR DE CONFIANZA EN LA CLASIFICACIÓN.....	98
6.5. ANÁLISIS DE SUSCEPTIBILIDAD A VARIACIÓN DE LOS PARÁMETROS.....	99
6.5.1. Tamaño de las Ventanas de Datos y de Análisis en el Algoritmo de Modas Realizadas.....	99
6.5.2. Nivel del Umbral para la Desviación Estándar Máxima Permitida.....	103
6.5.3. Ajuste del Radio del Kernel para el Algoritmo de Corrimiento de Media.....	108
6.5.4. Variaciones del Parámetro de Suavizamiento σ^2 en la Red Neuronal Probabilística.....	113
6.6. RESULTADOS CON IMÁGENES SINTÉTICAS DE IRM.....	119
6.7. RESULTADOS CON IMÁGENES REALES DE IRM.....	128
6.8. CONSIDERACIONES SOBRE EL TIEMPO DE PROCESAMIENTO.....	133
6.9. COMPARACIÓN DEL VALOR DE KAPPA OBTENIDO.....	133
CAPÍTULO 7. DISCUSIÓN Y CONCLUSIONES.....	134
BIBLIOGRAFÍA.....	140
APÉNDICE A.....	147

CAPÍTULO 1

INTRODUCCIÓN

Actualmente las aplicaciones de la Resonancia Magnética Nuclear (RMN) para generar imágenes médicas cobran cada vez mayor importancia, por las ventajas inherentes de la técnica. Sin la necesidad de exponer al paciente a radiaciones nocivas, se pueden obtener estudios anatómicos y funcionales que permiten a los médicos trabajar en el estudio de las funciones del organismo, analizar patologías, hacer planeaciones pre-operatorias y aprovechar la técnica como guía intra-operatoria. Más aún, la fusión de la técnica de imágenes de resonancia magnética (IRM) con otras técnicas para el estudio de las variables fisiológicas (como la Electroencefalografía), están abriendo posibilidades de generar nuevos conocimientos cada día en el campo médico.

Sin embargo, como cualquier técnica, la RMN no se encuentra libre de presentar dificultades para obtener resultados aprovechables para el diagnóstico o la investigación. Es por ello, que la presente tesis se dedica a dos aspectos muy importantes en IRM. Primero, modelar y analizar uno de los problemas más comunes de la IRM, que es la inhomogeneidad del campo magnético, cuya influencia se refleja en las imágenes adquiridas y por consecuencia en los resultados esperados. Segundo, obtener segmentaciones de las imágenes que se aprovechen como entradas a otros procesos, para aplicaciones tan novedosas como la neuronavegación.

Cada vez es mayor el uso de los equipos de RMN en los centros médicos, generando grandes cantidades de información a analizar, de ahí la importancia de los aspectos que se desarrollan en este trabajo.

En el capítulo 2 se proporciona información básica al lector sobre la generación de imágenes en IRM y sus aspectos técnicos.

En el capítulo 3 se abordan las principales dificultades para la segmentación en IRM, como son la presencia de artefactos, el efecto del volumen parcial, los resultados dependientes del operador y la cantidad de información a analizar.

Las inhomogeneidades del campo magnético se deben a diversos factores y su modelación matemática como un ruido multiplicativo presente en las imágenes también se aborda en el capítulo 3, el cual concluye con una amplia revisión técnica, tanto de la modelación y corrección del campo magnético, como de los métodos para la segmentación en IRM, incluyendo la descripción del método de restauración-segmentación propuesto por Wells, que es la base para las propuestas de mejora hechas en esta tesis.

En el capítulo 4 se hace el planteamiento formal de los objetivos de este trabajo y la justificación para el uso del modelado no paramétrico a diferencia del modelado paramétrico en el método original de Wells.

El capítulo 5 describe la metodología propuesta, cuyos aspectos a destacar son: emplear una Red Neuronal Probabilística para obtener los estimados de las probabilidades posteriores (necesarias en el método de restauración-segmentación), sin la necesidad de asumir un modelo de mezcla de gaussianas (como en el método original propuesto por Wells), construir la capa de entrada de la red empleando el algoritmo de Modas Realzadas utilizando estimadores robustos de localización y de dispersión (en lugar de los valores comúnmente usados de media y desviación estándar) y construir la capa de patrones de la red utilizando el algoritmo de Corrimiento de Media, el cual hace una estimación del gradiente de la función de densidad de las intensidades de la imagen, encontrando las clases principales de la misma.

Dentro del capítulo 5 se describe como se incorporan los resultados de la red al método de restauración-segmentación, la obtención de una imagen estadística para la estimación del

campo de ganancia y la segmentación de la imagen. También se hace una descripción de la manera de evaluar el método propuesto.

En el capítulo 6 se presentan los resultados de la determinación de las clases principales, en la interconexión entre la capa de patrones y la capa de clases de la red. Se muestran resultados cualitativos y también mediciones cuantitativas de las segmentaciones obtenidas con imágenes sintéticas, contaminadas con diferentes niveles de ruido aditivo y de inhomogeneidad del campo. Una consideración importante para todo trabajo es el análisis de susceptibilidad de los parámetros utilizados en el método, y en el mismo capítulo se presentan los resultados del análisis, siendo los parámetros analizados: el tamaño de las ventanas de datos y de análisis en el Algoritmo de Modas Realzadas, el nivel del umbral de censurado para la desviación estándar máxima permitida, el ajuste del radio del Kernel para el algoritmo de Corrimiento de Media y las variaciones del Parámetro de Suavizamiento σ^2 en la Red Neuronal Probabilística.

En el capítulo 7 se presentan el análisis de los resultados, su discusión, las conclusiones y diversos aspectos del trabajo futuro que se puede realizar.

También se acompaña la tesis de una amplia bibliografía sobre el tema y un apéndice sobre la gran variedad de artefactos que pueden afectar las imágenes de RMN.

CAPÍTULO 2

MARCO TEÓRICO SOBRE IRM

2.1. GENERACIÓN DE IMÁGENES DE RESONANCIA MAGNÉTICA (IRM) Y SUS APLICACIONES.

2.1.1. Orígenes.

A principios de los años 70, cuando la Tomografía Computarizada comenzaba a tener un fuerte impacto en el diagnóstico radiológico, ya se estaba investigando otra modalidad para la obtención de imágenes basada en la Espectroscopia de Resonancia Magnética Nuclear. La Imagen por Resonancia Magnética, como se le denomina en la actualidad, se emplea frecuentemente en la práctica clínica y su potencial impacto en la Medicina ha crecido de manera vertiginosa en igual o mayor medida que la Tomografía Computarizada o la Ecografía. Actualmente la IRM se ha convertido en una de las principales técnicas de diagnóstico por imagen.

La IRM es una variante de las técnicas de RMN que llevan varios años utilizándose en la física y química para fines distintos al de visualización. En 1946, los grupos de investigación de F. Bloch y E. Purcell, estudiaron el comportamiento de los núcleos atómicos inmersos en un campo magnético [1,2]. Descubrieron que los núcleos absorbían energía de las ondas de radio de ciertas frecuencias. Se concluyó que un análisis espectral puede proporcionar información sobre el movimiento y la composición de las moléculas. Por ello, hoy en día la espectroscopia de RMN se sigue utilizando ampliamente en la Química, para conocer la

composición detallada de moléculas complicadas, y en la Física para estudiar el movimiento molecular.

Posteriormente a las investigaciones de F. Bloch y E. Purcell, varios investigadores comenzaron a interesarse en realizar pruebas con tejidos vivos. Así, Raymond Damadian experimentó con tejidos extirpados de ratas y en el año 1971 informó que existían diferencias significativas en los parámetros de la RMN entre los tejidos sanos de rata y diversos tumores. En el año 1972, Paul Lauterbur publicó la primera imagen de RMN obtenida mediante un espectrómetro modificado, en la cual se apreciaba la sección de los capilares llenos de agua. Damadian obtuvo en el año 1975 las primeras imágenes de animales, [1,2]. Peter Mansfield y A. Maudsley en 1977 publicaron la primera imagen seccional humana, un dedo. Peter Mansfield y Paul Lauterbur posteriormente siguieron contribuyendo al desarrollo de la RMN y fueron galardonados con el premio Nobel de Fisiología y Medicina de 2003 [2]. A finales de los años 70, la IRM estaba desarrollándose a toda velocidad. Los primeros escáneres para estudiar el cerebro humano aparecieron en el año de 1978, seguidos muy poco tiempo después por los escáneres de cuerpo completo [1].

2.1.2. Principios Físicos.

La Resonancia Magnética Nuclear (RMN) es un fenómeno físico por el cual ciertas partículas como los electrones y los núcleos atómicos con un número impar de protones (Z) y/o de neutrones (N) pueden absorber selectivamente energía electromagnética de radiofrecuencia (RF).

Pueden diferenciarse dos vertientes de aplicación de la RMN:

- 1.- Técnicas de imagen (IRM)
- 2.- Técnicas de análisis espectrométrico (SRM)

En IRM pueden aprovecharse ya sea las propiedades magnéticas de los electrones (RME) o de los núcleos (RMN). Debido a su abundancia en el organismo humano y por su alta señal generada, el núcleo de Hidrógeno (H) es el que se utiliza rutinariamente en la práctica clínica.

Cuando los núcleos bajo un campo magnético entran en “*resonancia*”, absorben energía de radiofrecuencia en un proceso llamado de “*relajación*”. Durante este proceso de relajación inducen una señal eléctrica a una antena receptora (bobina) que tratada convenientemente sirve para obtener la imagen tomográfica en IRM o para realizar el análisis espectrométrico en SRM [1,3].

Para la generación de imágenes mediante RMN la materia es magnetizada por la influencia de un campo magnético B_o muy intenso. En estas circunstancias, los núcleos son capaces de absorber y emitir energía (resuenan) al ser sometidos a la acción de las ondas de RF [1,3], que cumplen la ley de Larmor:

$$f_p = K_{gm} * B_o \quad (2.1)$$

Donde,

- f_p : Frecuencia de precesión o frecuencia de Larmor (igual a la frecuencia de resonancia).
- K_{gm} : Constante giromagnética propia de cada núcleo magnetizable.
- B_o : Intensidad del campo magnético principal.

2.1.3. Obtención de Imágenes de RMN.

La obtención de las imágenes se logra al recolectar las ondas de radiofrecuencia procedentes de la materia estimulada y mediante un proceso similar al de la Tomografía Axial Computada (TAC), se logra generar un sistema de coordenadas donde se representan las diferentes densidades de los tejidos, obteniendo así una imagen representativa de las concentraciones de Hidrógeno en los tejidos analizados (los átomos de H son los más abundantes en el organismo humano).

Cualquier tomógrafo por RMN tiene las siguientes partes fundamentales (ver figura 2.1):

- Imán: Para la generación del campo magnético intenso (del orden de Teslas).
- Computadora: Para el sistema de representación de imagen.
- Antena emisora de RF (bobina emisora).
- Antena receptora (bobina receptora). A menudo la antena emisora es utilizada como antena receptora.

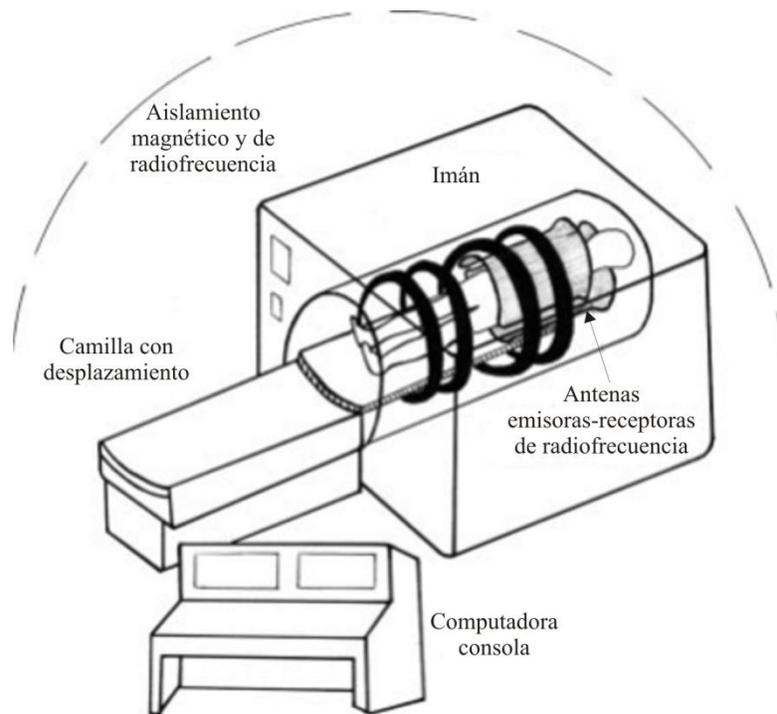


Figura 2.1. Partes fundamentales de un tomógrafo por RMN.

El equipo hace una representación tomográfica del paciente en elementos de volúmenes (llamados voxeles), que definen la matriz de adquisición y el espesor del corte.

Al colocar a un individuo bajo el campo magnético B_0 , en cada uno de los voxeles aparecen, derivado de los núcleos de H, medidas indirectas de propiedades magnéticas (*Magnetización del Voxel*) que se aprecian como magnitudes vectoriales orientadas en la dirección del campo magnético B_0 .

El valor de la *Magnetización del Voxel* depende de la densidad de núcleos de H que se encuentran en el voxel. En estas condiciones si se somete al voxel a ondas de RF y se varía una frecuencia determinada, el *Vector de Magnetización* (\vec{M}) se desvía de su posición inicial de equilibrio. Se dice que se ha producido el fenómeno de *Resonancia Magnética de los Núcleos de Hidrógeno*, o bien, que los núcleos de H están en resonancia con la emisión de RF.

El *Vector de Magnetización* \vec{M} realiza un movimiento de giro sobre la dirección del campo magnético a la frecuencia de la radiación absorbida. A este movimiento del vector \vec{M} se le denomina *Movimiento de Nutación* [3,4].

El ángulo de inclinación que forma la magnetización con la posición inicial depende entre otros factores de la duración de la emisión de RF (pulso). La importancia del pulso es por el valor del ángulo de inclinación que se logra. Se habla entonces de un pulso de 90°, un pulso inversor de 180° o simplemente un pulso de ángulo de inclinación.

Las imágenes de RMN se obtienen enviando pulsos de diversos valores, separados a intervalos de tiempo adecuados, lo que constituye las secuencias de pulsos. Después de enviar un pulso de ángulo de inclinación, los núcleos de H liberan el exceso energético que han absorbido de la RF mediante un proceso de *Relajación Energética*. Durante esta relajación, la *Magnetización del Voxel* regresa a su posición de equilibrio alineada con B_0 . Esta variación de posición representa una variación magnética que induce sobre la denominada antena receptora una corriente eléctrica que servirá para realizar la imagen [1,3].

2.1.4. Tipos de Imanes.

El imán constituye el elemento base de cualquier equipo de RMN, es de suma importancia cuidar las características del mismo, ya que de ellas dependerá la calidad de las imágenes que se obtengan. Además de la intensidad del campo magnético es muy importante considerar, la estabilidad en el campo y el grado de homogeneidad del mismo (que es el tema central de este trabajo), aún después de aplicar las placas y bobinas de compensación (*shimming coils*) [3].

El campo magnético en un sistema de RMN es originado por un imán. Se expresa en unidades de inducción magnética, las utilizadas son Teslas (T) y Gauss. La equivalencia es 1 T=10.000 Gauss. Los aparatos de RMN se clasifican como de bajo, medio o alto campo magnético, según el valor del campo magnético, siendo el valor más típico a 1.5 T, no por que se tengan condiciones optimas o especiales, sino simplemente porque era el valor de campo más alto que se consiguió a finales de los años setenta, cuando la RMN comenzaba a establecerse [3].

Existen diversos tipos de imanes utilizados en los equipos de RMN:

- 1.- Permanentes, adquieren sus propiedades magnéticas durante su proceso de fabricación normalmente hechos a base de aleaciones de Níquel, Aluminio y Cobalto. Pueden originar campos desde 0.2 T hasta alrededor de 0.6 T.
- 2.- Resistivos, crean el campo magnético mediante una corriente eléctrica, pudiendo crear campos desde 0.15 T hasta 0.5 T.
- 3.- Superconductivos, se basan en la propiedad de ciertas aleaciones como el Titanio-Niobio, que pierden su resistencia eléctrica al ser enfriados a temperaturas cercanas al cero absoluto, logrando intensidades de campo desde 0.5 T hasta 2 T. En equipos con intensidades de campo mayores a 2 T (hay algunos que operan hasta 9 T) se incrementa la resolución en las imágenes por la disminución del tamaño del voxel [3], sin embargo, se pueden inducir corrientes que degradan la imagen y si no se utilizan gradientes elevados de los protones del hidrógeno y de las grasas pueden generar un artefacto por desplazamiento químico [4].

2.1.5 Aspectos Técnicos en la Obtención de IRM.

La calidad de las señales de resonancia emitidos por la materia estudiada dependen de varios parámetros fundamentales: los *tiempos de relajación* (T1 y T2), *densidad de los núcleos resonantes* y *velocidad de flujo de la materia analizada*.

Los *tiempos de relajación* (T1 y T2), son fundamentalmente tiempos que miden la rapidez con que se recuperan los núcleos resonantes al ser perturbados por las ondas de RF. Los *tiempos*

de relajación de los protones (o de cualquier núcleo resonante) son completamente dependientes del resto de los átomos que los rodean, ya que estos modifican sus características de movimiento físico en relación con su entorno midiéndose mediante el T1 (*Tiempo de Relajación Longitudinal*) o el T2 (*Tiempo de Relajación Transversal*).

Para obtener buenas imágenes se requieren equipos de media o alta intensidad de campo magnético (más de 0.3 T) los más utilizados son los de 0.5 T ó 1.5 T, respectivamente. Para obtener una señal de RMN es necesario definir una secuencia dependiendo del órgano o de la patología que se quiere detectar, esto es, elegir el *tipo de impulso*, el *tiempo de repetición* (TR) y los *tiempos de eco* (TE). En estudios convencionales la *secuencia de pulso* más habitual se denomina *Spin-Echo* (SE), obteniéndose diferentes tipos de imágenes: *TR corto*, *TE corto* (imágenes de mayor calidad anatómica).

Los tres parámetros fundamentales en IRM son:

- 1.- Densidad Protónica (densidad de *spines*, densidad de Hidrógeno).
- 2.- Relajación T1 (relajación *spin-malla*, relajación longitudinal).
- 3.- Relajación T2 (relajación *spin-spin*, relajación transversal).

Diferentes tipos de tejidos generan diferentes tipos de señales, esto permite obtener diferentes contrastes de imágenes mediante la aplicación de las técnicas correctas que pueden mostrar diferencias entre características de tejidos. Por ejemplo, el aire aparece en negro en las imágenes, los huesos producen una escasa señal en T1 y en T2, la grasa produce una señal intensa sobre las imágenes generadas en T1 y un poco menos intensa en imágenes de T2, los músculos generan señales débiles en todas las condiciones, el líquido cefalorraquídeo no se distingue de los huesos en T1 y es fácil distinguirlo en T2, etc. [4].

En general puede decirse que las imágenes de T1 son anatómicas y las imágenes de T2 tienen un menor detalle anatómico, pero en términos generales son de mayor sensibilidad en la detección de patologías. De este modo, es la utilidad de la comparación de las imágenes en ambas secuencias T1 y T2 lo que proporciona la información de la lesión o patología [4]. Existe una secuencia intermedia *Densidad Protónica* (DP) que fundamentalmente lo que

detecta es la cantidad de protones [3]. En la figura 2.2, pueden apreciarse tres imágenes una adquirida con la secuencia T1, otra con la secuencia T2 y otra con la secuencia DP.

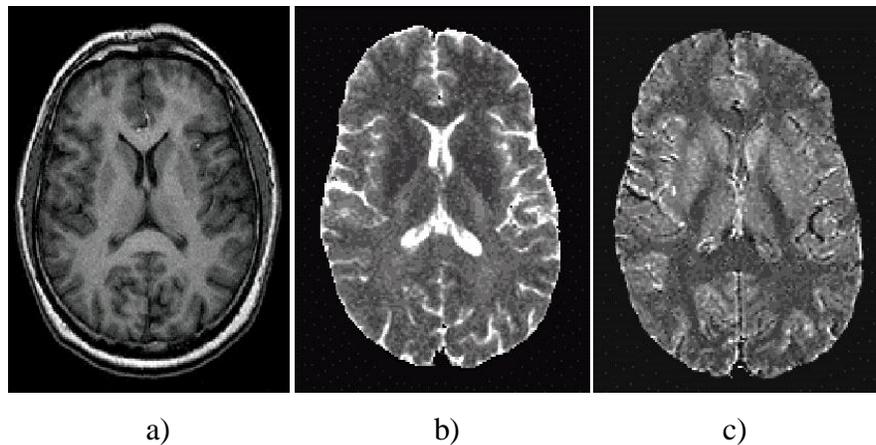


Figura 2.2. Imágenes de RMN adquiridas con distintas secuencias: a) Imagen en T1. b) Imagen en T2. c) Imagen en DP.

Dependiendo de la concentración de núcleos de H y del tipo de imagen analizada pueden observarse con mayor facilidad determinadas estructuras, en la tabla 2.1 se indican de manera general las tonalidades con las que se aprecian determinadas estructuras para imágenes de T1 y T2 [1].

	BLANCO	GRIS	NEGRO
T1	Grasa Hemorragia Subaguda Contraste Magnético Materia Blanca	Materia Gris Hígado Bazo Páncreas Riñón Músculos Lesiones con agua	Líquido Cefalorraquídeo Orina Quistes Tendones Vasos Aire Fibrosis
T2	Líquido Cefalorraquídeo Orina Quistes Tumores Riñón Bazo Agua libre	Materia Gris Grasa	Materia Blanca Páncreas Hígado Músculos Hueso Cortical Tendones Aire Vasos

Tabla 2.1. Apreciación en IRM dependientes de T1 y T2.

En la tabla 2.2, pueden observarse diferentes estructuras y patologías visibles dependientes de las condiciones de T1 y T2 [4].

	T2 corto	T2 largo
T1 corto	Grasa Hematoma agudo Algunos Melanomas	Hemorragias
T1 largo	Músculos	Tumores Edema Isquemia Desmielinización

Tabla 2.2. Patologías visibles dependientes de los parámetros dados a T1 y T2.

Para mejorar la calidad de las IRM se utilizan *Medios de Contraste* cuyo objetivo es aumentar la sensibilidad y la especificidad en la detección de patologías, así como diferenciar zonas anatómicas normales que pudieran simular patologías. Los contrastes más utilizados son los *Paramagnéticos* que pueden administrarse por dos vías: vía oral (que se utilizan para rellenar el tubo digestivo, técnica prácticamente en desuso) y vía intravenosa, aunque se empieza a utilizar la vía linfática. El principal contraste paramagnético utilizado es el *Gadolinio Dietilentriamina pentacético* (Gd-DTPA), que tiene la propiedad de acortar a T1 y acortar lo menos posible a T2 en el medio a donde accede realizando su señal [4].

2.1.6 Ventajas e Inconvenientes de la IRM.

La IRM tiene ventajas muy importantes sobre otras técnicas de diagnóstico por imagen empleadas en la actualidad:

- Mejor contraste entre tejidos suaves
- No utiliza radiaciones ionizantes
- Imágenes multiplanares directas
- Sin artefactos derivados del aire o los huesos
- Medidas de flujos directas

La IRM no se basa en un sólo parámetro como el *coeficiente de atenuación de rayos X*, sino en tres parámetros independientes T1, T2 y densidad *spin* o densidad protónica (DS o DP), además de varios parámetros secundarios. Esto es importante ya que los parámetros de IRM varían considerablemente de un tejido a otro, la *densidad protónica* y el *tiempo de relajación* T1 entre tejidos difiere un 20-30%, y el *tiempo de relajación* T2 difiere en un 40% entre tejidos, mientras que el *coeficiente de absorción de rayos X* sólo varía en 1% entre distintos tejidos. Debido a esto, la IRM tiene una excelente resolución de bajo contraste, lo cual es la principal ventaja de esta técnica.

Por otra parte, la IRM no emplea radiaciones ionizantes. La imagen se obtiene mediante campos magnéticos y RF, con lo que se evitan los riesgos pequeños que acompañan a las dosis bajas de radiación administradas en TAC o en los estudios de Rx convencionales.

Una ventaja más es que la región anatómica a explorar no está delimitada, como sucede en la TAC, sino que puede ser controlada electrónicamente, ello permite obtener planos transversales, coronales, sagitales y oblicuos. Se pueden obtener imágenes volumétricas sin modificar la posición del paciente. Además, la IRM ofrece otras ventajas significativas, no existen artefactos derivados del aire o de los huesos, como sucede en la TAC, y el flujo de la sangre se puede visualizar y cuantificar [1].

En cuanto a los inconvenientes de la técnica de IRM, ver tabla 2.3., se somete al paciente a tres efectos teóricamente perjudiciales: efecto calorífico de radiofrecuencia, campo magnético intenso, gradientes rápidamente cambiantes (que inducen en el organismo campos eléctricos). Sin embargo, se han realizado muchos estudios acerca de estos riesgos potenciales de la RMN sin demostrar hasta el momento alteraciones biológicas perjudiciales. No se han observado cambios en la temperatura corporal interna, aunque la superficial a nivel de la piel puede aumentar hasta 3 °C. La exploración por RMN aunque se considera exenta de riesgos para la salud (por sí misma no lesiona los tejidos biológicos), por precaución, se recomienda no aplicarla en mujeres durante el primer trimestre de embarazo, ya que se desconoce el efecto que pueda tener sobre el feto la acción de un campo magnético tan potente [1].

Existen, contraindicaciones absolutas para el estudio de RMN, producto de los efectos del campo magnético sobre prótesis o implantes con contenido metálico o magnético. En este sentido, las corrientes inducidas en objetos metálicos implantados pueden tener un efecto calórico local, aunque no ha sido demostrado efecto significativo alguno.

En el caso de pacientes cardiopatas es importante evitar que aquellos portadores de marcapasos o desfibriladores implantables sean sometidos a la acción del campo magnético. Para las válvulas cardíacas, la mayoría de éstas no suelen ser ferromagnéticas y el campo magnético no tiene efecto en su funcionamiento (a excepción del modelo Starr-Edwards serie pre-6000 con elevado contenido ferromagnético).

Como el campo magnético ejerce una fuerza de atracción sobre los objetos ferromagnéticos, el mayor riesgo se encuentra en los objetos móviles cercanos al imán, los cuales pueden convertirse en proyectiles, sobre todo en campos magnéticos altos [1].

SITUACIONES MAS FRECUENTES EN LAS CUALES ESTÁ CONTRAINDICADO UN ESTUDIO DE RMN
* Pacientes que utilizan algún equipo ferromagnético para el mantenimiento de la vida (marcapaso, desfibrilador implantable o neuroestimulador), debido a que el gradiente rápido del campo magnético podría inducir una corriente en los sistemas eléctricos de esos equipos
* Clips ferromagnéticos intracraneales, ya que pueden movilizarse
* Implantes o cuerpos extraños metálicos intraoculares
* Fragmento metálico (proyectil, metralla) cercano a estructura vital
* Implante coclear o audífono
* Prótesis valvular mitral Starr-Edward modelo 6000 o anteriores
* Claustrofobia
* Durante el primer trimestre de embarazo
* Paciente instrumentalizado (catéteres de termodilución, pulsoxímetros, cables y electrodos estándar de ECG).

Tabla 2.3. Contraindicaciones para la práctica de un estudio por RMN.

Como se ha visto, la calidad de las imágenes obtenidas por la RMN guarda una estrecha relación con diferentes parámetros utilizados en la técnica durante la adquisición y con

situaciones no controlables que son inherentes al proceso (por ejemplo la variación en la homogeneidad del campo magnético por el tipo de imán o por la forma del objeto bajo análisis), por lo que a menudo se presentan diferentes artefactos que afectan los resultados, en el siguiente capítulo se analizarán los artefactos más comunes, así como las principales dificultades que se presentan en IRM para lograr segmentaciones útiles.

CAPÍTULO 3

MARCO TEÓRICO SOBRE SEGMENTACIÓN E INHOMOGENEIDADES DE CAMPO EN IRM

3.1. DIFICULTADES PARA LA SEGMENTACIÓN DE IRM.

La segmentación es uno de los pasos esenciales para aprovechar al máximo todas las aplicaciones y ventajas de las imágenes de Resonancia Magnética, sin embargo, como en todos los sistemas de generación de imágenes se presentan diferentes problemas para lograr una segmentación útil, en este capítulo se describen las principales dificultades y se hace una descripción del estado del arte referente a la segmentación en IRM.

3.1.1. Artefactos.

En la técnica de IRM se pueden generar artefactos que deterioran o alteran la imagen. Para una mejor presentación de este capítulo, se ha dispuesto organizar una galería de artefactos de IRM en el Apéndice A.

En la figura A.1.a, se observa una imagen de resonancia magnética real como referencia obtenida lo más libre de artefactos posible.

- **Artefacto por Audio-Frecuencia**

Como puede apreciarse en la figura A.1.b, la imagen muestra un problema con audio frecuencia (en este caso, a la frecuencia de 60 Hz de la línea de alimentación principal). Este problema ocasiona la modulación de la señal de RMN como una señal de audio. En la imagen se aprecian como una especie de fantasmas en forma de copias tenues de la imagen real desplazadas a lo largo de ésta. Este problema puede disminuirse utilizando una técnica de sincronización con la línea de corriente alterna [5].

- **Artefacto por Formación de Arcos – Conexiones Seltas (*Arcing - Loose Connections*)**

Las imágenes c y d en la figura A.1., muestran las alteraciones intermitentes de los datos que típicamente se deben a problemas eléctricos. En la imagen a la izquierda, pueden observarse la generación de bandas y además se han modificado unos cuantos puntos de los datos, como podría ocurrir si un transitorio eléctrico (por ejemplo una descarga estática, a veces llamada “*arco*”) ocurriera durante la digitalización de un eco. También puede apreciarse el elevado nivel del fondo. En la imagen a la derecha, se observan bandas más suavizadas y una pequeña banda como si la computadora tuviera una pérdida de datos, o se tuviera un cable suelto momentáneamente (por unos milisegundos) que evitará la digitalización de la señal recibida (comúnmente a esto se le llama “*dropout*”). En la segunda imagen pueden apreciarse similitudes y diferencias con el caso del artefacto por movimiento [5].

- **Artefactos por Corrimiento Químico**

Estos artefactos se deben a la pequeña diferencia de *frecuencia de precesión* del hidrógeno ligado al agua o a la grasa. Se manifiestan como una banda hiper-intensa y otra hipo-intensa en las interfases agua-grasa. Como es un artefacto relacionado con la *frecuencia de precesión*, se produce en la dirección de codificación de frecuencia, ver figura A.2.a. Estos artefactos aumentan con los campos magnéticos intensos y técnicas muy potenciadas en T2. Se logran disminuir modificando la intensidad del gradiente o ancho de banda [4,5].

- **Artefacto por Recorte – Desbordamiento del Convertidor Analógico Digital**
(*Clipping - ADC overflow*)

Cuando la ganancia recibida se incrementa (por ejemplo 20 dB) de modo que el nivel de la señal es más grande que el valor del convertidor analógico-digital, se observa que la imagen no puede ser representada adecuadamente. Este efecto es llamado “recorte” (*clipping*) y puede apreciarse en la figura A.2.b [5].

- **Artefacto por Desplazamiento de la Corriente Directa (*DC Offset*)**

Si se aprecia detenidamente el píxel al centro de la figura A.2.c, puede apreciarse que es más brillante u oscuro que aquellos que le rodean, esto es la transformada de Fourier de una constante. Es muy común observar este artefacto debido a que las variaciones de temperatura a menudo ocasionan que los amplificadores acoplados en corriente directa tengan salidas diferentes de cero para entradas de cero. Normalmente esto se compensa en el software aplicando un corrector de línea base o de corriente directa, antes de realizar la transformada de Fourier [5].

- **Artefacto por Cuantificación del Digitalizador – Rango Dinámico Bajo (*Digitizer Quantization - Low Dynamic Range*)**

El conjunto original de datos fue generado con una precisión de digitalización de 16 bits de resolución (+32767 a -32768). Para generar una muestra de este artefacto se pusieron a cero los 8 bits menos significativos para obtener una resolución de 8 bits (+127 a -128) y los resultados pueden observarse en la figura A.2.d [5].

- **Artefactos de Gibbs**

Se observan como bandas de aumento y disminución de la intensidad de la señal, paralelas a las interfaces entre tejidos de intensidades distintas (como la cortical ósea y la grasa pericraneal) situados en la dirección de fase, ver figura A.2.e. Esto se debe a un error en la lectura

de la señal por adquirir un número insuficiente de datos. Se corrigen empleando más tiempo en la adquisición de la imagen [5].

- **Artefacto de Moire – Interferencia de Eco (*Echo Interference*)**

Este artefacto se presenta cuando los ecos de diferentes modos de excitación ocurren dentro de la ventana de adquisición, pero con diferencias ligeras en los tiempos de eco. Este artefacto se aprecia como el patrón de una pantalla sobrepuesta conocida como “*moire*”, en la figura A.2.f, puede apreciarse más fácilmente en la parte baja de la imagen. Este artefacto es sensible a las bobinas de compensación [5].

- **Artefactos Ferromagnéticos**

Estos generan una distorsión espacial de la imagen y una pérdida de señal al modificar localmente el campo magnético. Pueden producirse por objetos metálicos externos o internos. Los externos pueden ser cinturones, botones, cremalleras, horquillas, cosméticos (pintura de ojos), etc., y se evitan haciendo que el paciente se desprenda de ellos y se desmaquille los ojos. Los internos pueden ser clips, suturas metálicas, prótesis, osteosíntesis, etc., pueden disminuirse mediante técnicas de Espín-Eco (*Spin-Echo*) [5].

- **Artefactos por Envolvimiento – Plegamiento Trasero (*Wrap Around – Back Folding*)**

Este artefacto consiste en la superposición de un extremo de la zona estudiada en el extremo opuesto. Esto sucede cuando el diámetro del objeto estudiado es mayor que el *Campo de Vista* (*Field of View, FOV*) utilizado, al obtenerse información redundante externa. Se produce en la dirección de codificación de fase. Para evitar este artefacto se aumenta el *FOV*, se modifica la codificación de fase y se impide que las señales de los objetos externos al área bajo estudio lleguen a la bobina [5].

- **Artefactos por Movimiento**

Uno de los problemas para la IRM es el movimiento, ya que el estudio con esta técnica es largo. Los movimientos pueden ser voluntarios o involuntarios y éstos últimos pueden ser rítmicos (cardíacos, respiración, pulso) o no rítmicos (movimiento intestinal). Los movimientos pueden ser mitigados por control del propio paciente o por mecanismos de sincronización. Para disminuir los artefactos de movimientos cardio-respiratorios puede efectuarse una técnica de sincronismo, obteniendo los datos siempre en el mismo momento del ciclo respiratorio y/o cardíaco. En el sincronismo cardíaco se utilizan técnicas asociadas al monitoreo del electrocardiograma, para así acoplar las secuencias de pulso a los espacios entre los complejos QRS. Para disminuir el movimiento intestinal pueden administrarse fármacos inhibidores de la motilidad, como los anticolinérgicos. Para disminuir el efecto del movimiento respiratorio se pueden realizar estudios en apnea con técnicas RMN rápidas o también estudios con sincronización respiratoria. En los artefactos por movimiento de flujo de estructuras vasculares, se puede cambiar la dirección de preparación para cambiar la zona hacia la que se produce el artefacto. En la figura A.3.a, se aprecia el efecto de un artefacto por movimiento [1,5].

- **Artefacto por Fantasma de Cuadratura (*Quadrature Ghost*)**

Para generar este artefacto se modificó ligeramente la ganancia del canal receptor antes de la adquisición (también los errores de fase entre los dos canales de cuadratura pueden causar el mismo efecto). En la figura A.3.b, puede apreciarse que el “*fantasma*” se encuentra desplazado diagonalmente a través del centro [5].

- **Artefacto por Interferencia de Radio Frecuencia (*RFI*)**

En las imágenes c y d de la figura A.3., pueden apreciarse dos imágenes con una señal de interferencia a 170.000000MHz, la frecuencia central de la imagen se encuentra en 170.029470MHz. La imagen de la izquierda tiene un ancho espectral de 50kHz, de esta manera la interferencia es 4470Hz por debajo del borde espectral de baja frecuencia de la

imagen y está atenuada y mezclada con la parte de alta frecuencia de la imagen. La imagen de la derecha tiene un ancho espectral de 100kHz, por lo tanto este artefacto se encuentra dentro del ancho de banda del receptor y es mucho más intenso [5].

- **Artefacto por Dato Atrancado (*Stuck Bit*)**

Con el hardware moderno disponible hoy en día este artefacto no es común, pero no es imposible que suceda. Puede ocurrir si existen localidades de memoria dañadas o algún falso contacto en el bus de datos. En la figura A.3.e, se aprecia este artefacto y también puede observarse que guarda cierta similitud con el artefacto por Cuantificación del Digitalizador por tratarse de una alteración en algún bit de la información [5].

- **Artefactos por Ruido Aleatorio**

En cualquier sistema electrónico existen diversas fuentes de ruido, incluyendo *Ruido de Johnson* o *Ruido Térmico*, etc. Estos ruidos pueden ser distinguibles en mayor o menor grado y su apariencia a menudo se describe como “*granulosa*” o como una baja relación señal ruido (*low signal to noise Ratio*), ver figura A.3.f [5].

Para el caso de las IRM el ruido principalmente tiene una distribución de Rician y no está correlacionado entre voxels. El nivel de ruido generalmente se encuentra entre 2 y 5% del nivel de intensidad máximo para un scanner moderno [6].

- **Artefacto por Desajuste de Compensación (*Shimming Missadjusted*)**

El efecto de las corrientes en las bobinas de compensación tiene una gran influencia en la técnica de adquisición de las imágenes. Las imágenes a y c de la figura A.4, muestran dos ejemplos de estos efectos. La imagen A.4.a se adquirió con una secuencia *spin-echo* y un error de ZXY de 1.86 A, la única evidencia del artefacto por desajuste de compensación es una diminuta distorsión geométrica menor a 2 píxeles (vista a lo largo del eje Z), la distorsión más extendida que se aprecia depende de la intensidad del gradiente de lectura, de hecho, en la

imagen A.4.b se muestra la diferencia entre la imagen distorsionada y la imagen de referencia. La imagen A.4.c se adquirió con una secuencia *echo-gradient* utilizando parámetros de excitación muy similares a los anteriores, pero con una tercera parte del error en la corriente (0.61 A), de este modo la componente en Z del error de compensación produce una tremenda pérdida de la señal.

- **Artefacto por Susceptibilidad**

La figura A.4.d muestra un artefacto de este tipo, para generar el artefacto se colocó una moneda muy cerca al objeto de prueba circular (*fantoma*), la moneda colocada es muy pequeña y pobremente conductiva como para originar una inhomogeneidad muy grande. Sin embargo hace que el campo magnético se distorsione de una manera similar al error de desajuste de compensación. Si se observa con cuidado se aprecia una pequeña distorsión en el lado izquierdo del objeto de prueba. Una característica de este tipo de distorsión es que se ve un efecto de mancha-brillosa/mancha-oscura, en este caso el borde izquierdo del objeto de prueba tiene una porción oscura y justo debajo un área más brillante. Este efecto difiere de una *inhomogeneidad de campo* en que esta última parece conservar un gradiente suavizado. Finalmente, si la moneda se aproxima más al objeto de prueba los efectos pueden ser muy severos.

- **Artefacto por Inhomogeneidad de Campo Magnético – Artefacto de Sombreado – Campo de Ganancia – Campo de Sesgo (*Magnetic Field Inhomogeneity, Shading Artifact o Bias Field*)**

Este artefacto en particular es el tema principal en el trabajo que aquí se presenta. Para generar el artefacto del ejemplo mostrado en la figura A.4.e, se colocó una lámina cuadrada de 2 pulgadas de lado hecha de cobre en el lado izquierdo del objeto de prueba para alterar el campo magnético B_0 . El sombreado (debido a las corrientes de Eddy en la lámina de cobre) altera a la imagen casi como una pérdida de señal. Este efecto como de una iluminación desnivelada ocurre con algunos tipos de bobinas de radiofrecuencia, particularmente (pero no limitado) con bobinas superficiales.

Se ha demostrado recientemente que la mayor contribución al *Campo de Sesgo* o *Campo de ganancia* (*Bias Field*) observado en las imágenes de RMN es la inhomogeneidad del campo electromagnético el cual depende, entre otros factores, de la magnetización de la materia bajo estudio (dependiendo de su composición y forma) [7], así como del tipo de bobinas de radiofrecuencia, de las secuencias de adquisición o de la estabilidad y uniformidad del campo magnético generado por el imán y ello a su vez puede depender del tipo de imán y del proceso de fabricación del mismo [3,4].

3.1.2. Efecto del Volumen Parcial.

Aunque en sentido estricto este efecto no es un artefacto, si es importante su consideración. Este efecto es producto de la resolución finita del proceso de adquisición de imágenes. Los voxels (que representan típicamente un volumen de 1mm^3) pueden contener una mezcla de diferentes tipos de tejidos que contribuyen a la señal medida. No siempre es práctico incrementar la resolución por el incremento en el tiempo de adquisición y el incremento del ruido, una posible solución es intentar recuperar las proporciones de mezcla en el método de segmentación [6].

3.1.3. Resultados Operador-Dependientes.

Las imágenes de Resonancia Magnética proporcionan abundante información de las estructuras anatómicas. Entre las aplicaciones médicas de las IRM se encuentran:

- Estudios clínicos.
- Estudios patológicos cuantitativos.
- La obtención de un atlas anatómico computarizado.
- Guía pre-operatoria e intra-operatoria para intervenciones quirúrgicas.

- Como una referencia anatómica para modalidades funcionales como, la Tomografía por Emisión de Positrones (PET), Tomografía Computada por Emisión de Fotón Simple y MRI funcional.

Varias de estas aplicaciones avanzadas utilizan el contenido morfológico de las imágenes de RMN y, a menudo, requieren la segmentación del volumen de imágenes registrado en diferentes tipos de tejidos.

Muchos de los equipos que actualmente realizan esta tarea se basan en métodos que requieren la intervención de un operador para proporcionar diversos parámetros acerca de las clases a fin de obtener segmentaciones útiles, más aún, otros sistemas necesitan un operador que realice la segmentación de manera manual.

Lo anterior conduce a resultados que son dependientes del operador, no son reproducibles y además pueden mostrar diferencias entre apreciaciones de diversos sujetos (información subjetiva) [6].

También las condiciones de operación y el estado del equipo de RMN frecuentemente afectan las intensidades observadas, originando importantes inhomogeneidades de intensidad inter-scan.

3.1.4. Cantidad de Información a Analizar.

Entre las ventajas de las imágenes de Resonancia Magnética se pueden mencionar: alta resolución espacial, discriminación excelente de tejidos suaves y que el paciente puede ser sometido a varios estudios de IRM a diferencia de técnicas de TAC u otras que requieren períodos determinados entre estudios.

Sin embargo, por las múltiples aplicaciones avanzadas de la IRM mencionadas anteriormente y por muchas de sus ventajas, la técnica de IRM ha cobrado tanta utilidad que actualmente se

constituye como una importante herramienta médica en muchos hospitales, clínicas y centros de diagnóstico.

Por esto mismo, una dificultad más que agregar al problema de la segmentación de imágenes de IRM, es el gran volumen de información que se debe analizar en los centros médicos. Las segmentaciones realizadas con métodos manuales o inicializaciones semejantes de algoritmos no permiten cubrir la necesidad de respuesta en tiempo ante una demanda cada vez más grande para ofrecer resultados que deben tenerse de manera oportuna.

3.2. INHOMOGENEIDADES DE CAMPO MAGNÉTICO Y SU MODELACIÓN MATEMÁTICA.

Al igual que cualquier proceso que busca obtener datos de alguna variable fisiológica, la obtención de las imágenes de RMN no está exenta de presentar información no deseable.

Estos ruidos tienen diferentes génesis y características, todos ellos dificultan la labor de la segmentación. Sin embargo, una de las principales dificultades que cualquier método o algoritmo de segmentación de IRM debe enfrentar es la inhomogeneidad de campo magnético presente en las imágenes y el ruido aditivo a las mismas, que se observan a lo largo de todos los cortes de un estudio completo de IRM. Vencer esta dificultad implica el modelado y corrección de las inhomogeneidades de campo magnético en conjunto con el ruido aditivo a fin de restaurar las intensidades en la escena que se desea segmentar en clases.

La inhomogeneidad del campo magnético puede visualizarse en las intensidades de la imagen como un campo de sesgo o de ganancia multiplicativo (*Bias Field*), que produce distorsiones geométricas y de intensidad.

En un modelo de intensidades para las imágenes, la formulación matemática para los efectos del campo de ganancia puede asumirse como sigue [8]:

$$Y = (X * G) + R \quad (3.1)$$

Donde,

Y : Imagen observada.

X : Imagen con las intensidades verdaderas de los tejidos (ideal).

G : Campo de ganancia (*Bias Field*).

R : Ruido aditivo del sistema.

A pesar del aspecto aparentemente uniforme de las imágenes de RMN, las inhomogeneidades a menudo alteran los métodos de segmentación basados en la intensidad. En la práctica, las inhomogeneidades de intensidad espaciales resultantes tienen la suficiente magnitud para causar que las distribuciones de intensidades de señal asociadas a las clases de diferentes tejidos se traslapen significativamente.

3.3. REVISIÓN DEL ESTADO DEL ARTE.

En este trabajo se propone un método que considera la corrección del campo de ganancia y la segmentación al mismo tiempo, por lo que es necesario revisar el estado del arte de ambos procesos.

3.3.1. Corrección del Campo Magnético con las Bobinas de Compensación.

Como es sabido, el imán genera un campo magnético constante para alinear los núcleos de los átomos del paciente. Si este campo presenta inhomogeneidades, puede ser modificado por

medio de las *bobinas de compensación* (conocidas como *shimming coils*) y por placas de hierro dispuestas dentro y fuera del cilindro del imán a fin de maximizar la homogeneidad del campo [3,4]. Entonces el primer proceso de corrección del campo de ganancia se hace desde este punto.

Sin embargo, las técnicas para homogeneizar el campo magnético mediante las bobinas de compensación no siempre pueden resolver el problema [8]. Ya que en ocasiones sólo lo aminora, y esas imágenes sirven para ciertos propósitos donde los médicos y radiólogos pueden interpretarlas con razonable justificación, pero no son útiles para fines de segmentación en la obtención de un atlas anatómico o para una guía pre-intra operatoria en intervenciones quirúrgicas. En otras ocasiones no se logran buenos resultados y las imágenes obtenidas carecen de cualquier utilidad.

Una vez considerado el tiempo invertido que se necesita para ajustar las corrientes de las bobinas de compensación (proceso de compensación denominado *shimming*) en un equipo nuevo de RMN, además de éste, debe considerarse la continua necesidad de estar reajustando dichos valores para tratar de asegurar un campo magnético uniforme [9,10]. El tiempo invertido puede variar enormemente de acuerdo a los propósitos.

El proceso de compensación (siempre necesario) a veces no elimina satisfactoriamente la inhomogeneidad del campo, por lo que es necesario el enfoque hacia el procesamiento de datos post-adquisición.

3.3.2. Métodos de Segmentación de IRM.

Una revisión general de los métodos de segmentación de imágenes médicas puede consultarse en [11, 12, 13, 14].

Existen algunos métodos de segmentación que están basados en la identificación de bordes, pero, tienen serios problemas con estructuras anatómicas que presentan curvas muy

pronunciadas y complicadas de distinguirse entre dos o más tipos de tejidos (como por ejemplo las uniones entre materia blanca y materia gris), que son difíciles de recuperar en imágenes de resolución finita.

Cualquier traslape de las distribuciones de clases en el espacio de características conduce a una determinada cantidad de errores de clasificación, generalmente en las uniones entre tejidos. Algunas soluciones para reducir este problema consisten en operaciones morfológicas post-clasificación y en clasificadores contextuales tales como procedimientos de optimización usando modelos de *campos aleatorios de Markov* (*MRF* por sus siglas en inglés) [15, 16, 17]. Otros autores han propuesto un método de *conectividad difusa* (conocido como *Fuzzy Connectedness*) [18], el cual mide la fuerza de conexión entre dos píxeles como una función de su localización espacial relativa y la similitud de intensidad entre ellos.

Niessen [19], recientemente propuso un método que combina la información de intensidad y la información de bordes en un enfoque multi-escalar, pero requiere algunas intervenciones del usuario y no es completamente automático.

Otro enfoque típicamente utilizado para segmentar estructuras anatómicas específicas es empleando información de “*alto nivel*” como por ejemplo modelos deformables de atlas o conocimiento a priori de las formas. De cualquier modo tales métodos tienen dificultades con anatomías anormales o con estructuras que son altamente variables. Warfield [20] propuso un método interesante que combina la clasificación y los modelos deformables. Este método tiene limitaciones de clasificación que se enfocan en la restricción de la propia clasificación contra la plantilla anatómica generada.

Por otra parte, el algoritmo de *Maximización de la Esperanza* mejor conocido como algoritmo *EM* por sus siglas en inglés (*Expectation Maximization*) es un esquema muy popular aplicado al problema de la segmentación. La técnica fue originalmente propuesta por Wells [21] para IRM, ha sido mejorada por otros investigadores [22, 23, 24, 25]. Este método entrelaza la estimación del campo de ganancia para su corrección y la segmentación en un algoritmo iterativo. Sin embargo, el método propuesto por Wells es muy sensible a los valores iniciales y

a los *valores fuera de rango* (conocidos en inglés como *outliers*) que pueden desviar la estimación del campo de ganancia, de hecho, las implementaciones basadas en la propuesta de Wells necesitan ser alimentadas con los parámetros de las clases, los cuales generalmente se obtienen manualmente seleccionando píxeles representativos a criterio del operador. Otras modificaciones a la implementación típica del método de Wells, fueron propuestas por Van Leemput [24, 25] y Ashburner [26, 27] consistiendo en volver a estimar los parámetros de las clases en cada iteración, pero ambos métodos necesitan valores iniciales y tienen una alta sensibilidad a ellos.

3.3.3. Método de Restauración-Segmentación.

El método descrito por Wells [21], llamado “*Segmentación Adaptiva*”, es un método de clasificación basado en el modelo de intensidades de la imagen, el cual emplea conocimiento de las propiedades de los tejidos y de las inhomogeneidades de intensidad, para corregir y segmentar las imágenes de RMN. El método de Wells hace uso del algoritmo de Maximización de la Esperanza para lograr una segmentación de los tipos de tejidos, así como una mejor visualización de los datos de IRM. A continuación se describe el método propuesto por Wells.

Cabe mencionar que a diferencia de la presente tesis, el trabajo descrito por Wells, no considera al ruido aditivo presente en la imagen del modelo para el campo de ganancia descrito en la ecuación 3.1, sino que sólo contempla al campo de ganancia que multiplica a la imagen con las intensidades verdaderas.

Asumir lo anterior puede ser válido siempre que el ruido aditivo no sea significativo (lo cual es una condición desconocida). Sin embargo, asumir las imágenes como libres de ruido aditivo (o con un nivel despreciable) puede ayudar a simplificar la tarea de restauración de la imagen ya que el campo de ganancia puede separarse de las intensidades de imagen verdaderas mediante una transformación logarítmica, como lo describe Wells [21]:

$$y = \ln(Y) = \ln(X*G)$$

$$y = x + b \quad (3.2)$$

Donde,

y : Imagen logaritmo de las intensidades observadas (por simplicidad referida como la imagen).

x : Imagen logaritmo de las intensidades verdaderas.

b : Imagen logaritmo correspondiente al campo de ganancia (por simplicidad referida como el campo de ganancia).

Y : Intensidades observadas.

X : Intensidades verdaderas de los tejidos.

G : Campo de Ganancia.

Lo cual permite tratar con mayor simplicidad a la imagen verdadera y al campo de ganancia como un artefacto aditivo. Si se tiene conocimiento del campo de ganancia, entonces la restauración se puede realizar de manera directa y se puede estimar la distribución de intensidad de los tejidos para segmentar la imagen bajo el criterio de Bayes. Sin embargo, el campo de ganancia es desconocido y debe inferirse de la imagen observada. Estas consideraciones proporcionan la perspectiva básica del método de Restauración-Segmentación, que de manera general se puede establecer como sigue [28]: dado un campo de ganancia inicial b_o ,

1. Se calcula un estimado de la imagen restaurada $x_i = y - b_i$
2. Se estima la distribución de intensidad $f_i(x_i)$ de x_i .
3. Se obtiene un nuevo estimado del campo de ganancia b_{i+1} basado en $f_i(x_i)$
4. Se repite desde 1 hasta alcanzar el criterio de paro.

El cálculo del nuevo estimado del campo de ganancia debe incorporar todo el conocimiento estadístico de la distribución de clases que se encuentra en $f_i(x_i)$. Ésta distribución se puede modelar como una mezcla de densidades condicionales de clase como:

$$f_i(x_i) = \sum_{c=1}^M p_c f_{c,i}(x_i|c) \quad (3.3)$$

Donde,

$f_{c,i}(x_i|c)$: Probabilidad condicional de observar la intensidad x_i dada la clase de tejido c .

p_c : Proporciones de mezcla.

M : Número de clases de tejido.

La segmentación de la imagen se puede realizar basándose en el modelo de mezcla obteniendo las probabilidades a posteriori para cada pixel:

$$f_i(c|x_i) = \frac{p_c f_{c,i}(x_i|c)}{\sum_{c=1}^M p_c f_{c,i}(x_i|c)} \quad (3.4)$$

Asignando cada pixel como perteneciente a la clase para la cual $f_i(c|x_i)$ es máxima. Más aún, los estimados de las probabilidades posteriores se pueden utilizar para definir un estimado lineal del campo de ganancia como:

$$b_{i+1} = F_{PB} * [y - \sum_{c=1}^M E_c f_i(c|x_i)] \quad (3.5)$$

Donde,

E_c : Valor esperado de la clase c .

F_{PB} : Respuesta al impulso en 2-D de un filtro pasa-bajas y $*$ denota la convolución en 2-D.

La sumatoria dentro de la ecuación del estimado del campo de ganancia es una aproximación a la imagen x_i basada únicamente en la evidencia estadística recopilada en el modelo de mezcla, de aquí, que la diferencia de ésta aproximación con la imagen observada es un estimado “*crudo*” del campo de ganancia que debe ser filtrado a través de un filtro pasa-bajas para recuperar la suavidad característica de este tipo de artefacto.

Para realizar el procedimiento de Restauración-Segmentación se requiere estimar $f_i(x_i)$. Asumiendo que el modelo de mezcla está compuesto por condicionales gaussianas (una por cada clase de tejido) con media $\mu_{c,i}$ y varianza $\sigma_{c,i}^2$:

$$f_{c,i}(x_i|c) = \frac{1}{\sqrt{2\pi\sigma_{c,i}^2}} e^{-\frac{(x_i-\mu_{c,i})^2}{2\sigma_{c,i}^2}} \quad (3.6)$$

Y el problema de estimación de parámetros se resuelve con un enfoque de *Máxima Verosimilitud* (conocido en inglés como *Maximum Likelihood* o *ML*) a través del algoritmo de Maximización de la Esperanza que aplicado a la ecuación (3.3) se tiene:

$$\hat{\mu}_{c,i+1} = \frac{\sum_{j=1}^N f_{c,i}(x_i(j))x_i(j)}{\sum_{j=1}^N f_{c,i}(x_i(j))} \quad (3.7)$$

$$\widehat{\sigma}_{c,i+1}^2 = \frac{\sum_{j=1}^N f_{c,i}(x_i(j))(x_i(j) - \hat{\mu}_{c,i+1})^2}{\sum_{j=1}^N f_{c,i}(x_i(j))} \quad (3.8)$$

$$\hat{p}_{c,i+1} = \frac{1}{N} \sum_{j=1}^N f_{c,i}(x_i(j)) \quad (3.9)$$

Donde,

N : Es el número total de píxeles en la imagen.

j : Es el índice usado para denotar cada uno de los N píxeles en la imagen.

$\hat{\mu}_{c,i}$: Reemplaza a E_c en la ecuación (3.5).

Como un estimador de Máxima Verosimilitud iterativo, este método depende fuertemente de las condiciones iniciales y es muy sensible a los valores fuera de rango inducidos por el ruido.

De esta manera si se conocen las clases de los tejidos, entonces se puede estimar el campo de ganancia comparando las intensidades observadas contra las intensidades estimadas, construyendo un algoritmo iterativo que utiliza el conocimiento mutuo entre el campo de ganancia y la imagen estimada. Puede demostrarse que dicho algoritmo converge [21] en pocas iteraciones (típicamente 5 a 10). La figura 3.1 muestra de manera general el método de Restauración-Segmentación de Wells.

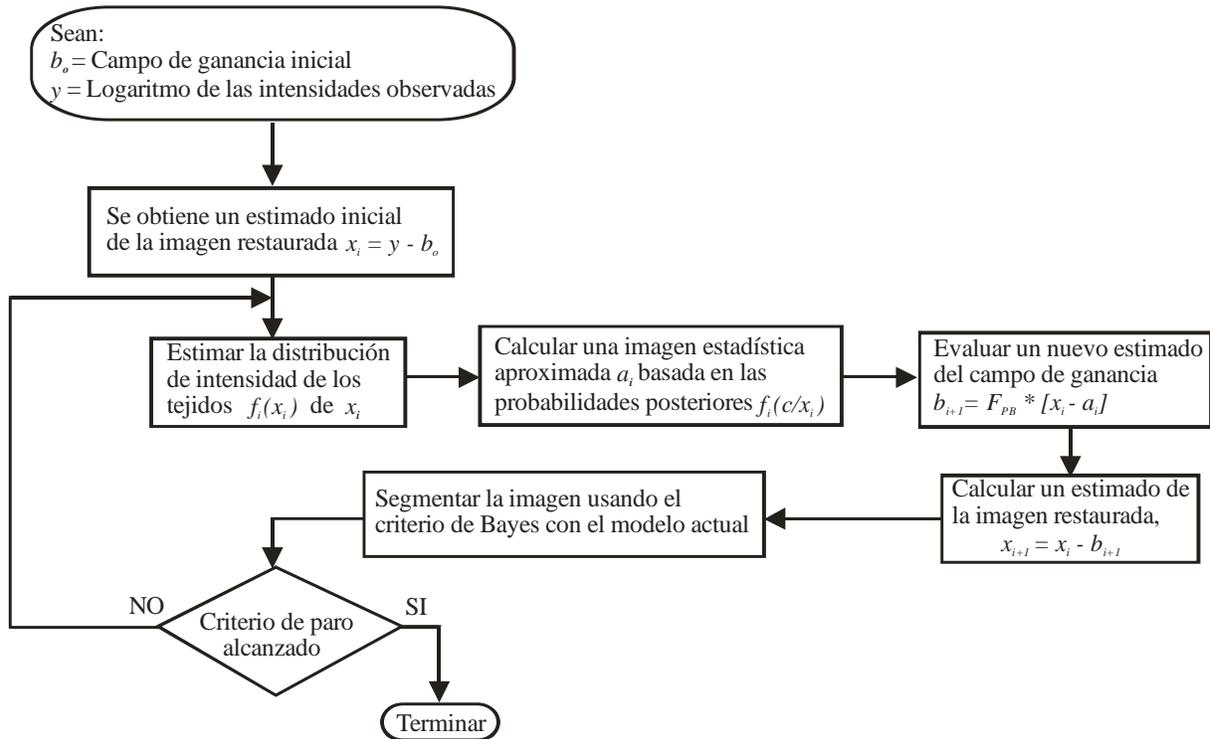


Figura 3.1. Método de Restauración-Segmentación Propuesto por Wells.

El método de Wells inicia a partir de la imagen logaritmo de las intensidades observadas y de un campo de ganancia inicial (por ejemplo inicializado en cero). Utiliza un enfoque bayesiano para estimar el nuevo campo de ganancia de la iteración actual.

3.3.4. Modalidades del Método de Restauración-Segmentación.

Como se mencionó anteriormente, el método de Restauración-Segmentación propuesto por Wells [21], ha sido modificado en su implementación por diferentes autores, por ejemplo, el grupo de trabajo del laboratorio de Neuroimagenología del Depto. de Ingeniería Eléctrica de la Universidad Autónoma Metropolitana Iztapalapa, han propuesto consideraciones para la mejora en la segmentación de imágenes de IRM y la estimación del campo de ganancia [28], que a continuación se describen:

- **MLRS**

Es el procedimiento de Restauración-Segmentación usando estimados de Máxima Verosimilitud por medio del algoritmo de Maximización de la Esperanza para obtener los parámetros del modelo, inicializado manualmente. A continuación en la figura 3.2, se muestra una segmentación obtenida a partir del método original propuesto por Wells.

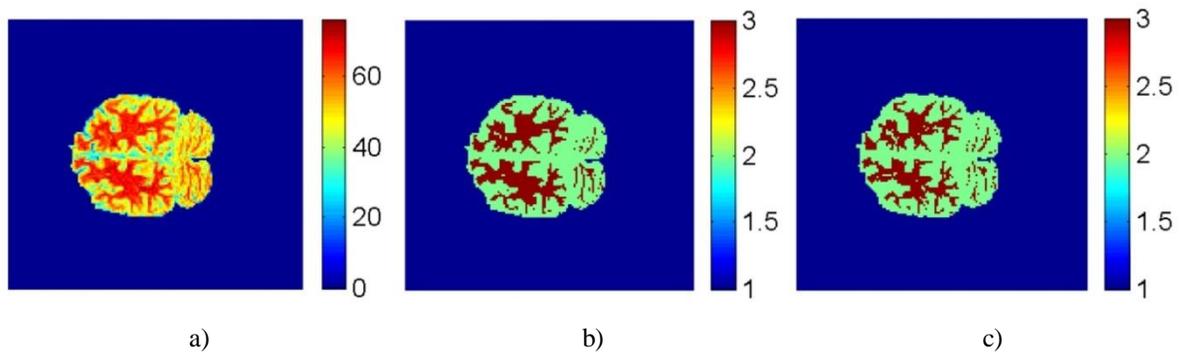


Figura 3.2. Resultados con el método de Restauración-Segmentación Propuesto por Wells.
a) Imagen original, b) Imagen segmentada por el médico, c) Imagen por modalidad MLRS.

- **AIRS**

Es el procedimiento de Restauración-Segmentación usando estimados Máxima Verosimilitud para obtener los parámetros del modelo, pero inicializado con la técnica de estimación de *Modas Realzadas* [28, 29, 30, 31], que se describirá en el siguiente capítulo. A continuación en la figura 3.3, se muestra una segmentación obtenida con la modalidad AIRS.

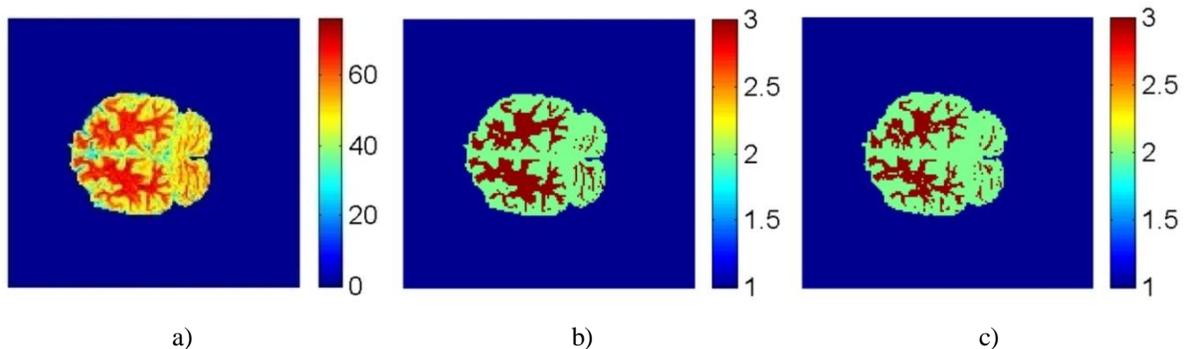


Figura 3.3. Resultados con el método de Restauración-Segmentación Propuesto por Wells.

a) Imagen original, b) Imagen segmentada por el médico, c) Imagen por modalidad AIRS.

- **MBRS**

Es el procedimiento de Restauración-Segmentación usando los estimados de *Modas Realzadas* [28, 29, 30, 31] para los parámetros del modelo en cada iteración. A continuación en la figura 3.4 se muestra una segmentación obtenida con la modalidad MBRS.

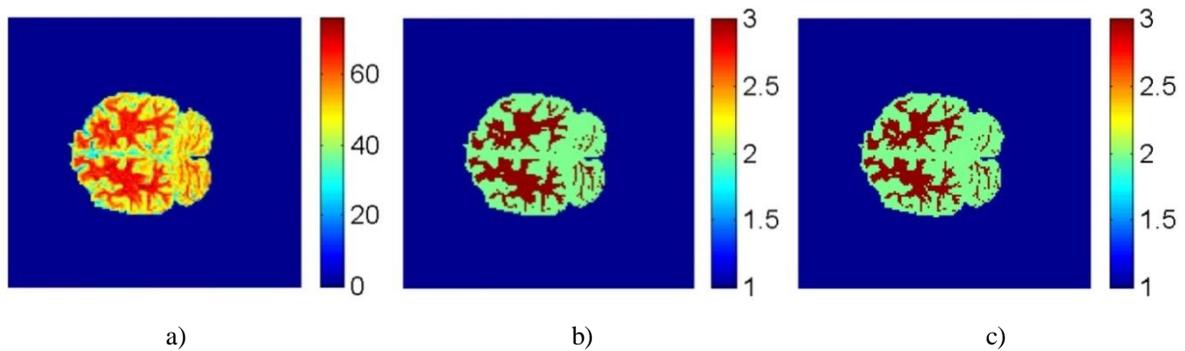


Figura 3.4. Resultados con el método de Restauración-Segmentación Propuesto por Wells.

a) Imagen original, b) Imagen segmentada por el médico, c) Imagen por modalidad MBRS.

En el caso del procedimiento de Restauración-Segmentación en la modalidad MLRS se asume que una vez analizado un grupo de imágenes, la información disponible es útil para construir un conjunto de condiciones iniciales para los siguientes análisis, si las condiciones técnicas del escáner también permanecen fijas, lo cual es una condición débil ya que en la práctica rara vez sucede lo anterior, incluso a pesar de intentar mantener los parámetros del escáner, estos cambiarán con el tiempo y el conjunto de condiciones iniciales se deberá revisar constantemente. Por otra parte, la naturaleza de las iteraciones del algoritmo de Maximización de la Esperanza usadas en el procedimiento MLRS es sensible a las condiciones iniciales y tiende a fallar cuando el análisis parte de condiciones iniciales que se asumen iguales para todas las imágenes [28].

Las modalidades AIRS y MBRS ayudan a disminuir los problemas antes mencionados ya que las condiciones iniciales se obtienen directamente de la imagen, una característica importante de estas modalidades de inicialización (y de todo el procedimiento en la modalidad MBRS) es

que no es necesario establecer a priori el número de clases en la segmentación, ya que la estimación de *Modas Realzadas* puede modificar dinámicamente el número de clases, el cambio en el número de clases no está determinado por algún medio manual o externo, sino por el resultado de los picos significativos en la distribución de modas, de esta manera el procedimiento MBRS se adapta a la imagen bajo análisis y puede incluso hallar otras clases de tejido presentes en la imagen [28].

En las tres modalidades el algoritmo de Restauración-Segmentación alcanzó la convergencia en alrededor de veinte iteraciones, en el caso de la modalidad MBRS pueden presentarse problemas de hallar demasiadas clases en las imágenes con mayor ruido y no se obtenga la segmentación esperada.

Una debilidad común a las tres modalidades es la transformación homomórfica realizada a la imagen que incrementa aún más la dificultad de encontrar los parámetros adecuados para el modelo de mezcla de gaussianas, ya que la porción de intensidades altas en la distribución se comprime debido a la transformación logarítmica y el algoritmo de Maximización de la Esperanza tiene problemas para diferenciar entre dos componentes muy cercanas en una mezcla gaussiana. Por lo anterior, el método que se presenta en esta tesis trabaja con el modelo multiplicativo del campo de ganancia sobre la imagen sin necesidad de la transformación logarítmica.

3.3.5. Limitaciones del Modelado Paramétrico.

Como el método de Wells asume una mezcla de gaussianas para modelar la distribución de probabilidad de la imagen, es necesario que los parámetros de la mezcla mencionada sean los apropiados (cercaos a los centroides de las clases principales) para lograr que el algoritmo obtenga una segmentación útil. En la figura 3.5, se observa una segmentación no aprovechable como consecuencia de una mala inicialización de los parámetros del modelo en el método de Wells [21].

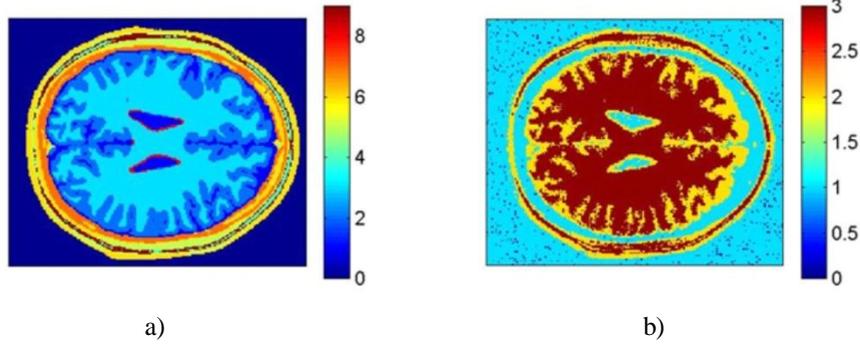


Figura 3.5. Resultados con el método de Restauración-Segmentación Propuesto por Wells: a) Imagen segmentada manualmente, b) Segmentación lograda con una mala inicialización de los parámetros del modelo..

3.3.6. Modelado No Paramétrico.

Se observa que el método de Restauración-Segmentación de Wells, ofrece buenos resultados si se trata la implementación con cuidado, vigilando varios aspectos.

Sin embargo, las principales deficiencias del método de Wells [21] recaen en las inicializaciones necesarias para el algoritmo de Maximización de la Esperanza (implícito en el método) y en el modelo de mezcla gaussiano asumido, que en la práctica puede no resultar lo más conveniente. Esta fuerte dependencia de las condiciones iniciales, puede eliminarse si el método de Wells es provisto con información de las clases extraída de la propia imagen [29], y si el modelo gaussiano es sustituido por técnicas no paramétricas las cuales no asumen un modelo específico. Estas consideraciones constituyen la aportación central de este trabajo.

De manera general, se puede describir un modelado no paramétrico usando *Ventanas de Parzen* [32], como sigue:

Sea $\{X_i\}_{i=1\dots N}$ un conjunto de N vectores en el espacio euclidiano R^d (de dimensión d), entonces el estimado de la densidad de probabilidad para el conjunto de datos se define como:

$$\hat{f}(x) = \frac{1}{Nh^d} \sum_{i=1}^N \Phi\left(\frac{x-X_i}{h}\right) \quad (3.10)$$

Donde,

N : Número de vectores del conjunto

d : Dimensión del espacio

$\hat{f}(x)$: Estimado de la densidad de probabilidad para los vectores de características x de dimensión d .

$\Phi\left(\frac{x-X_i}{h}\right)$: Función núcleo

h : Radio de la ventana del núcleo (soporte o parámetro de suavizamiento, que describe un hipercubo de lado h o hiperesfera de diámetro h)

Entonces, se estima la distribución de probabilidad en la porción donde se ubica el núcleo (en lo consecutivo *kernel*, por el término en inglés con el que se denomina comúnmente), esto se hace para obtener toda la $\hat{f}(x)$. La elección de la función kernel, el número de muestras de entrenamiento N y el tamaño de h determinan el suavizado de la estimación.

El no asumir un modelo específico para las distribuciones de probabilidad puede representar una ventaja de adaptación dependiente de cada situación. A diferencia de la estimación paramétrica donde están presentes el error de clasificación bayesiano, el error del modelo asumido y el error de estimación, en la estimación no paramétrica se tienen sólo el error de clasificación bayesiano y el error de estimación [32].

Por otra parte, para estimar la densidad de probabilidad existen diferentes técnicas no paramétricas [33], por ejemplo *histogramas multivariantes*, el método de *vecinos más cercanos* o *estimación por kernel*. Los *histogramas multivariantes* son poco usados debido a su número exponencialmente creciente de casillas (en inglés *bins*) en relación con la dimensión del espacio y al error generado en el proceso de cuantificación. El método de vecinos más cercanos, muestra gran sensibilidad al ruido local, además, los estimados que se pueden obtener no son una densidad de probabilidad (su integral no tiene valor uno). Para muchos fines prácticos la estimación por kernel resulta adecuada, el estimado de densidad es asintóticamente no sesgado y consistente en el sentido cuadrático medio.

Existen principalmente dos técnicas de estimación por kernel [33]. En una de ellas se estima la función de densidad de probabilidad mencionada mediante la derivación de una *estructura jerárquica de datos* (conocida en inglés como *graph theoretical clustering*). La otra técnica hace una estimación del gradiente de la función de densidad de probabilidad mediante un procedimiento de *ascenso por gradiente* (comúnmente denominado en inglés como *hill climbing*). Ambas técnicas requieren encontrar la moda de los datos que están dentro de la vecindad delineada por el kernel empleado. Para implementar el ascenso por gradiente se puede hacer uso del procedimiento denominado *algoritmo de Corrimiento de Media*, donde el *Vector de Corrimiento de Media* siempre apunta hacia la dirección del incremento máximo en la densidad, entonces se hace una ruta que conduce hacia un máximo local en la función de densidad. Esta técnica permite identificar las clases principales en la escena, en el capítulo siguiente se describirá con detalle ya que en esta tesis se hace uso del algoritmo de Corrimiento de Media como parte del procedimiento de Restauración-Segmentación de la imagen. Otros autores han propuesto utilizar dicho algoritmo directamente en el espacio de las intensidades de la imagen y combinarlo con el uso de *mapas de confianza de bordes* e información a priori (atlas cerebral digital) de las clases de tejido mediante *mapas de probabilidad* para la segmentación de imágenes de RMN [34, 35], lo cual ofrece buenos resultados, pero la calidad de la segmentación depende considerablemente de la resolución de intensidad de la imagen (sobre-segmentando o sub-segmentando si la resolución de intensidad es baja o alta respectivamente), además de que la identificación de estructuras neuroanatómicas depende de los *mapas de probabilidad* disponibles.

Sin embargo, dentro del modelado no paramétrico pueden obtenerse resultados desalentadores si no son considerados el ajuste (experimental o calculado) de algunos parámetros esenciales (tamaño de las ventanas o forma del kernel) para la correcta clasificación de los píxeles de la imagen [35].

Además, la estimación no paramétrica podría consumir un mayor tiempo de procesamiento computacional, comparada a la rapidez de ejecución del método tradicional de Wells con el algoritmo de Maximización de la Esperanza, por lo que a veces es deseable trabajar con un

subconjunto de los datos para la obtención de las clases principales de la escena, como se describirá más adelante.

En el estado de la técnica también se encuentran, muy similares a los clasificadores tradicionales discretos (cuya salida es un valor discreto de pertenencia a una clase), los clasificadores con una salida difusa (continua) para el valor de pertenencia a una clase. Estos clasificadores pueden considerarse como un estimado de las proporciones de mezcla de varios tejidos. Para realizar esto varios autores han propuesto clasificadores continuos: Choi [36] lo denominó modelo mixto, Laidlaw [37] usó un clasificador bayesiano, Schroeter [23] lo hizo mediante una mejora al algoritmo de Maximización de la Esperanza y también un algoritmo genético, y Pham [38] utilizó un método adaptivo difuso de medias que también hace una estimación del campo de ganancia.

Reddick [39] empleó un método híbrido combinando una red neuronal autorganizada de Kohonen con una red neuronal de retropropagación multicapa, actuando directamente sobre el espacio de las intensidades de la imagen, por lo que sólo muestra buenos resultados en la segmentación de imágenes con bajo nivel de ruido y sin la influencia de un campo de ganancia. Morrison [40] y Kollias [41] emplearon una red neuronal probabilística, también directamente sobre los datos, con algunas consideraciones de vecindad entre píxeles, pero escogiendo de manera supervisada los píxeles de clases conocidas para la capa de patrones y la capa de clases, que de manera similar al método de Reddick [39] no ofrecen resultados favorables en imágenes contaminadas con un campo de ganancia.

En contraste a los últimos métodos mencionados, como ventaja a un clasificador discreto y a otras implementaciones basadas en redes neuronales, en este trabajo se ha propuesto una red neuronal probabilística que opera sobre un espacio de características construido a partir de estimadores robustos de localización y dispersión, donde las clases principales se identifican mediante el algoritmo de Corrimiento de Media, obteniendo a la salida de la red los estimados de las probabilidades posteriores para cada píxel y de esta manera eligiendo el valor mayor para etiquetar cada píxel a la *n*-ésima clase correspondiente, e incorporando la técnica al proceso de Restauración-Segmentación.

3.3.7. Procedimientos Automáticos para la Segmentación de IRM.

Una característica deseable por el gran volumen de información que deben analizarse en los centros médicos, es que el algoritmo que realice la segmentación tenga la mayor independencia posible del usuario, siendo deseable un procedimiento totalmente automático. Pero, un aspecto importante a tratar es ¿cómo un procedimiento totalmente automático produce un conjunto correcto de muestras de entrenamiento para algún clasificador, cuando se supone que el conjunto de datos de IRM no se ha visto? Algunos investigadores han trabajado en este tema:

Harris [42] propone extraer muestras de pequeñas áreas cerebrales con baja varianza. Después reordena y agrupa estas muestras en el espacio de características rechazando los valores fuera de rango mediante algunas reglas heurísticas. Sin embargo, este método requiere proporcionar valores de media y varianza por grupo (comúnmente llamado por el término en inglés *cluster*).

También puede hacerse uso de *Mapas de Probabilidad de Tejido* (TPM por sus siglas en inglés) para seleccionar muestras de entrenamiento de localizaciones espaciales que están muy probablemente contenidas en un tipo de tejido dado. Esta técnica fue originalmente propuesta por Kamber [43]. Sin embargo, este enfoque es muy sensible a cualquier variación entre la anatomía del paciente y el modelo estadístico representado por el Mapa de Probabilidad de Tejido.

Van Leemput [24, 25], utiliza un atlas cerebral probabilístico para inicializar y también restringir su esquema del algoritmo de Maximización de la Esperanza. El mismo autor reporta que el método falla en imágenes significativamente diferentes del atlas, tales como cerebros infantiles o cerebros con anomalías patológicas.

Un enfoque muy similar al anterior fue utilizado por Ashburner [26, 27]. Consiste en difuminar el Mapa de Probabilidad a priori con un kernel gaussiano con la finalidad de incrementar la robustez, sin embargo, se reportaron limitaciones muy similares para cerebros patológicos.

En resumen, existen métodos totalmente automáticos para lograr la clasificación de diversos tejidos, sin embargo, típicamente esos métodos se basan en un modelo anatómico predefinido, lo que ocasiona que esos métodos sean muy sensibles a cualquier variación del modelo ya sea por alguna patología o simplemente por la variabilidad anatómica normal que existe entre personas de una misma población. Más aún, también puede suceder que el modelo anatómico utilizado se haya construido a partir de algún sujeto de una población con rasgos y tallas muy diferentes con las imágenes que se desean segmentar [6].

En esta propuesta, para la extracción de muestras de entrenamiento se utilizan estimadores de localización y dispersión que presentan una gran robustez al ruido y realizan una discriminación de valores fuera de rango, este método se basa en obtener información tanto local como global de una región de la imagen y es descrito en detalle por M. Garza-Jinich, V. Medina y O. Yañez [28, 29, 30, 31].

Finalmente para cerrar la revisión del estado del arte, la mayoría de los métodos para segmentar imágenes de RMN se basan en la clasificación de los píxeles mediante la extracción de características, se asumen distribuciones de intensidad de clases gaussianas y ello es una consideración cuestionable [6].

En IRM la distribución de las clases de tejidos no es necesariamente una función estadística conocida, lo cual resulta en una estimación sesgada. También, una clase de tejido usualmente está asociada con un número de componentes normales dentro de la mezcla, requiriendo la estimación de una cantidad significativa de parámetros, esto puede causar problemas de estabilidad y convergencia. Más aún, los bordes entre las clases en la distribución pueden ser complejos y no expresables en una forma paramétrica [35].

CAPÍTULO 4

PLANTEAMIENTO DEL PROBLEMA

4.1. JUSTIFICACIÓN.

El modelado de las inhomogeneidades de campo magnético, la restauración de las imágenes y su segmentación, presentan serias dificultades. Hay distintos enfoques para estos propósitos que, a menudo, se realizan aplicando métodos estadísticos de clasificación a la señal de intensidad, en conjunción con operaciones morfológicas de procesamiento de imágenes. Para estos fines existen métodos de estimación paramétrica, no paramétrica, multicanales, etc.

A través de técnicas de estimación paramétrica pueden obtenerse resultados favorables para lograr segmentaciones aceptables. Estos métodos presentan facilidad en su implementación, rapidez y buenas aproximaciones. Sin embargo, los métodos paramétricos tradicionales para la estimación del campo de ganancia, la restauración de la imagen y la obtención de la imagen segmentada tienen de manera implícita, además del error bayesiano de clasificación, la desventaja de asumir un modelo gaussiano para la distribución de probabilidad de la imagen (que es algo cuestionable). Además, tales métodos, son altamente dependientes de las condiciones iniciales proporcionadas generalmente por un operador (y ello los hace semi-automáticos) o bien obtenidas de un mapa o atlas predefinido no válido en muchas situaciones. Entonces, se requieren inicializaciones apropiadas tanto del número de clases como de sus cualidades, para encontrar soluciones convergentes y resultados útiles. Todo ello hace que los resultados de estos métodos sean dependientes del operador.

Por otra parte, la exploración al modelado y corrección del campo de ganancia mediante técnicas no paramétricas continúa siendo objeto de diversas propuestas, por ejemplo

algoritmos que utilizan el método de vecinos más cercanos, el algoritmo de Corrimiento de Media [35] y Redes Neuronales Artificiales.

Siendo este último enfoque la propuesta del algoritmo de este trabajo, con la finalidad de no asumir un modelo de mezcla gaussiano para la distribución de clases de la imagen, y que pueda proporcionar estimados útiles de pertenencia a determinadas clases basándose en la extracción de características de la imagen con el uso de parámetros robustos al ruido [29].

El gran volumen de información a procesar en los centros médicos, los resultados dependientes de un operador, las desventajas de otras técnicas de clasificación conducen a proponer un método para la restauración y segmentación de las imágenes que considere el campo de ganancia multiplicativo a la imagen y el ruido aditivo a la misma.

4.2. OBJETIVO GENERAL.

Diseñar, implementar y evaluar un método para la descripción del campo de ganancia de IRM, que permita simultáneamente corregir la inhomogeneidad introducida por éste, así como obtener la segmentación de la imagen.

4.2.1. Objetivos Específicos.

Para el logro del objetivo general se plantean los siguientes objetivos específicos:

- Obtener estimadores robustos de localización y de dispersión asociados a cada pixel de la imagen.
- Obtener las clases principales de la imagen utilizando el algoritmo de Corrimiento de Media.

- Construir una Red Neuronal Probabilística, asumiendo un modelo no paramétrico de la distribución de probabilidad de la imagen, para obtener una imagen estadística aproximada a la ideal.
- Incorporar la Red Neuronal construida dentro del método de Restauración-Segmentación de Wells, para corregir la inhomogeneidad de campo magnético presente y obtener la segmentación de la imagen.
- Validar la eficiencia del método.

CAPÍTULO 5

METODOLOGÍA

5.1. RED NEURONAL PROBABILÍSTICA.

Las redes neuronales se emplean frecuentemente como sistemas para la clasificación de patrones basados en el aprendizaje de los mismos datos. Existen diferentes tipos de redes neuronales que utilizan sus propias reglas de aprendizaje, pero invariablemente todas las topologías de redes generan patrones a partir de mediciones estadísticas de los datos de entrenamiento y después clasifican nuevos patrones en base a la información estadística actual.

Aquí se propone utilizar una Red Neuronal Probabilística (RNP, Specht [44]) que es un modelo multicapa que estima probabilidades posteriores de manera natural, con un procedimiento de entrenamiento de un sólo paso a diferencia de las redes multicapa convencionales. Estas características apoyan la elección de este modelo para el problema abordado, pues se requieren los estimados de densidad y se cancela el gasto computacional del entrenamiento tipo retropropagación.

Otra ventaja a considerar, es que se puede demostrar que una Red Neuronal Probabilística es la implementación de un clasificador (basado en estimadores de Parzen) que asintóticamente se aproxima a un clasificador bayesiano [44].

La arquitectura de una Red Neuronal Probabilística (RNP) se muestra en la figura 5.1. Básicamente consta de una capa de entrada, una capa de patrones y una capa de clases.

Entre la capa de entrada y la capa de patrones la interconexión es total (interconexión conocida en inglés como *Fully Connected Layers*). Entre la capa de patrones y la capa de clases, las interconexiones requieren conocimiento supervisado para conectar cada nodo de la capa de patrones con el nodo de la capa de clases al cual pertenece (interconexión conocida en inglés como *Sparsely Connected Layers*).

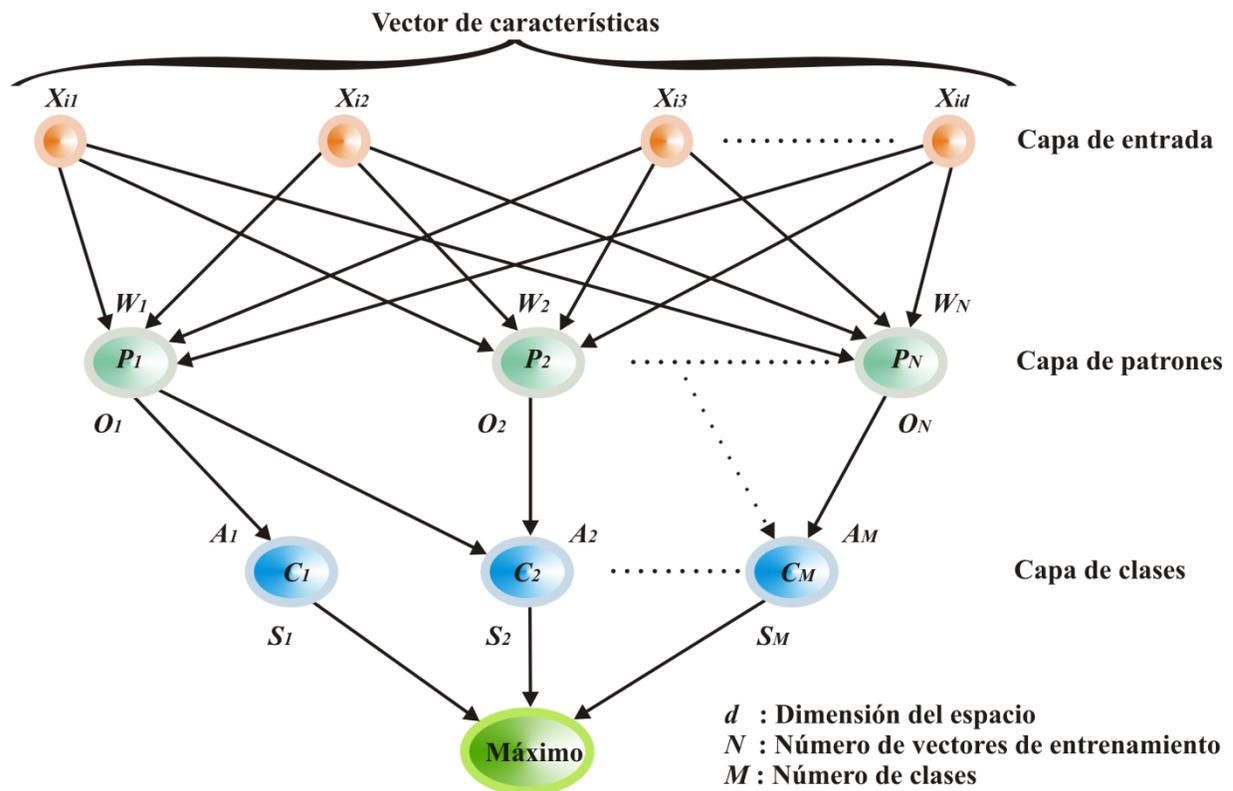


Figura 5.1. Arquitectura de una Red Neuronal Probabilística.

El objetivo es clasificar al vector de características X_i de dimensión d como perteneciente a alguna de las clases C_M . La RNP realiza un procesamiento paralelo, para ello, primero los N vectores conocidos como “los pesos” W_N , se definen de la siguiente manera:

$$W_k = \frac{X_k}{\|X_k\|} \quad k=1, \dots, N \quad (5.1)$$

Donde,

W_k : Peso del nodo P_k

X_k : Vector de entrenamiento

Es decir, son el conjunto de vectores de entrenamiento normalizado. Y para pasar al nodo P_k , se hace:

$$Z_k = W_k^T \frac{X_i}{\|X_i\|} \quad (5.2)$$

Donde,

Z_k : Es el valor resultante del producto punto entre el k -ésimo vector de entrenamiento y el vector X_i a ser clasificado.

Después, en el nodo P_k se realiza la siguiente operación:

$$O_k = \exp\left(\frac{Z_k - 1}{\sigma^2}\right) \quad (5.3)$$

Donde:

O_k : Es el resultado de aplicar un kernel exponencial al valor Z_k

Como estas operaciones se hacen de manera paralela en los N nodos, entonces el vector O_N de dimensión $1 \times N$, contiene los resultados de los productos punto entre los vectores de entrenamiento (pesos) y el vector a ser clasificado, después de aplicarles la función kernel (exponencial).

Las funciones A_M se definen como:

$$A_{M_k} = \begin{cases} 1, & \text{si } W_k \in C_M \\ 0, & \text{en otro caso} \end{cases} \quad (5.4)$$

De este modo las funciones A_M forman una matriz binaria de $N \times M$, donde reside el conocimiento a priori (clasificación supervisada) de las conexiones entre la capa de patrones y la capa de clases.

En los nodos C_M (o unidades de suma) de la capa de clases se realiza la siguiente operación:

$$S_M = \sum_{k=1}^N O_k \cdot A_{M_k} \quad (5.5)$$

El vector S_M contiene los estimados proporcionales equivalentes a las probabilidades posteriores de las clases C_M para el vector X_i (asumiendo que las proporciones de muestra de los datos de entrenamiento fueron consideradas en base a las probabilidades a priori [44]). Así, se puede considerar el valor máximo de S_M para asignar al vector de características X_i a su clase correspondiente.

Entonces, el procedimiento descrito anteriormente se realiza para todos los vectores de características X_i (que están asociados cada uno de ellos a su i -ésimo píxel correspondiente en la imagen) a fin de realizar la clasificación y obtener una imagen estadística basada en un modelo no paramétrico de estimación de la distribución de la imagen.

Como se ha mencionado a la salida de la RNP (vector S_M) se obtienen estimados proporcionales a las probabilidades posteriores de las clases C_M , para visualizarlo se puede retomar la ecuación (5.3) referente a la operación que se realiza en el nodo P_k como sigue:

$$O_k = \exp\left(\frac{z_k - 1}{\sigma^2}\right) = \exp\left(\frac{w_k^T X_i' - 1}{\sigma^2}\right) \quad (5.6)$$

$$O_k = \exp\left(-\frac{1}{2\sigma^2}(2 - 2W_k^T X'_i)\right) = \exp\left(-\frac{1}{2\sigma^2}(W_k^T W_k + X_i'^T X'_i - 2W_k^T X'_i)\right)$$

Reacomodando los términos la expresión queda:

$$O_k = \exp\left(-\frac{1}{2\sigma^2}(X'_i - W_k)^T(X'_i - W_k)\right) \quad (5.7)$$

Donde,

$X'_i = \frac{X_i}{\|X_i\|}$: Es el vector normalizado a ser clasificado.

Retomando la ecuación 3.10 (por comodidad al lector nombrada ahora como 5.8), donde se tiene que el estimado de la densidad de probabilidad es:

$$\hat{f}(x) = \frac{1}{Nh^d} \sum_{i=1}^N \Phi\left(\frac{x-X_i}{h}\right) \quad (5.8)$$

Entonces O_k puede ser un operador de Parzen válido, sólo que ahora el kernel es del tipo gaussiano si existe una constante para que O_k sea gaussiano, entonces obtenemos $\hat{f}(X_i/C_k)$. Por lo tanto en S_M se obtienen estimados proporcionales a las condicionales de clase, es decir, es proporcional a la verosimilitud de la clase.

Por ejemplo, para S_1 :

$$S_1 = \sum_{X_i \in C_1} \exp\left(-\frac{1}{2\sigma^2}(X'_i - W_k)^T(X'_i - W_k)\right) \propto \hat{f}(X_i/C_1) \quad (5.9)$$

Por otro lado, si N_l es el número de vectores de entrenamiento que pertenecen a la clase C_l :

$$f(C_l/X_i) = f(X_i/C_l) P(C_l) = f(X_i/C_l) \frac{N_l}{N_1+N_2+\dots+N_M} \quad (5.10)$$

Añadiendo las constantes para que se vuelva gaussiano y una ventana de Parzen (ecuación 5.8), se tiene:

$$f(C_1/X_i) = \frac{N_1}{N_1+N_2+\dots+N_M} \frac{1}{N_1 h^d} \sum_{\substack{k=1 \\ X_i \in C_1}}^N \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2} (X_i' - W_k)^T (X_i' - W_k)\right) \quad (5.11)$$

$$f(C_1/X_i) = A \sum_{\substack{k=1 \\ X_i \in C_1}}^N \exp\left(-\frac{1}{2\sigma^2} (X_i' - W_k)^T (X_i' - W_k)\right) = A \sum_{\substack{k=1 \\ X_i \in C_1}}^N \exp\left(\frac{Z_k-1}{\sigma^2}\right) \quad (5.12)$$

Donde,

$$A = \frac{1}{N_1+N_2+\dots+N_M} \frac{1}{h^d} \frac{1}{\sqrt{2\pi\sigma^2}}$$

Como A es la misma para todas las clases, se puede omitir:

$$g_1(X_i) = \sum_{\substack{k=1 \\ X_i \in C_1}}^N \exp\left(\frac{Z_k-1}{\sigma^2}\right) = S_1 \quad (5.13)$$

Donde,

$g_1(X_i)$: Es una función discriminante para la clase C_1 .

Y puede observarse que a la salida de la RNP (vector S_M) se obtienen los estimados de las probabilidades posteriores de las clases C_M .

Finalmente, cabe señalar que al aplicar el kernel, existe un parámetro a ser considerado. Este es la σ^2 (o parámetro de suavizamiento), que es el responsable de la modificación del estimado de la densidad de probabilidad del modelo no paramétrico.

El efecto del parámetro de suavizamiento (σ^2), puede verse en la figura 5.2.

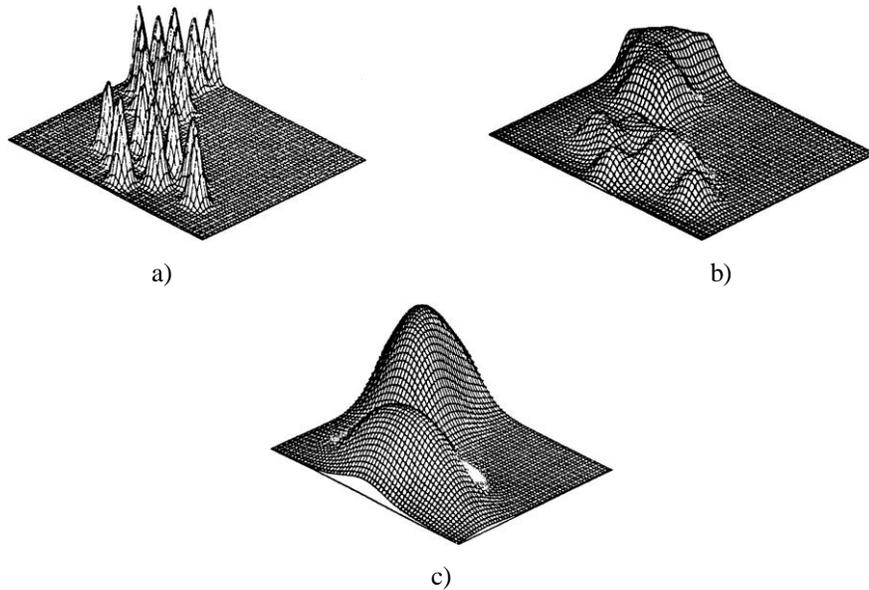


Figura 5.2. Efecto de suavizamiento del estimado de la función de densidad dependiendo del valor de σ^2 .

a) Para un valor pequeño de σ^2 , b) Un valor grande de σ^2 c) Un valor mucho más grande de σ^2 .

El valor de σ^2 puede variar tanto como $0 < \sigma^2 < \infty$. A medida que $\sigma^2 \rightarrow \infty$, el comportamiento de la frontera de decisión varía continuamente desde un hiperplano hasta que el clasificador tiene una frontera de decisión no lineal que se asemeja al clasificador de vecinos más cercanos [44], este comportamiento es el efecto de suavizamiento observado en la figura anterior. En general se han observado mejores desempeños para un clasificador de k-vecinos más cercanos cuando presenta cierto grado de promediación con los vecinos más cercanos. La RNP tiene esta ventaja, controlando el parámetro de suavizamiento.

Specht [44], hace una amplia discusión para el mejor valor de σ^2 , como una función de la dimensión del problema y del número de vectores de entrenamiento. Sin embargo, el mismo Specht, menciona que en la práctica no es difícil encontrar un valor para la σ^2 y que el error de clasificación no cambia significativamente con pequeños cambios de σ^2 . El único parámetro que debe seleccionarse para una RNP (sin considerar el número de vectores de entrenamiento y sus porciones acordes a las probabilidades a priori) es el parámetro de suavizamiento σ^2 , ya que éste controla el factor de escala de la función de activación exponencial y su valor debe ser por lo tanto el mismo para todos los nodos P_k .

5.2. CONSTRUCCIÓN DE LA RED NEURONAL PROBABILÍSTICA.

5.2.1. Construcción de la Capa de Entrada.

- **Estimadores Robustos de Localización ($\vec{\theta}_{EM}$) y de Dispersión (\vec{S}_{EM}).**

En cualquier proceso de segmentación de imágenes se debe determinar el número de clases o categorías existentes en la escena, esto constituye en sí mismo un problema digno de una dedicación especial. Así mismo, también deben ser considerados los artefactos presentes en la imagen a fin de que la técnica de segmentación incorpore información tanto de las intensidades de imagen ideales así como del modelado del ruido.

Tradicionalmente los parámetros más empleados como descriptores de las clases de una imagen son el valor esperado $\vec{\mu}$ y la desviación estándar $\vec{\sigma}$, que son estimados asumiendo un modelo gaussiano.

También es necesario contar con parámetros que describan características específicas asociadas a cada píxel de la imagen a fin de crear un espacio de características para la tarea de clasificación, la cual puede ser llevada a cabo por distintos clasificadores acordes a las cualidades de la información disponible.

Utilizando $\vec{\mu}$ y $\vec{\sigma}$ como descriptores de clases, entonces se deben estimar parámetros semejantes asociados a cada píxel de la imagen que pueden denominarse como *estimador de localización* $\vec{\theta}$ y *estimador de dispersión* \vec{s} , respectivamente.

Por otra parte la media muestral y la desviación estándar muestral obtenidas como parámetros $\vec{\theta}$ y \vec{s} , no son robustos a valores fuera de rango [29]. Para solucionar este problema se propone el uso de *estimadores robustos*.

Para el estimador de localización la *moda muestral*, resulta ser una posibilidad ante la presencia de valores fuera de rango. Garza Jinich [29], describe que el punto de ruptura para la moda muestral es alto incluso en presencia de un 50% de outliers.

En este trabajo se obtiene la moda muestral mediante el uso del *algoritmo del medio intervalo más corto*, que opera en base a que la moda es el valor más probable que toma la variable, la moda está referida al valor máximo de la función de densidad que es desconocida, entonces fácilmente se puede obtener la moda muestral ordenando los datos ascendentemente y buscando la región con mayor densidad [28, 29, 30].

Sin embargo, existe un problema con el cálculo de la moda muestral cuando los datos tienen una distribución bimodal, ello puede ocurrir de manera simple en las discontinuidades o bordes de la imagen. En estos casos, es imprescindible que el método busque alguna alternativa para eliminar el efecto de volumen parcial del píxel analizado. Puede asumirse un *modelo constante por pedazos* y aprovecharse de las altas variaciones de la desviación estándar en los bordes. Aquí, como se describirá más adelante, se ha propuesto extraer los bordes de la imagen (basándose en la desviación estándar) y realizar una rutina específica para las ventanas cuyo píxel central se encuentra en un borde.

- **Algoritmo de Modas Realzadas, $\vec{\theta}_{EM}$** (referido en inglés como *Enhanced Mode*).

Para obtener un *estimador robusto de localización* ($\vec{\theta}_{EM}$) y un *estimador robusto de dispersión* (\vec{S}_{EM}) asociados a cada píxel de la imagen analizada, se implementó el algoritmo propuesto por Garza-Jinich [29] para la obtención de las *modas realzadas*. En la figura 5.3, se describe de manera general el procedimiento. Se han definido dos tipos de ventanas sobre la imagen, con la finalidad de que el método sea sensible tanto local como globalmente a la información contenida en la imagen.

Se definen como “ventana de datos, $Wd_{x,y}$ ”, a un conjunto de valores de intensidad de la imagen con una dimensión de 5x5 píxeles. La imagen completa es cuadrículada (incluyendo los píxeles de las orillas aumentando la imagen con réplicas de las orillas) con un corrimiento unitario, para de esta manera calcular los valores de moda realizada $\vec{\theta}_{EM}$ y de dispersión \vec{S}_{EM} asociados a cada píxel de la imagen.

A su vez, se definen como “ventanas de análisis, $wa_{x,y}$ ” al cuadrículado interno aplicado a cualquier ventana de datos $Wd_{x,y}$, con la finalidad de recuperar la información local. Estas ventanas de análisis son de dimensión 3x3 píxeles y tienen también un corrimiento unitario.

El procedimiento para estimar la moda realizada ($\vec{\theta}_{EM}$) y el estimador de dispersión (\vec{S}_{EM}), asociados al píxel central de una ventana de datos Wd_{xy} , es sencillo. Primero se estima la media y la desviación estándar para cada ventana de análisis wa_{xy} , después se estima la moda muestral del conjunto de valores de desviaciones estándar de las ventanas de análisis, este valor será \vec{S}_{EM} de la ventana de datos. Posteriormente, se identifican los valores fuera de rango en la distribución de desviaciones estándar y se descartan en la distribución de las medias aquellos valores de medias asociados a un valor fuera de rango en la distribución de desviaciones estándar. Finalmente se estima la moda muestral de la distribución de medias actualizada y ésta será $\vec{\theta}_{EM}$ asociada al píxel central de la ventana de datos.

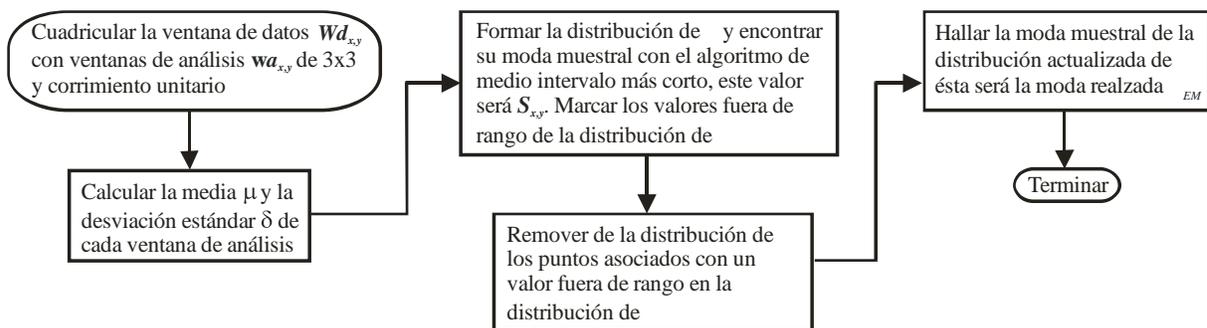


Figura 5.3. Algoritmo para la obtención de las modas realizadas $\vec{\theta}_{EM}$ y sus estimadores de dispersión \vec{S}_{EM} asociados.

- **Vectores de Entrada.**

Para ilustrar mejor el procedimiento propuesto, se utilizará una imagen de prueba.

Sea X_i una imagen de intensidades a ser procesada, definida por 256 niveles de intensidad y cuyas localidades pueden ser direccionadas por medio del índice i . Entonces, en la figura 5.4, se muestra una imagen de ejemplo de 181x217 píxeles con tres círculos concéntricos con valores de clases (del círculo interior hacia el exterior) $\vec{\mu} = [60 \quad 140 \quad 220]$ y un nivel de intensidad para el fondo de 30.

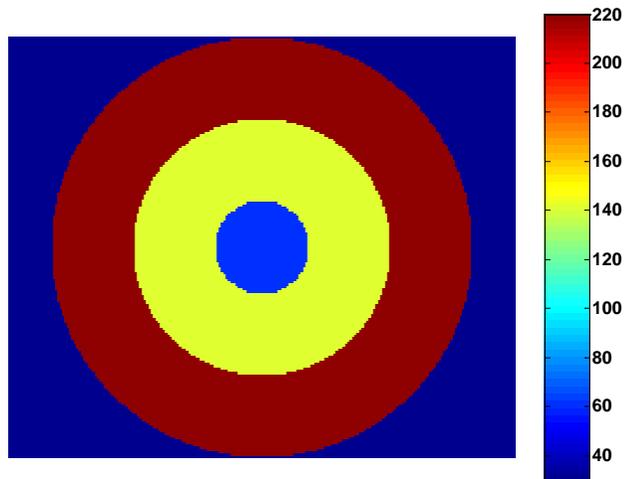


Figura 5.4. Generación de la Imagen de prueba.

Aunque la definición de las imágenes utilizadas es en escala de grises, para una mejor visualización de todas las operaciones aplicadas se emplea falso color.

La imagen de prueba, es alterada con la imagen de un campo de ganancia real proporcionado por la Universidad de McGill [45,46, 47, 48, 49]. La imagen del campo se escala de modo que el campo tenga un nivel del 20%, la imagen del campo se muestra en la figura 5.5 a). Posteriormente, se añade ruido gaussiano de $\vec{\mu}=0$ y $\vec{\sigma}= 3$. Tanto los valores del campo de ganancia como los del ruido aditivo propuestos para alterar a la imagen de prueba son típicos en la práctica médica. Finalmente, la imagen obtenida para ser procesada se muestra en la figura 5.5 b).

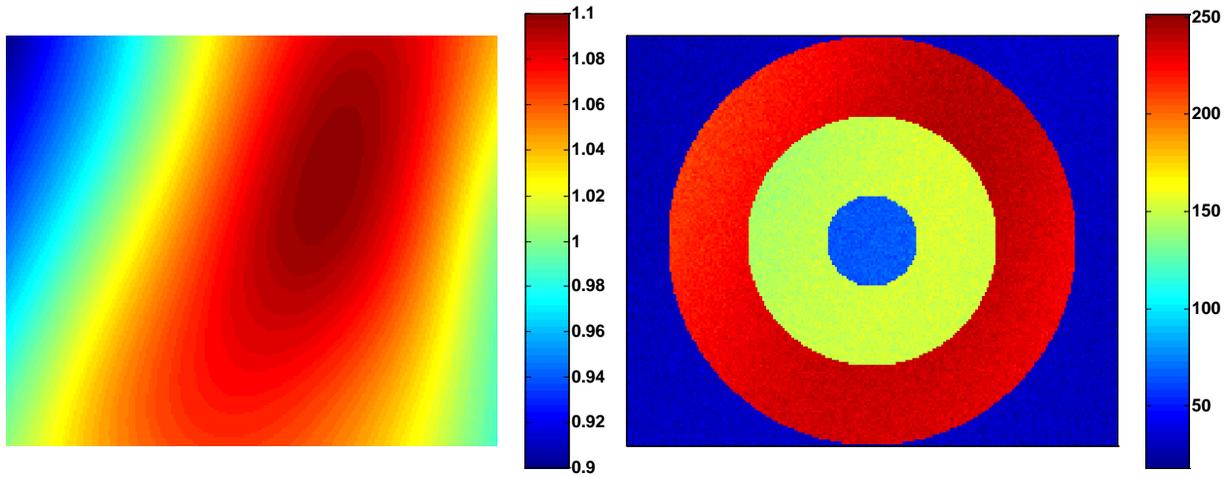


Figura 5.5. a) Imagen del campo de ganancia utilizado. b) Imagen de prueba contaminada con campo de ganancia y ruido aditivo.

Los vectores de entrada a la red neuronal, están formados por los pares $\{\vec{\theta}_{EM}, \vec{S}_{EM}\}$ que describen las características de cada píxel de la imagen.

La figura 5.6, muestra el aspecto de las imágenes de modas realzadas $\vec{\theta}_{EM}$ y de sus valores de dispersión \vec{S}_{EM} obtenidos con el algoritmo de modas realzadas.

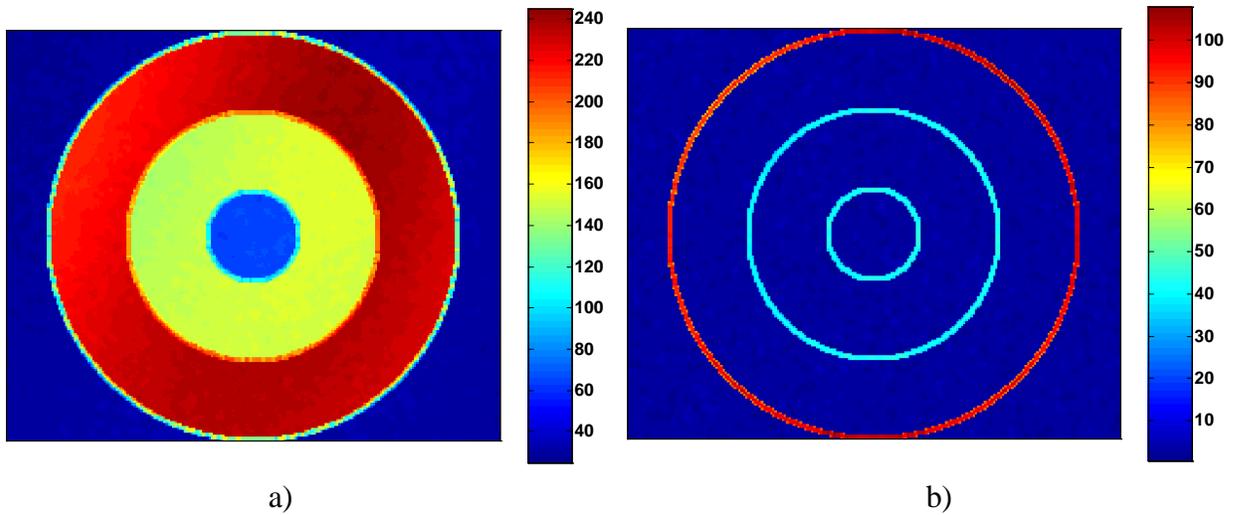


Figura 5.6. a) Imagen de modas realzadas $\vec{\theta}_{EM}$. b) Imagen de los valores de dispersión \vec{S}_{EM} .

En la figura 5.7, se observan las imágenes una vez corregido el efecto de los bordes. Es muy importante corregir este efecto, el cual es ocasionado por la distribución bimodal que se genera en el borde entre dos clases. Si el efecto de los bordes no se corrige, la generación de “*clases falsas*” hará que el resto del procedimiento sea inútil.

Existen muchos métodos para la extracción de bordes. Sin embargo, es importante considerar el contexto de clasificación que se está implementando para aprovechar la información acerca de la dispersión (\vec{S}_{EM}) que se ha generado hasta el momento, y que además, corresponde a una misma génesis con el conjunto de vectores que se desea clasificar, ya que la inclusión de otra técnica puede derivar en un conjunto de valores de desviación estándar con las suficientes diferencias como para disminuir la eficiencia de clasificación o incluso estropear dicha tarea.

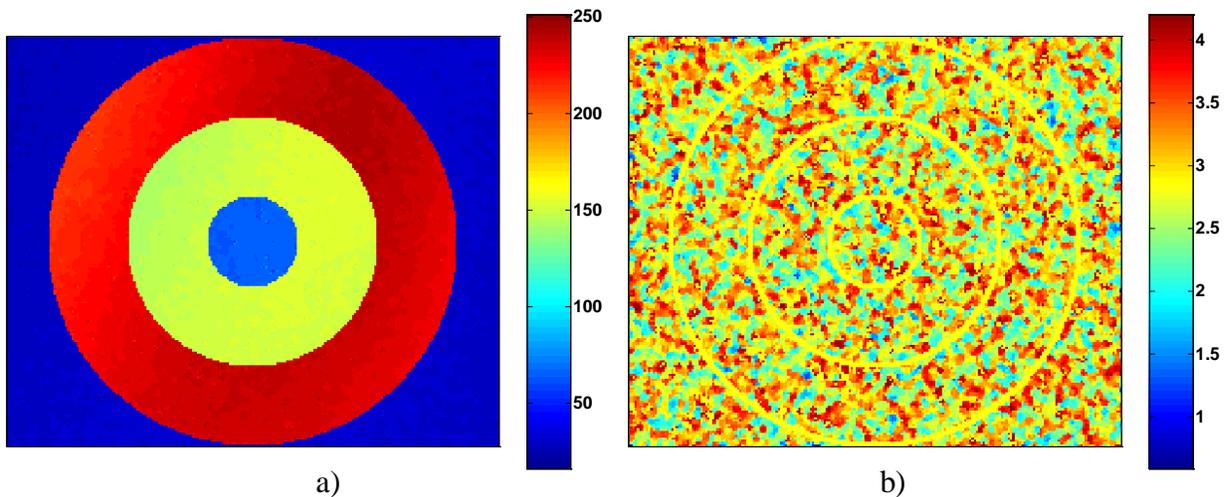


Figura 5.7. a) Imagen de modas realzadas $\vec{\theta}_{EM}$ después de corregir el efecto de los bordes. b) Imagen de los valores de dispersión \vec{S}_{EM} después del censurado.

Entonces maximizando la información obtenida por el algoritmo de modas realzadas, la corrección de bordes se realiza aprovechando las altas variaciones de \vec{S}_{EM} en los bordes. Para ello, se fija un umbral para \vec{S}_{EM} , ajustado experimentalmente a $1.5 \cdot \vec{S}_{EM}$, y se censuran con el valor del umbral a todos los valores de \vec{S}_{EM} mayores en la imagen de \vec{S}_{EM} , ajustándolos al valor de moda de \vec{S}_{EM} de toda la imagen (que es el valor más probable de desviación estándar).

Después, las posiciones asociadas en la imagen de $\vec{\theta}_{EM}$ que fueron censuradas, se actualizan con su valor original de intensidad.

Entonces, ahora a partir de las imágenes corregidas de $\vec{\theta}_{EM}$ y \vec{S}_{EM} se generan los vectores de entrada.

En la figura 5.7 a), puede observarse que el efecto del ruido aditivo ha disminuido considerablemente en la imagen de modas realzadas, este es el primer paso en la restauración de la imagen. Sin embargo, también puede apreciarse que el efecto del campo de ganancia aún no es eliminado.

En la figura 5.7 b), se puede notar que la imagen presenta casi el mismo valor de dispersión, recordando que fue alterada con ruido aditivo del 3%. El método propuesto podría prescindir de considerar los valores de dispersión como parte de los vectores de entrada, si se asume que no hay variaciones de dispersión significativas en la imagen. No obstante, la propuesta considera el caso general, en el cual una imagen puede contener ruido con diferencias de valores de dispersión muy considerables entre sí a lo largo de la imagen, y si solamente se considera al valor de intensidad asociado al píxel, entonces no se pueden obtener resultados satisfactorios en tales casos.

Si toda la imagen tiene casi la misma desviación estándar, entonces los vectores de entrada conservan el par $\{\vec{\theta}_{EM}, \vec{S}_{EM}\}$. Pero, si la imagen presenta varias \vec{S}_{EM} , entonces se cambian los valores de \vec{S}_{EM} por las desviaciones estándar asociadas a cada nivel de gris. Este procedimiento se detalla más adelante cuando se describe la selección de los vectores de entrenamiento.

- **Construcción del Espacio de Características.**

El espacio de características se genera a partir de los vectores de dos dimensiones, formados por las modas realzadas $\vec{\theta}_{EM}$ y sus valores de dispersión \vec{S}_{EM} asociados. Estos vectores se

extraen de las imágenes mostradas anteriormente y se aprecian en la figura 5.8. \vec{S}_{EM} (los valores de \vec{S}_{EM} se multiplican por 10 a fin de balancear las dimensiones).

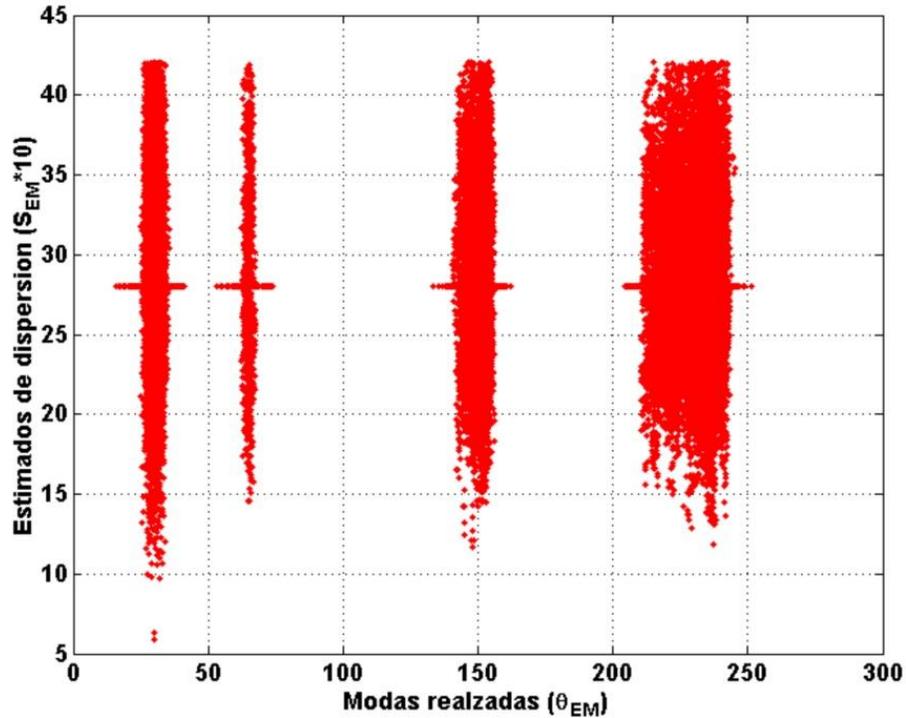


Figura 5.8. Espacio de características generado (vectores de entrada), sin normalizar.

Cabe señalar que el recorte que se observa en la parte superior de las nubes de los vectores de la figura 5.8, se debe al censurado realizado en el valor del umbral, y el efecto de semi-líneas horizontales que se aprecia a la mitad de las nubes de datos son todos los vectores que sobrepasaron el umbral y se ajustaron al valor de moda de \vec{S}_{EM} .

Cuando se realiza una tarea de clasificación es de utilidad añadir una dimensión extra a fin de dispersar los vectores y lograr una menor confusión. También se requiere que los vectores de entrada a la red neuronal se encuentren normalizados a fin de obtener estimados de probabilidades a posteriori correctos en la salida de la red. En la figura 5.9, se muestra el espacio de características tal y como es alimentado a la red neuronal.

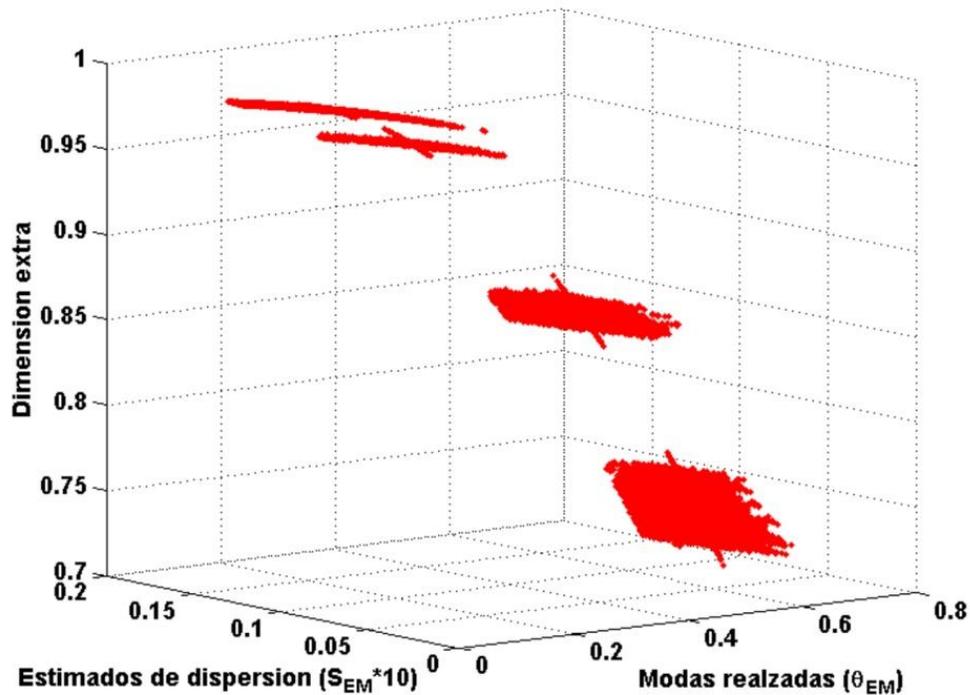


Figura 5.9. Espacio de características (vectores de entrada) normalizado y dispersado.

5.2.2. Construcción de la Capa de Patrones.

- Selección de los Vectores de Entrenamiento.

Los vectores de entrenamiento utilizados en la capa de patrones por la red neuronal se seleccionan a partir de un sub-muestreo de las imágenes de $\vec{\theta}_{EM}$ y \vec{S}_{EM} corregidas en los bordes, formando los pares $(\vec{\theta}_{EM}, \vec{S}_{EM})$ con los valores de los píxeles de dichas imágenes, tomados cada 3 píxeles tanto en la dirección horizontal como vertical. Esto da como resultado seleccionar un porcentaje aproximado del 11% del total de píxeles disponibles en toda la imagen. La figura 5.10 muestra el aspecto del sub-muestreo de las imágenes de $\vec{\theta}_{EM}$ y \vec{S}_{EM} , donde puede observarse que el sub-muestreo realizado, genera un conjunto de datos de entrenamiento que mantiene las proporciones de clases (probabilidades a priori), cualidad que

se debe satisfacer para que la salida de la red neuronal probabilística entregue efectivamente un estimado de las probabilidades posteriores de clase para cada píxel a ser clasificado.

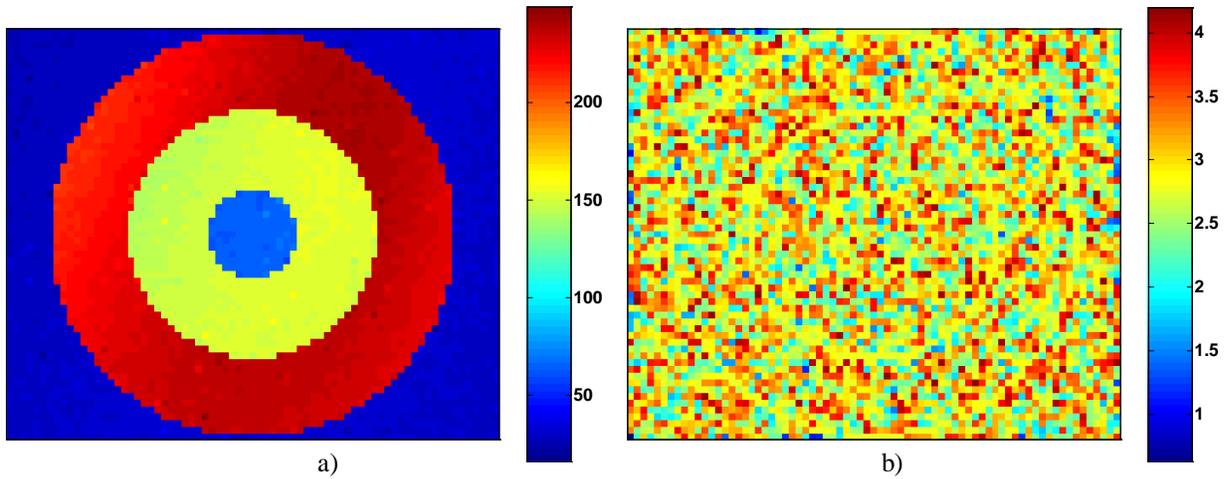


Figura 5.10. a) Imagen de $\vec{\theta}_{EM}$ sub-muestreada. b) Imagen de \vec{S}_{EM} sub-muestreada.

Si toda la imagen tiene prácticamente la misma desviación estándar, entonces, de manera similar a la generación de los vectores de entrada, los vectores de entrenamiento estarán formados por los pares $\{\vec{\theta}_{EM}, \vec{S}_{EM}\}$, que se dispersan y se normalizan de igual modo a los vectores de entrada, como se muestra en la figura 5.11.

Una cualidad a cumplir por los vectores de entrenamiento es que sean representativos de los datos a ser clasificados, esto puede verificarse con las figuras 5.17 y 5.19, donde se aprecia que los vectores seleccionados como patrones cumplen con la cualidad mencionada.

Si la imagen presenta varias \vec{S}_{EM} , entonces se hace necesario cambiar los valores de \vec{S}_{EM} por las desviaciones estándar asociadas a cada nivel de gris, con la finalidad de incrementar la robustez de la técnica ante la presencia de valores de \vec{S}_{EM} considerados como valores fuera de rango [29], puesto que la fijación de un solo umbral para censurar \vec{S}_{EM} muy grandes no es un criterio aceptable sin proporcionarle información adicional al sistema.

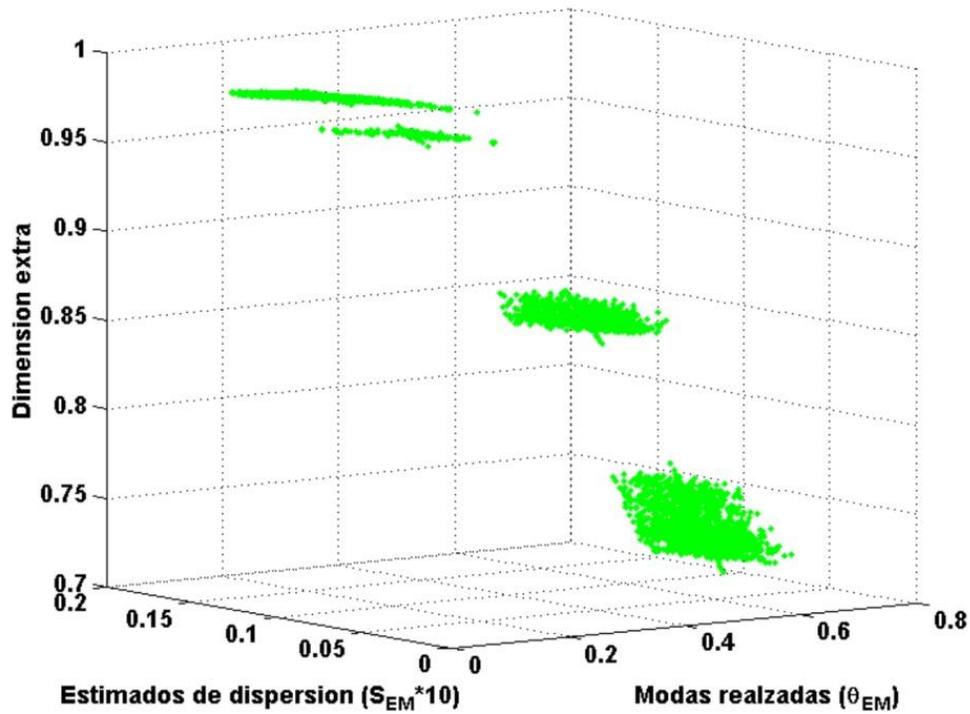


Figura 5.11. Vectores de entrenamiento seleccionados después de dispersarlos y normalizarlos.

Para prever el caso de diferentes \vec{S}_{EM} presentes en la imagen, en el código de implementación del método propuesto se debe establecer algún tipo de criterio, por ejemplo, calcular el histograma de \vec{S}_{EM} y su respectivo percentil 70 [29], si la suma acumulada de frecuencias en el histograma está por debajo del percentil 70 y de un valor de índice (bin) a otro en el histograma la suma excede por mucho al percentil 70, significa que el histograma posee un pico muy superior a otros y puede concluirse que la imagen presenta prácticamente un sólo valor de \vec{S}_{EM} .

En el ejemplo aquí presentado no es necesario realizar esta modificación de \vec{S}_{EM} por las \vec{S}_{EM} asociadas a cada nivel de gris, ya que en la figura 5.10 b) puede observarse que la imagen submuestreada presenta prácticamente la misma \vec{S}_{EM} , lo cual es corroborado de manera cuantitativa con el cálculo del histograma de \vec{S}_{EM} , ver figura 5.12, y aplicando el criterio descrito anteriormente.

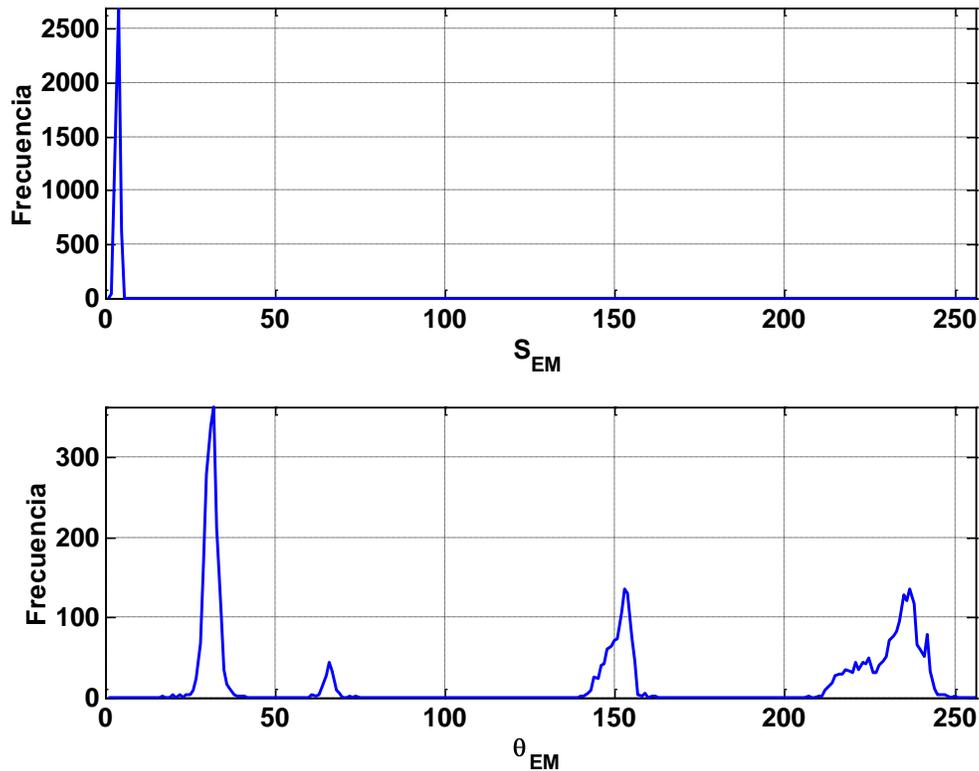


Figura 5.12. Histogramas obtenidos con los datos del conjunto de entrenamiento.

a) Histograma de los valores \vec{S}_{EM} . b) Histograma de $\vec{\theta}_{EM}$.

De la figura 5.12 a), puede observarse que al estimar el percentil 70 y realizar la suma acumulativa de frecuencias, de un valor de índice a otro es posible percatarse de la existencia de un valor dominante de \vec{S}_{EM} para toda la imagen.

De la figura 5.12 b), puede observarse el alto desempeño del algoritmo de modas realizadas para la eliminación del ruido aditivo, recordando que las clases de la imagen de prueba original son $\vec{\mu} = [60 \ 140 \ 220]$ y un nivel de fondo de 30. La variación entre los valores reales y estimados se debe a la influencia del campo de ganancia que hasta el momento no ha sido eliminado y es el campo de ganancia quien dispersa los cúmulos de las clases, incluso la clase con valor real de 220 se ve más afectada, ya que es la que contiene un mayor número de datos a lo largo de toda la imagen.

- **Cálculo de las Desviaciones Estándar Asociadas.**

Si se tiene el caso de varias \vec{S}_{EM} presentes en una imagen, el proceso que se sigue es el siguiente [29]:

1. En esta labor, los datos de trabajo serán el conjunto de datos de entrenamiento que está definido por todos los valores de modas realizadas $\vec{\theta}_{EM}$ y valores de dispersión \vec{S}_{EM} de las imágenes sub-muestreadas.
2. Se calculan los histogramas de $\vec{\theta}_{EM}$ y \vec{S}_{EM} .
3. Se censa el histograma de \vec{S}_{EM} en el percentil 70, eliminando los valores de \vec{S}_{EM} mayores al percentil 70 y descartando del conjunto de entrenamiento las modas realizadas $\vec{\theta}_{EM}$ con \vec{S}_{EM} superior al percentil 70. Esta operación generará una actualización tanto del histograma de \vec{S}_{EM} como del histograma de $\vec{\theta}_{EM}$.
4. Para cada nivel de gris (0-255), o dicho de otra manera, para cada valor posible de $\vec{\theta}_{EM}$ se buscan en el conjunto de trabajo (ya actualizado) todas las \vec{S}_{EM} que correspondan al valor de gris actual ($\vec{\theta}_{EM}$) y se calcula su moda muestral, y éste será el valor de desviación estándar asociado (\vec{S}_{EM} asociada) con el nivel de gris actual ($\vec{\theta}_{EM}$).

De esta manera, el valor de las \vec{S}_{EM} asociadas a cada nivel de gris, representan el valor de desviación estándar más probable asociado a cada píxel para una imagen que presenta diferentes \vec{S}_{EM} [29].

Posteriormente se cambian los valores de \vec{S}_{EM} en los vectores de entrada por su respectiva \vec{S}_{EM} asociada a cada valor de $\vec{\theta}_{EM}$. La única razón de obtener las \vec{S}_{EM} asociadas a partir de las imágenes sub-muestreadas para entrenamiento, en vez de operar sobre todos los datos en las imágenes de $\vec{\theta}_{EM}$ y \vec{S}_{EM} completas de los vectores de entrada, es el incremento del gasto computacional de manera innecesaria.

Para ilustrar el caso en el cual la imagen a ser procesada presenta diferentes \vec{S}_{EM} , se ha generado la imagen que se aprecia en la figura 5.13, dicha imagen es de tamaño 256x256 píxeles y contiene cuatro clases con valores de $\vec{\mu} = [40 \ 80 \ 160 \ 200]$ y $\vec{\sigma} = [5 \ 10 \ 5 \ 10]$, respectivamente de la barra de izquierda a derecha.

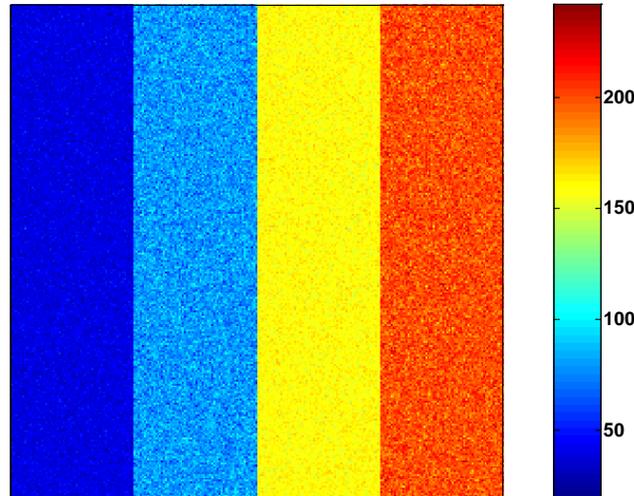


Figura 5.13. Imagen con diferentes valores de desviaciones estándar.

En la figura 5.14 se muestra el cálculo de los histogramas de $\vec{\theta}_{EM}$ y \vec{S}_{EM} después de la corrección de bordes, pueden apreciarse las cuatro clases contenidas en la imagen y se distingue que hay dos valores para \vec{S}_{EM} , también nuevamente se aprecia el desempeño del algoritmo de modas realzadas aplicado a la imagen eliminando en gran medida el ruido aditivo.

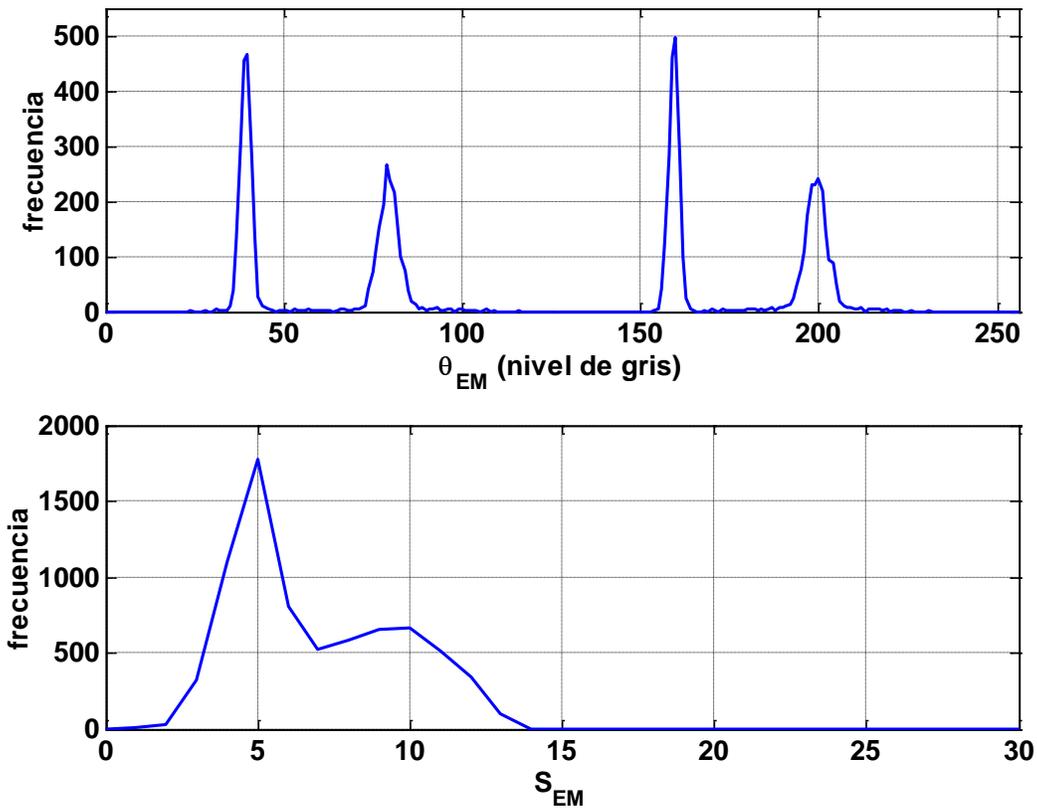


Figura 5.14. Histogramas de $\vec{\theta}_{EM}$ y \vec{S}_{EM} para entrenamiento, sin censurar en el percentil 70.

En la figura 5.15 se puede observar el resultado del cálculo de las desviaciones estándar (\vec{S}_{EM}) asociadas a cada nivel de gris presente en la imagen. Se puede apreciar que el resultado de la técnica indica que hay dos valores de \vec{S}_{EM} presentes en la imagen y si se observan los niveles de gris, estos dos valores tienen una correspondencia con los valores para cada clase definidos previamente.

Como producto del mismo ruido en la imagen, al graficar el cálculo de las \vec{S}_{EM} asociadas no se presenta una suavidad ideal.

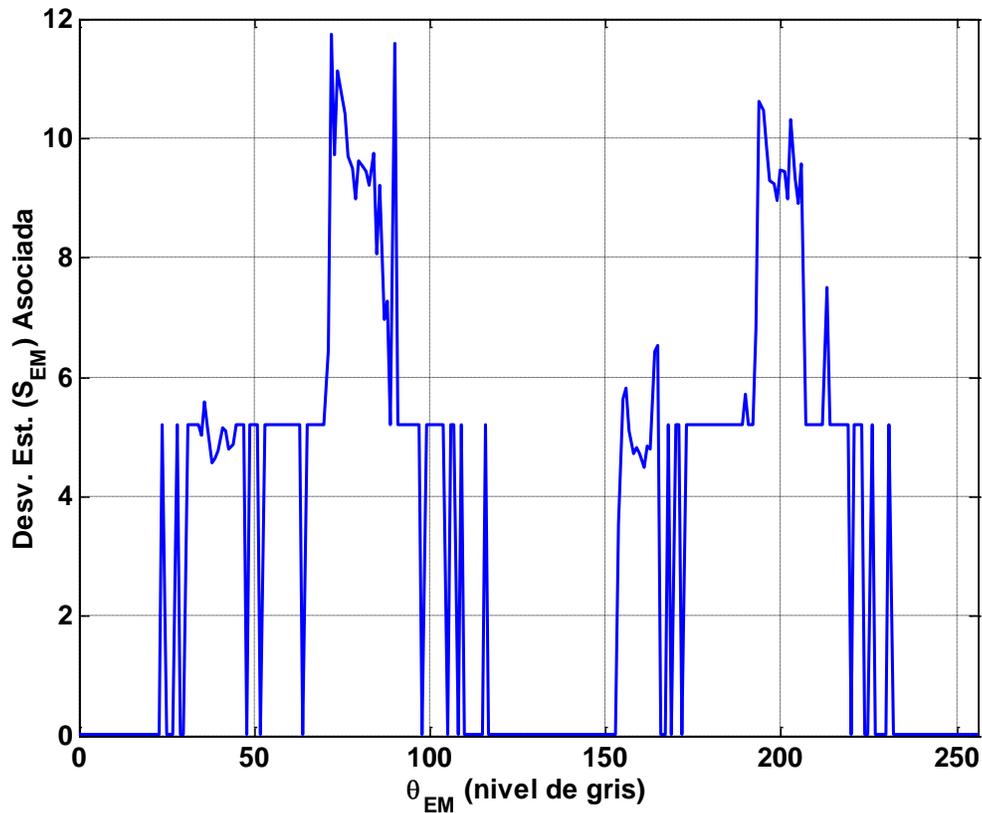


Figura 5.15. Desviaciones estándar (\vec{S}_{EM}) asociadas a cada nivel de gris.

Finalmente, después de actualizar los valores de \vec{S}_{EM} por los valores de \vec{S}_{EM} asociadas tanto en los vectores de entrenamiento como en los vectores de entrada, puede verse el resultado global en la figura 5.16, que es el histograma de los nuevos valores de \vec{S}_{EM} en toda la imagen (conjunto de entrada). Ahora puede claramente distinguirse que la imagen original presenta dos clases de desviaciones estándar y que cualquier metodología de segmentación propuesta deberá considerarlo.

De aquí, se observa que en la definición que se ha realizado sobre cuáles parámetros forman a los vectores de entrada, de entrenamiento y de clases, debe incluirse no sólo el valor de intensidad del píxel o el valor de moda asociado, sino también algún parámetro que pueda describir la dispersión (\vec{S}_{EM}) presente de manera particular en cada clase de la imagen.

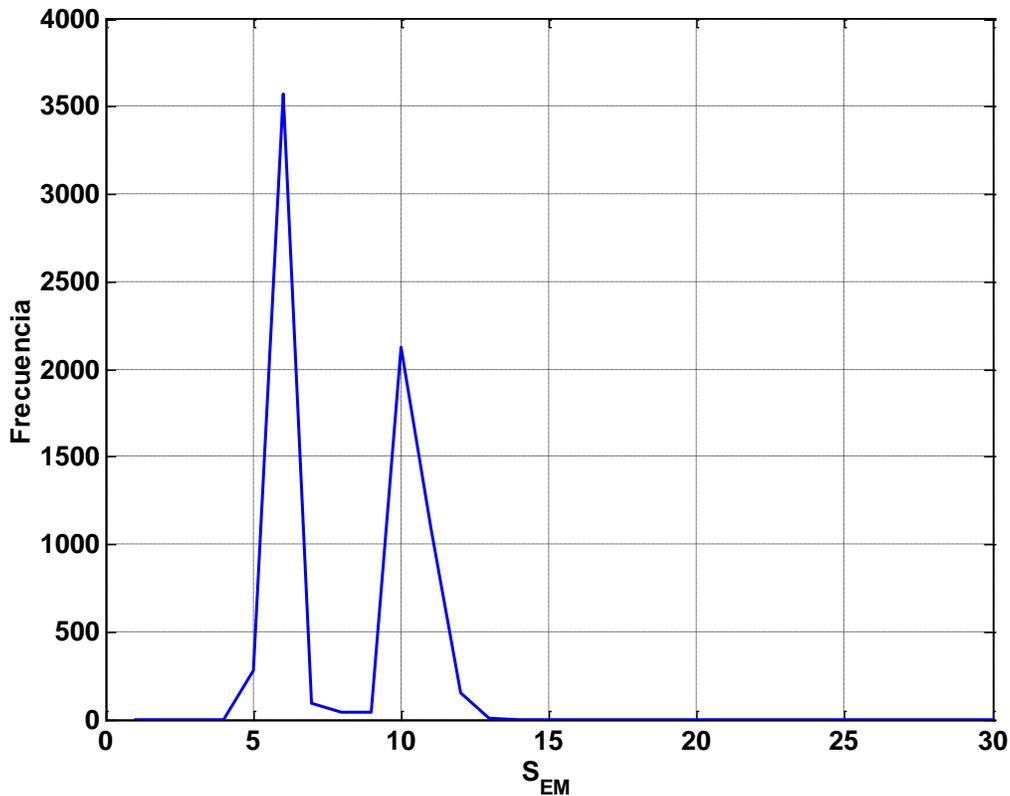


Figura 5.16. Histograma para todos los valores de \vec{S}_{EM} en la imagen, después del proceso de censurado y sustitución por las desviaciones estándar asociadas.

La figura 5.17 a), muestra el resultado de aplicar el algoritmo de modas realzadas sobre la imagen, la corrección de bordes y el sub-muestreo para obtener el conjunto de entrenamiento. En la figura 5.17 b) se puede observar el resultado de identificar diferentes valores para la dispersión en la imagen. Al aplicar el censurado de histogramas en el percentil 70 y el cálculo de los valores de dispersión asociados a cada nivel de gris, se aprecia que cada clase en la imagen presenta un valor de dispersión específico, entonces el desempeño de la tarea de clasificación mejora al realizar esta consideración.

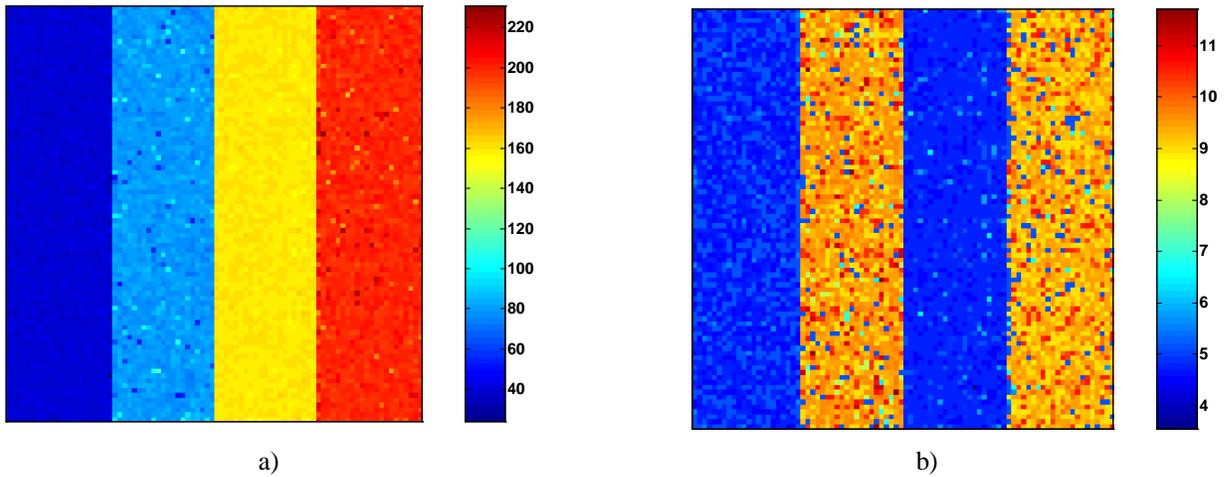


Figura 5.17. Aspecto de las imágenes sub-muestreadas para generar el conjunto de entrenamiento.

a) Imagen de $\vec{\theta}_{EM}$ para entrenamiento. b) Imagen de \vec{S}_{EM} para entrenamiento.

5.2.3. Construcción de la Capa de Clases.

- **Estimación de los Parámetros del Modelo Vía Modas Realzadas.**

Por todas las bondades descritas anteriormente el algoritmo de las modas realzadas, proporciona la información suficiente para estimar los parámetros del modelo y en consecuencia, como se ha mostrado, para la construcción de la red neuronal probabilística.

- **Algoritmo de Corrimiento de Media (referido en inglés como *Mean Shift*).**

En la descripción de imágenes, el espacio de características derivado de los datos a menudo tiene una estructura compleja y puede ser que no se posea información a priori para guiar el análisis, o que se requiera desarrollar un proceso totalmente automatizado. Entonces, para solucionar la tarea de clasificación, se requiere obtener las características dominantes en el espacio generado, y ello tiene una correspondencia con los centros de los agrupamientos

(referidos en inglés como *clusters*) en dicho espacio. El número de agrupamientos y sus formas dependen de los mismos datos y de las reglas para su obtención.

El espacio de características puede ser considerado como una representación de una función de distribución de probabilidad que se desconoce. Si se representa a esta distribución mediante un modelo paramétrico, por ejemplo una mezcla de gaussianas, entonces se generan errores graves ya que la forma de los agrupamientos se está predefiniendo a una forma particular.

Como se mencionó en el capítulo anterior, para estimar la densidad de probabilidad existen diferentes técnicas no paramétricas [33], una de ellas es hacer una estimación del gradiente de la función de densidad de probabilidad mediante un procedimiento de ascenso por gradiente (referido en inglés como *hill climbing*), en el cual se requiere encontrar la moda de los datos que están dentro de la vecindad delimitada por la función núcleo (referida en inglés como *kernel*). Para implementar el ascenso por gradiente se puede hacer uso del procedimiento denominado *algoritmo de Corrimiento de Media*.

La estimación del gradiente de densidad puede obtenerse de manera no paramétrica, recordando la ecuación 3.10, que por practicidad se vuelve a presentar como ecuación 5.14.

$$\hat{f}(x) = \frac{1}{Nh^d} \sum_{i=1}^N \Phi\left(\frac{x-x_i}{h}\right) \quad (5.14)$$

Recordando que $\hat{f}(x)$ es el estimado de la densidad de probabilidad para los vectores de características x de dimensión d . Entonces, se define que la función núcleo (en lo consecutivo *kernel*) $\Phi(x)$ es una función escalar, la cual debe satisfacer las siguientes condiciones:

1. $x \in R^d \Rightarrow |\Phi(x)| < \infty$
2. $\int_{R^d} |\Phi(x)| dx < \infty$
3. $\lim_{x \rightarrow \infty} \|x\| \Phi(x) = 0$, donde $\|x\|$ es la norma euclidiana
4. $\int_{R^d} \Phi(x) dx = 1$

El kernel óptimo que puede proporcionar el mínimo error cuadrático medio es el kernel de Epanechnikov [33], el cual se define como:

$$\Phi_E(x) = \begin{cases} \frac{1}{2} V_d^{-1} (d + 2) & \text{si } x^T x < 1 \\ 0 & \text{en otro caso} \end{cases} \quad (5.15)$$

Donde,

x : Vector de trabajo actual

V_d : Volumen de la esfera de dimensión d

El uso de un kernel diferenciable permite definir el estimado del gradiente de la densidad de probabilidad como el gradiente del estimado de la densidad de probabilidad:

$$\widehat{\nabla} f(x) \equiv \nabla \hat{f}(x) = \frac{1}{N h^d} \sum_{i=1}^N \nabla \Phi \left(\frac{x - X_i}{h} \right) \quad (5.16)$$

De las ecuaciones 5.15 y 5.16, para el kernel de Epanechnikov, el estimado del gradiente de la densidad es:

$$\widehat{\nabla} f(x) = \frac{1}{N (h^d V_d)} \frac{d+2}{h^2} \sum_{X_i \in S_h(x)} [X_i - x] = \frac{N_x}{N (h^d V_d)} \frac{d+2}{h^2} \left(\frac{1}{N_x} \sum_{X_i \in S_h(x)} [X_i - x] \right) \quad (5.17)$$

Donde,

$S_h(x)$: Es una hiperesfera de radio h con el volumen $h^d V_d$ centrado en x y conteniendo N_x datos.

Al último término de la ecuación 5.17 se le conoce como el corrimiento de media de muestra:

$$M_h(x) = \frac{1}{N_x} \sum_{X_i \in S_h(x)} [X_i - x] \quad (5.18)$$

Si se utiliza un kernel diferente al de Epanechnikov, entonces $M_h(x)$ será un cálculo ponderado de la media.

Por otra parte, la cantidad $\frac{N_x}{N(h^d V_d)}$ es el estimado de la densidad $\hat{f}(x)$, calculado con la hiperesfera $S_h(x)$, y de este modo la ecuación 5.17 puede redefinirse como:

$$\widehat{\nabla}f(x) = \hat{f}(x) \frac{d+2}{h^2} M_h(x) \quad (5.19)$$

Por lo tanto:

$$M_h(x) = \frac{h^2}{d+2} \frac{\widehat{\nabla}f(x)}{\hat{f}(x)} \quad (5.20)$$

Este resultado muestra que se puede obtener un estimado del gradiente normalizado calculando el corrimiento de media de muestra. Si se utiliza el kernel de Epanechnikov, el vector de corrimiento de media en x tiene la dirección del estimado de densidad del gradiente.

Partiendo de que el vector de corrimiento de media siempre apunta hacia la dirección del incremento máximo en la densidad, se puede definir una ruta que conduzca hacia un máximo local en la función de densidad. Lo anterior conduce al desarrollo de un algoritmo que utilice el estimado del gradiente de la densidad para definir una técnica iterativa de *ascenso por gradiente* que detecte las modas y los valles en la distribución que se desconoce. El procedimiento de corrimiento de media es una técnica adaptable de ascenso que calcula el vector de corrimiento de media para cada dato, traslada el kernel hacia esa cantidad y repite los cálculos hasta que se encuentra con alguna moda local (máximo local en la función).

Una cualidad destacable de esta técnica es el hecho de que el gradiente normalizado tiene un comportamiento deseable, el incremento del corrimiento de media es largo en aquellas regiones de baja densidad que corresponden a los valles de la función y el incremento disminuye a medida que x se aproxima a una moda local.

También es importante mencionar que el problema de aplicar esta técnica para cada uno de los datos es que el gasto computacional no es satisfactorio en aplicaciones prácticas, además,

pueden existir regiones de alta densidad que presenten mesetas donde un máximo local no está muy definido y la convergencia presenta problemas. La primera dificultad se disminuye considerablemente si se hace que el algoritmo actúe sobre un subconjunto de los datos, seleccionado apropiadamente. La segunda dificultad puede superarse con un radio del kernel apropiado y eliminando entre las modas encontradas aquellas con valores muy cercanos.

- **Obtención de las Clases Principales en la Imagen Mediante la Estimación del Gradiente de la Función de Densidad.**

A partir de los vectores de entrenamiento, en el espacio de características se obtienen nubes de datos (cúmulos) de los pares $\{\vec{\theta}_{EM}, \vec{S}_{EM}\}$. Los centros de dichas nubes de datos serán los valores más probables (modas locales) de $\{\vec{\theta}_{EM}, \vec{S}_{EM}\}$ para cada clase presente en la imagen. Para encontrar los centros de las nubes de datos, se utiliza el algoritmo de Corrimiento de Media [33]. Por cada clase encontrada (valor de $\vec{\theta}_{EM}$ en el centro de la nube) se conoce su desviación estándar (\vec{S}_{EM}) y, con esta información, se construyen los vectores para la capa de clases de la red neuronal probabilística.

A diferencia del análisis de cúmulos [29] y otras técnicas no paramétricas [33], este método presenta un mejor desempeño para encontrar las clases más significativas. También como una ventaja, el número de clases encontradas por esta técnica no está determinado por el usuario sino por las propias características de la técnica de corrimiento de media, esto constituye una cualidad deseable para la propuesta de este trabajo que busca resultados no-dependientes del operador.

La implementación práctica del algoritmo de Corrimiento de Media puede apreciarse en la figura 5.18. Primero para reducir el problema del gasto computacional se hace un muestreo sobre los datos (vectores de entrenamiento), el procedimiento utilizado es tomar un vector de entrenamiento de cada 3, estos valores se toman como pares de coordenadas para la inicialización del algoritmo de corrimiento de media, de esta manera las modas iniciales se asemejan a las nubes de datos, logrando que el algoritmo opere sobre regiones de alta densidad y se garantice la convergencia. Una vez que se tiene el muestreo de los datos se aplica el

procedimiento de Corrimiento de Media, actualizando los valores de las modas iniciales hacia nuevos valores de modas candidatas hasta que las variaciones entre las modas locales candidatas sean mínimas. Después se perturban las modas locales candidatas mediante vectores aleatorios de norma muy pequeña y se repite el procedimiento de corrimiento de media. Cuando se han obtenido conjuntos de modas candidatas muy próximas entre sí, el valor de media de esas modas candidatas será el centro de la nube de datos. Finalmente, se validan los centros encontrados al localizar valles entre los centros candidatos mediante el corrimiento de una hiperesfera con radio del kernel, si se observa que el número de datos contenidos en la hiperesfera disminuye entre dos centros por debajo de un umbral, pequeño, entonces ambos centros son confirmados como clases principales en la imagen.

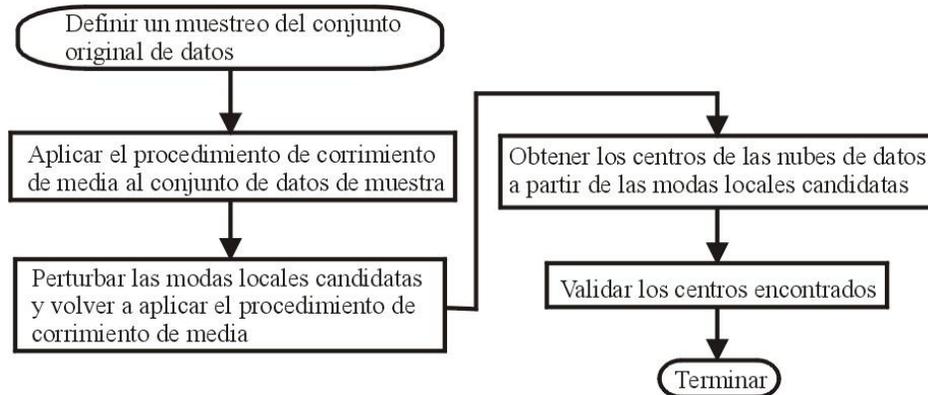


Figura 5.18. Algoritmo de Corrimiento de Media.

La figura 5.19 muestra los puntos de inicialización (modas iniciales) que se obtuvieron para la imagen de prueba. De un total de 4453 vectores de entrenamiento se seleccionaron 743 vectores como modas iniciales, lo que representa un 16.6% del conjunto de entrenamiento. Puede notarse que los puntos elegidos siguen la forma de las nubes de datos.

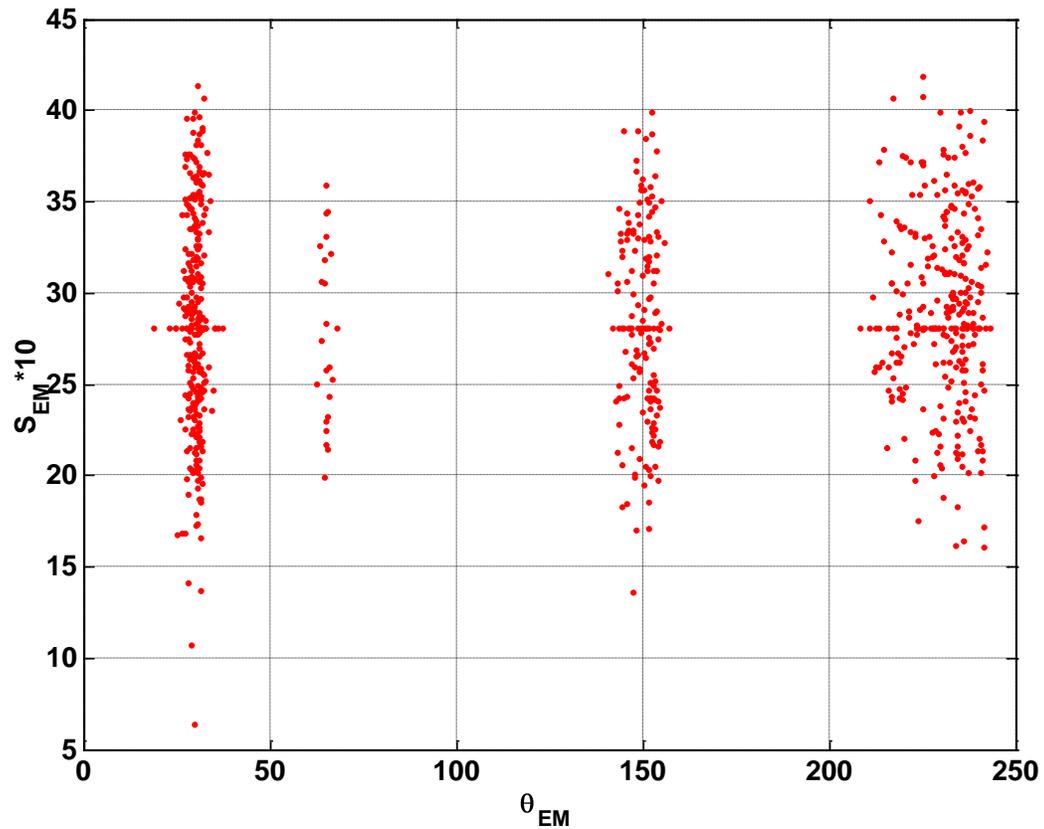


Figura 5.19. Puntos de inicialización para el algoritmo de Corrimiento de Media.

Los resultados obtenidos por el algoritmo de corrimiento de media sobre los vectores de entrenamiento se muestran en la figura 5.20. En color verde, se muestran los vectores de entrenamiento, sobre ellos en color azul se muestran las trayectorias de los corrimientos de las medias (apuntando hacia las regiones de mayor densidad) y en color rojo se muestran los centros encontrados o las principales clases presentes en la imagen.

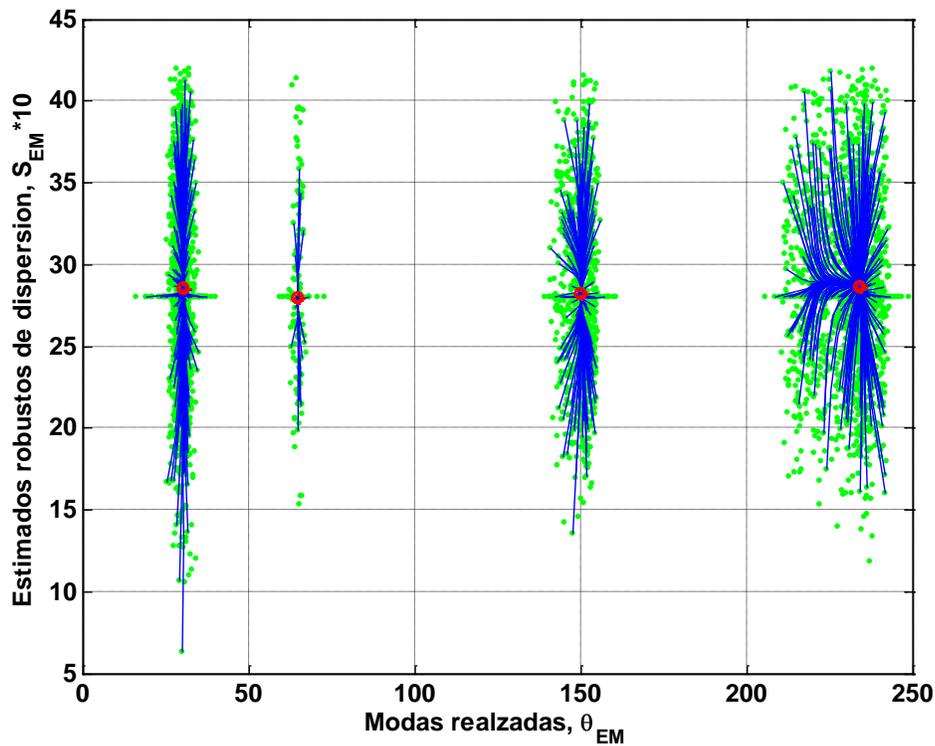


Figura 5.20. Resultados del Algoritmo de Corrimiento de Media.

5.2.4. Interconexión Entre la Capa de Patrones y la Capa de Clases.

- **Clasificador de Distancia de Mahalanobis.**

El conocimiento supervisado requerido para la interconexión de la capa de patrones y la capa de clases puede ser sustituido siguiendo las rutas que los vectores de características toman en el algoritmo de corrimiento de media, sin embargo, solo se trabaja con un subconjunto de los datos, por el gasto computacional que implica trabajar con todos ellos. Entonces, para interconectar la capa de patrones y la capa de clases se utiliza un clasificador de distancia de Mahalanobis, conectando cada vector patrón con el vector de la capa de clases para el cual su distancia es mínima.

Debido a que la forma de las nubes de datos en el espacio de características no son circulares (la matriz de covarianza no es diagonal), se ha elegido utilizar un clasificador de distancia de Mahalanobis en vez de un clasificador de distancia Euclidiana.

La distancia de Mahalanobis se define como:

$$D_m = \left((x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i) \right)^{1/2} \quad (5.21)$$

Donde,

x : Es el vector para el cual se calcula su distancia de Mahalanobis

μ_i : Es el valor de media para la clase i , en este contexto, es el valor de moda encontrado por el algoritmo de Corrimiento de Media para la clase i .

Σ_i^{-1} : Es la inversa de la matriz de covarianza.

Aplicando el clasificador de Mahalanobis sobre los vectores de entrenamiento y los vectores de clases encontrados por el algoritmo de Corrimiento de Media, en la figura 5.21 se muestran con colores blanco y negro, los valores contenidos en la matriz binaria A_M de interconexión entre la capa de patrones y la capa de clases, descrita en la ecuación 5.4. Un valor de 1 (blanco) significa que el vector de entrenamiento pertenece a la clase μ_i , mientras que un valor de cero (negro) significa que el vector no está conectado a la clase μ_i .

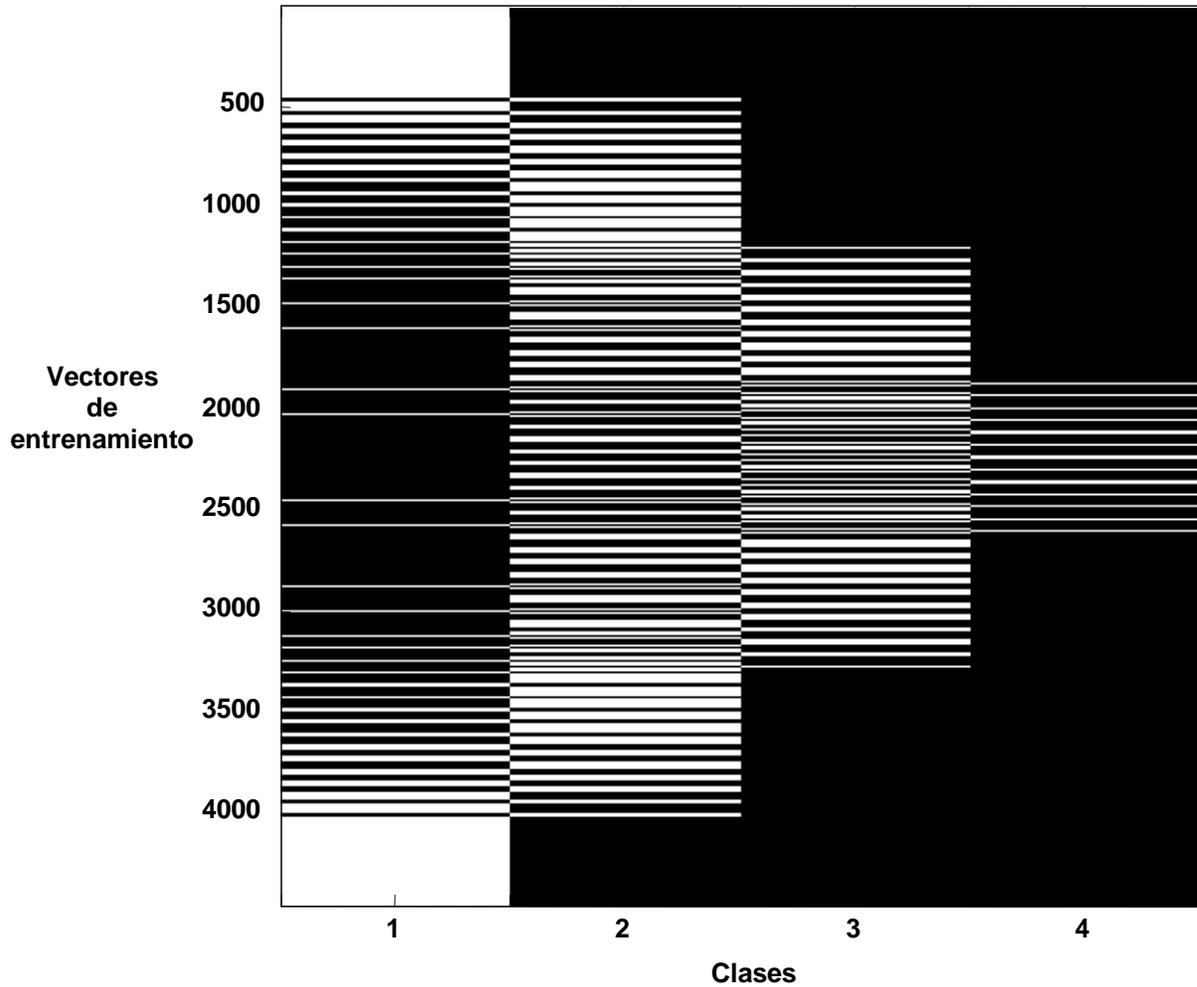


Figura 5.21. Aspecto de la matriz de interconexión binaria (1 blanco, 0 negro) entre la capa de patrones y la capa de clases.

5.3. OBTENCIÓN DE LAS PROBABILIDADES A POSTERIORI E INCORPORACIÓN AL MÉTODO DE RESTAURACIÓN-SEGMENTACIÓN.

La diferencia esencial entre el método original de restauración-segmentación de Wells y la propuesta de este trabajo, radica en que para el primer caso los parámetros del modelo

(número de clases, sus valores de media y desviación estándar) y las probabilidades a posteriori para cada píxel se obtienen mediante estimación paramétrica y asumiendo un modelo de mezcla de gaussianas. En el segundo caso, para cada iteración del algoritmo de restauración-segmentación se estiman de manera no paramétrica los valores para las clases y se construye una red neuronal probabilística cuyos estimados de probabilidades a posteriori para cada píxel, proporcionados a la salida de la capa de clases, se utilizan para calcular la imagen estadística aproximada, la cual será utilizada en la siguiente iteración del método.

Este procedimiento realizado iterativamente continúa hasta que el criterio de paro es alcanzado. A diferencia de la implementación de Wells, el procedimiento converge sólo en una o dos iteraciones, por lo que el criterio de paro se fundamenta en las diferencias entre las segmentaciones de una iteración a otra.

De manera general, si la imagen presenta regiones muy pequeñas, en iteraciones posteriores a la primera, la imagen segmentada no mejorará ya que se pierden las regiones pequeñas de la imagen y se distorsionan los bordes; esto es debido al efecto de promediación del algoritmo de Modas Realzadas y también porque el tamaño de la ventana de análisis usada en dicho algoritmo no puede ser reducido y cubre regiones pequeñas mezclándolas con regiones más grandes.

Con este planteamiento de obtener las probabilidades a posteriori de manera no paramétrica, el método descrito anteriormente conserva la ventaja de no asumir algún modelo para la función de densidad de probabilidad y la dependencia de parámetros iniciales es suprimida.

5.4. ESTIMACIÓN DE LA IMAGEN ESTADÍSTICA.

La estimación de la imagen estadística se lleva a cabo con una suma ponderada de las probabilidades a posteriori y las clases, asignando a cada píxel el nivel de gris resultante del promedio de los estimados de las probabilidades a posteriori ponderado por las medias de las

clases. Esta suma “ponderada” equilibra el error de estimación. De manera formal, la obtención de la imagen estadística es:

$$a = \sum_{c=1}^M [\mu_c * f_{c,i}(c|x_i)] \quad (5.22)$$

Para $i = 1, 2, \dots, N$

Donde,

N : Número total de píxeles en la imagen.

a : Es la imagen estadística que contiene los valores ponderados de las probabilidades a posteriori para cada píxel.

μ_c : Valor de media de la clase C , que es la moda local, encontrada por el algoritmo de Corrimiento de Media.

$f_{c,i}(c|x_i)$: Estimados de las probabilidades a posteriori para el vector de características x_i asociado al i -ésimo píxel de la imagen bajo análisis.

M : Número de clases encontradas.

La siguiente figura (5.22), muestra el resultado obtenido para la estimación de la imagen estadística con la imagen de prueba.

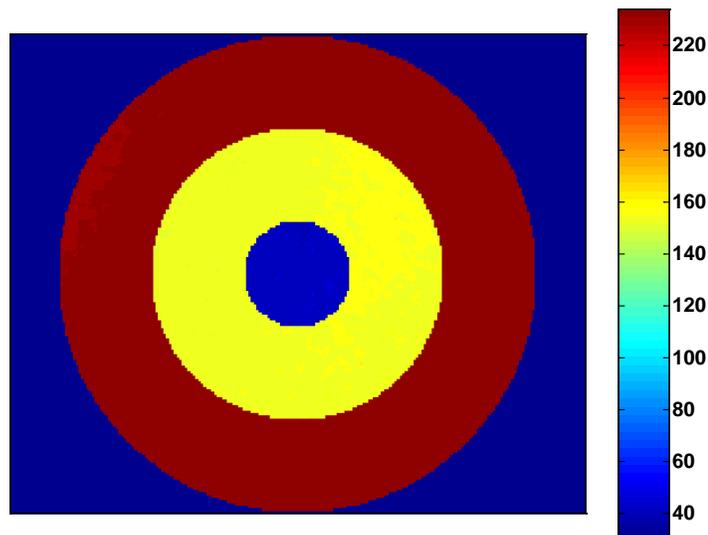


Figura 5.22. Imagen estadística obtenida.

5.5. ESTIMACIÓN DEL CAMPO DE GANANCIA.

Una vez que la imagen ha sido liberada del ruido aditivo por el uso del algoritmo de modas realizadas y se ha obtenido la imagen estadística, entonces, aplicando el modelo para el campo de ganancia descrito en la ecuación 3.1, para estimar el campo de ganancia se realiza el cociente entre la imagen de modas realizadas corregida en los bordes (imagen libre del ruido aditivo) y la imagen estadística. Cabe señalar que este método, a diferencia del método de Wells, sí considera el ruido aditivo por lo que no se hace la separación del campo de ganancia de la imagen de intensidades ideales mediante una transformación logarítmica.

En la figura 5.23 a), se puede apreciar que el resultado del cociente entre las imágenes conserva la estructura de la imagen de prueba, además la clase con menor número de píxeles de la imagen sobresale del resto de las clases, esto es producto de la poca cantidad de vectores disponibles para esa clase durante todo el proceso de clasificación, lo que origina que las diferencias entre la probabilidad a posteriori mayor y las demás para un mismo píxel disminuyan entre clases muy próximas.

Como el cociente entre ambas imágenes es un estimado “*crudo*” del campo de ganancia, para el suavizamiento en la estimación del campo de ganancia (recordando que es un artefacto de baja frecuencia) se hace la convolución con un filtro pasa-bajas, ver figura 5.23 b). Este filtrado proporciona un suavizamiento acorde al modelo de gradiente del campo de ganancia.

La aplicación de un filtro pasa-bajas contribuye a la eliminación de las frecuencias más altas presentes en el estimado “*crudo*” del campo de ganancia. Sin embargo, los resultados obtenidos difieren bastante de la morfología original del campo de ganancia, ver figura 5.23 c), y la aplicación iterativa del filtro a menudo puede conducir a que la morfología del estimado del campo de ganancia adquiera la geometría circular centrada del filtro aplicado.

Para mejorar la estimación del campo de ganancia se ha propuesto realizar promediaciones iterativas con una ventana de tamaño 40, sugeridas en [8, 21]. El resultado final de

suavizamiento después de 12 iteraciones de promediación se observa en la figura 5.23 d), que al compararse con la imagen original del bias utilizado para contaminar a la imagen se aprecia el notable recuperación de la morfología original.

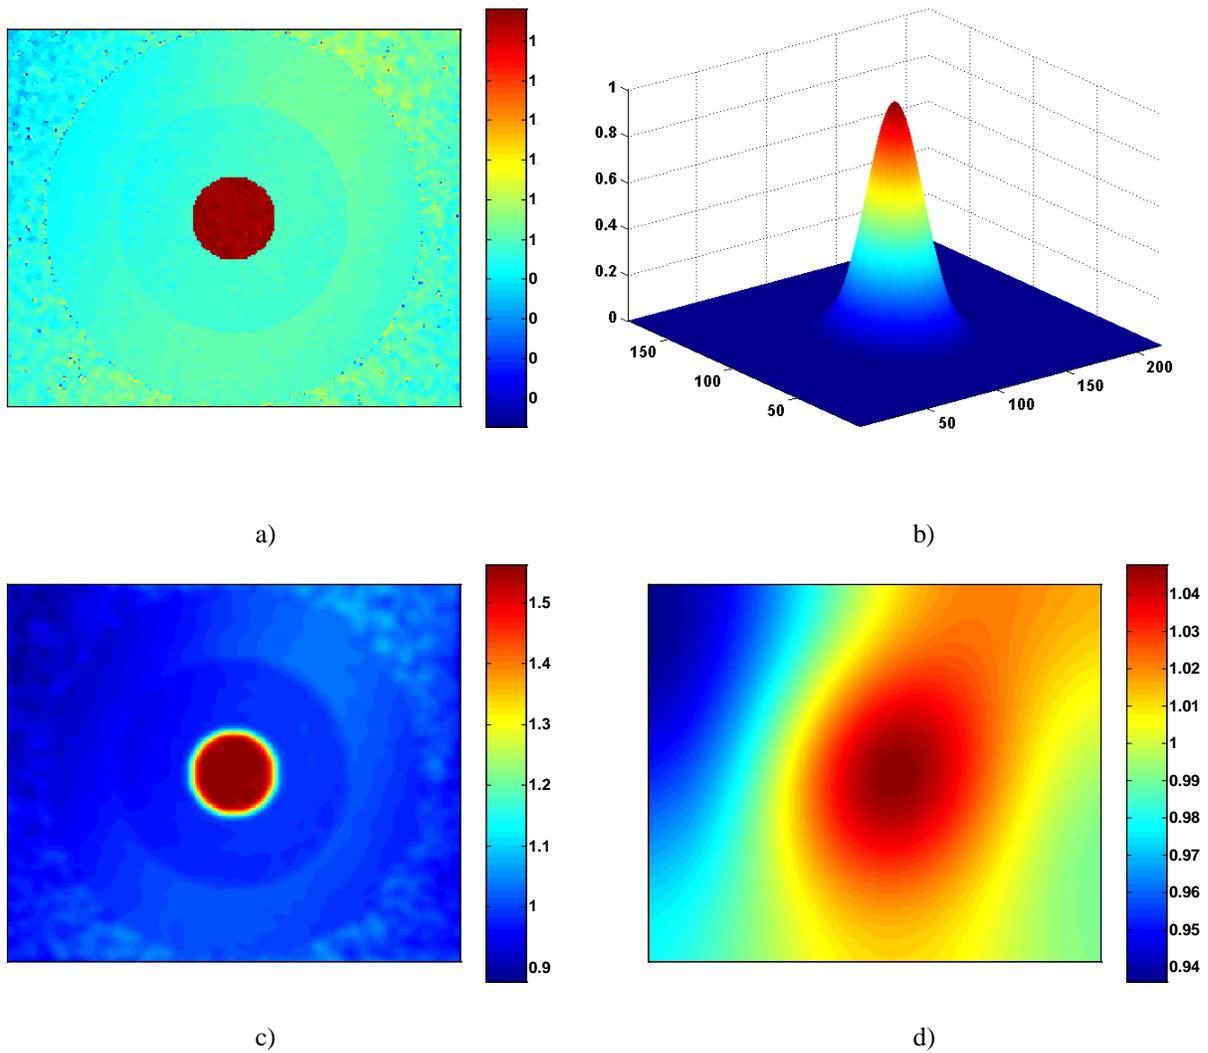


Figura 5.23. Obtención del campo de ganancia. a) Estimado “crudo” del campo de ganancia. b) Filtro pasa-bajas empleado para suavizamiento. c) Estimado del campo de ganancia después del filtrado pasa-bajas. d) Estimado del campo de ganancia después del promediado.

Una de las principales dificultades en la estimación del campo de ganancia es el criterio de paro que se debe establecer para el proceso de suavizamiento. Para hacer frente a esta dificultad, se debe disponer de información que distinga significativamente una iteración de la

otra. Esta información puede obtenerse de las diferencias, ya sea entre los valores máximos o entre los valores mínimos de intensidad presentes entre iteraciones.

Después de realizar el cociente entre la imagen de modas realizadas y la imagen estadística, así como el filtrado pasa-bajas, en el estimado del campo de ganancia aún se preserva la estructura de los objetos presentes en la escena, siendo éstos los valores de intensidad más grandes y, por tanto, los que no permiten visualizar claramente el estimado del campo de ganancia aunque esté presente. Por esta razón, es preferible seleccionar las diferencias entre los valores máximos para establecer el criterio de paro en la promediación, cuando éstas diferencias se vuelven cero de una iteración a otra, entonces se detiene el proceso de promediación.

En la figura 5.24 se muestran las diferencias entre los valores máximos y las diferencias entre los valores mínimos presentes en la estimación del campo de ganancia de una iteración a otra. El índice 0 indica las primeras diferencias obtenidas entre el estimado “*crudo*” del campo de ganancia y el estimado después de aplicar el filtro pasa-bajas y, a partir del índice 1 comienzan a mostrarse las diferencias entre las iteraciones de promediación. Para la imagen de prueba el criterio de paro se alcanzó en la iteración 12.

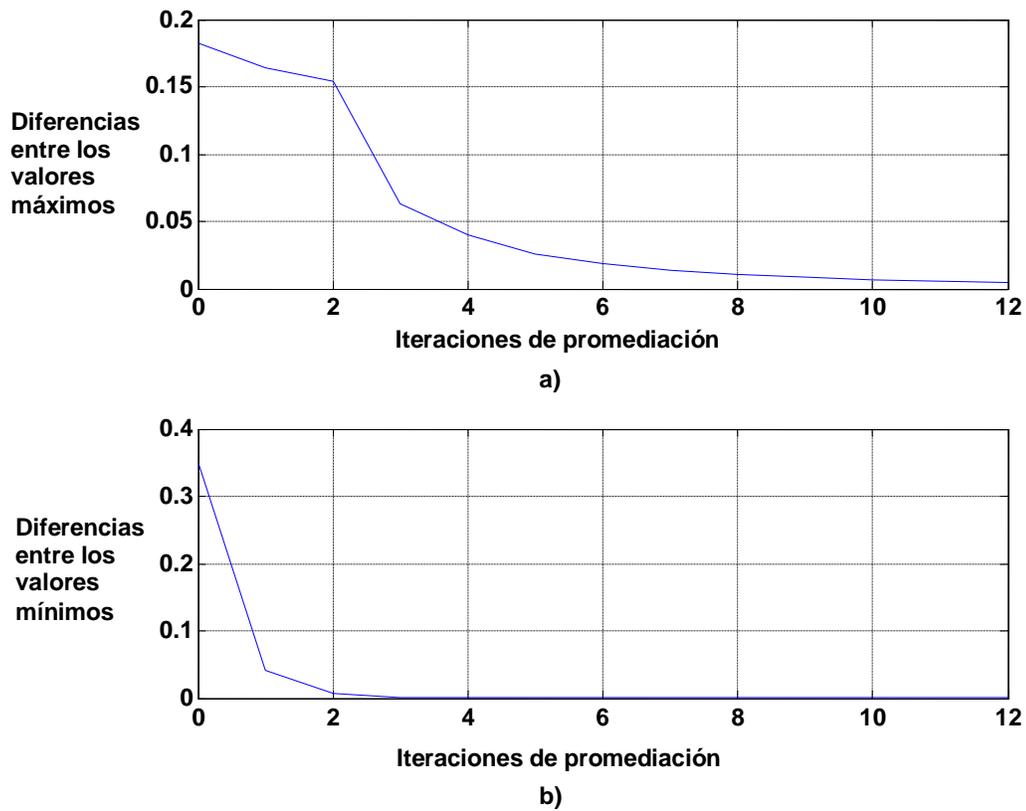


Figura 5.24. Criterio de paro cuando las diferencias entre los valores máximos se hacen cero de una iteración de promediación a otra. a) Diferencias entre los valores máximos. b) Diferencias entre los valores mínimos.

En la figura 5.25, se aprecian los cambios en el estimado del campo de ganancia de una iteración de promediación a otra. Comparando con la figura 5.24, se observa que considerando a las diferencias de los valores mínimos el proceso pararía en la segunda o tercera iteración, por lo que es preferible atender a las variaciones de los valores máximos presentes en el estimado.

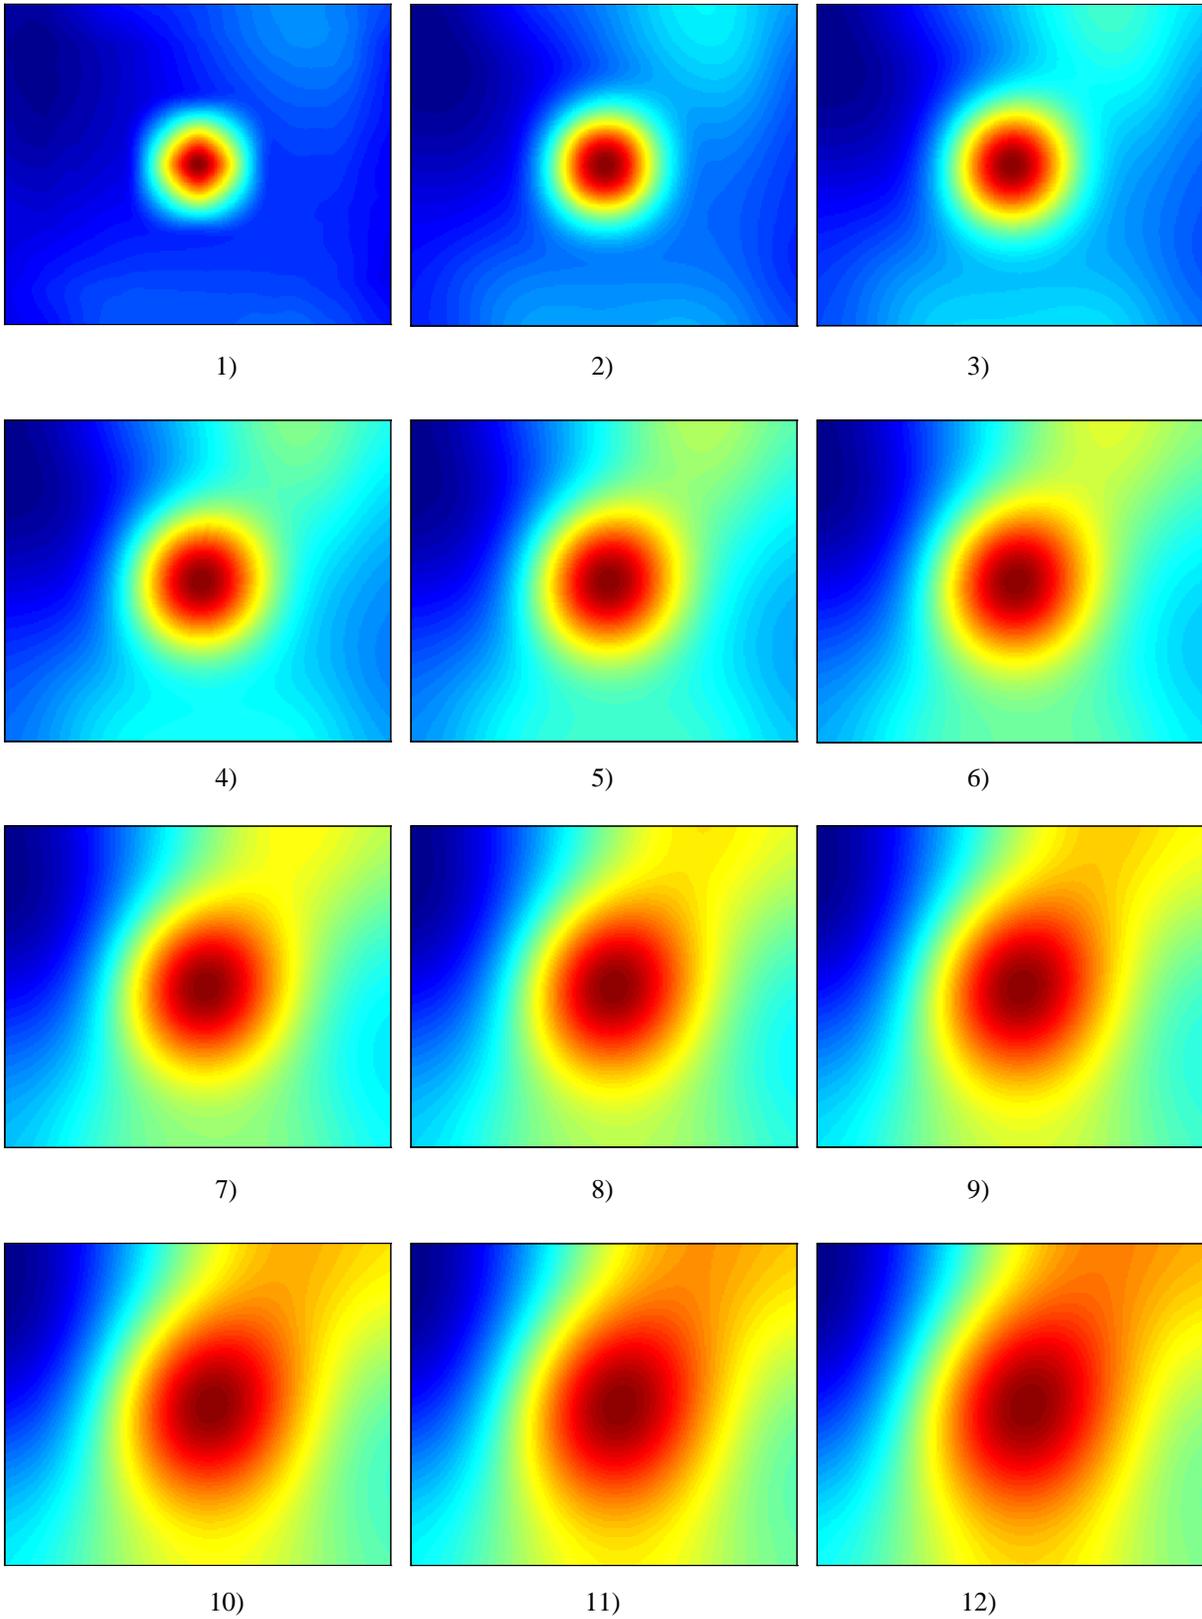


Figura 5.25. Iteraciones de promediación en el estimado del campo de ganancia hasta alcanzar el criterio de paro.

5.6. SEGMENTACIÓN DE LA IMAGEN.

La imagen segmentada se obtiene a partir de la clasificación bayesiana con las probabilidades a posteriori asociadas a cada píxel proporcionadas por la red neuronal probabilística, asignando cada píxel a la clase para la cual su estimado de probabilidad a posteriori es mayor. La figura 5.26 muestra la segmentación obtenida para la imagen de prueba.

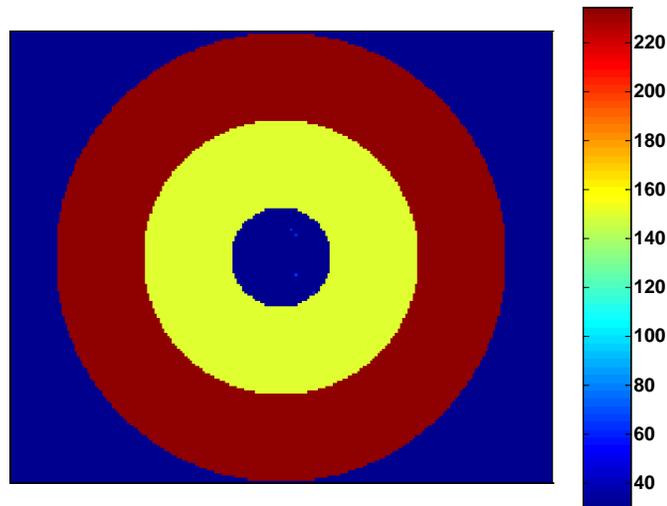


Figura 5.26. Imagen segmentada obtenida.

5.7. EVALUACIÓN DEL MÉTODO.

Cualquier método de segmentación puede ser evaluado utilizando imágenes sintéticas que simulen condiciones reales dentro de un experimento controlado, o bien, puede ser evaluado con imágenes adquiridas en situaciones verdaderas. Por otra parte, la evaluación puede dirigirse en dos sentidos:

1. Evaluación Cualitativa

En una evaluación cualitativa los resultados se inspeccionan manualmente y se comparan contra el conocimiento a priori de la anatomía cerebral típica. En este tipo de evaluación el usuario hace una confrontación entre la segmentación obtenida y algún patrón de referencia.

Una evaluación cualitativa es sencilla, rápida y muy útil, pero tiene la desventaja de ser dependiente de la apreciación del usuario.

2. Evaluación Cuantitativa

En una evaluación cuantitativa se debe calcular automáticamente alguna medida de similitud entre el resultado de segmentación obtenida y una referencia o patrón de clasificación cuidadosamente construido.

Una evaluación cuantitativa tiene la ventaja de no depender de la apreciación del usuario, en vez de ello, se aumenta la complejidad para establecer un criterio aplicable.

Algo importante de considerar es que si la segmentación resultante presenta un número de clases diferente al de la segmentación de referencia, se tiene el problema entre definir una mezcla de clases de cierta semejanza con la finalidad de tener imágenes comparables directamente entre sí, o bien, calcular la medida de similitud excluyendo los píxeles de aquellas clases que tienen un valor no presente en la otra imagen de segmentación. Más aún, puede generarse el caso en el cual una clase adicional (presente ya sea en la segmentación de referencia o en la obtenida) tenga alguna región que en la imagen a comparar pertenezca a cierta clase y otra región que pertenezca a otra(s) clase(s), por lo que su mezcla o exclusión modifican el valor de similitud hacia un sentido.

5.7.1. Estimados de las Probabilidades a Posteriori.

La obtención de segmentaciones útiles con la metodología propuesta descansa en las probabilidades a posteriori. Entonces, es necesario verificar que la red neuronal efectivamente otorga estimaciones de probabilidades a posteriori que son aprovechables, una primera evaluación cualitativa se realiza sobre dichos estimados y puede observarse en el capítulo de resultados, sección 6.3.

5.7.2. Factor de Confianza en la Clasificación.

Ciertamente las imágenes de probabilidades a posteriori ofrecen una visión del grado de certidumbre que se obtiene en la clasificación, pero es necesario definir un criterio cuantitativo acerca de la clasificación.

Para cada píxel se calcula un “*Factor de Confianza*” [40,41], el cual representa el grado de confiabilidad que se tiene en la clasificación. Esta medida se calcula a partir del valor de probabilidad a posteriori máximo y del segundo valor de probabilidad a posteriori más grande para un píxel dado:

$$c(x, y) = 1 - \exp\left(-\frac{p_{1o.}(x,y) - p_{2o.}(x,y)}{p_{2o.}(x,y)}\right) \quad (5.23)$$

Donde,

$c(x, y)$: Factor de confianza para el píxel en la posición (x, y) .

$p_{1o.}(x, y)$: Valor máximo de probabilidad a posteriori para el píxel en (x, y) .

$p_{2o.}(x, y)$: Segundo valor de probabilidad a posteriori más grande para el píxel en (x, y) .

La ecuación 5.23 produce una medición en el rango entre cero cuando $p_{1o.}(x, y) = p_{2o.}(x, y)$ y la unidad cuando $p_{1o.}(x, y) \gg p_{2o.}(x, y)$.

La obtención de los factores de confianza para cada píxel proporciona una evaluación más concreta a cerca del proceso de clasificación.

5.7.3. Estadísticas de Clasificación.

Una de las formas más comunes para realizar un análisis cuantitativo en tareas de clasificación es presentar una estadística de concordancia entre la clasificación obtenida y la clasificación real o verdadera, la tabla 5.1 muestra éstas relaciones para un problema de dos clases.

		Clasificación	
		Sí	No
Verdad	Sí	Verdadero Positivo (VP)	Falso Negativo (FN)
	No	Falso Positivo (FP)	Verdadero Negativo (VN)

Tabla 5.1. Relaciones entre clasificación y verdad.

Si la clasificación es correcta, entonces se genera un verdadero positivo, pero, si un píxel perteneciente a otra clase se asigna a la clase actual se genera un falso positivo, y un falso negativo ocurre cuando un píxel que debió ser asignado a la clase actual fue asignado a otra. Estas relaciones se pueden generalizar para un problema de M clases definiendo que para cada clase i : SI \Rightarrow clase i , NO \Rightarrow unión de las otras clases ($M - 1$).

5.7.4. Matrices de Confusión de Clases.

A partir de las estadísticas de clasificación puede generarse una presentación de resultados que ayude a visualizar las proporciones entre clasificaciones correctas e incorrectas de una clase específica respecto al resto de ellas, una matriz de confusión de clases ofrece esta bondad. Para M número de clases ($k=1, \dots, M$), una matriz de confusión es de tamaño $M \times M$, el par (i, j) denota los índices de renglón y columna respectivamente, la matriz de confusión se genera como sigue:

1. Sea el par (x, y) , una posición arbitraria en la imagen bajo análisis, entonces, para cualesquiera valores (x, y) dados, el valor de la segmentación de referencia en esa posición (x, y) será el índice del renglón i en la matriz de confusión.
2. De manera similar, el valor de la segmentación obtenida en la posición (x, y) proporciona el índice de la columna j en la matriz de confusión.
3. Si coinciden los valores de segmentación ($i=j$), se incrementa la cuenta de verdaderos positivos en la diagonal de la matriz para el valor de clase k correspondiente a $k=i$ y $k=j$.
4. Si $i \neq j$, entonces se incrementan las cuentas de falsos positivos o negativos en posiciones distintas a la diagonal de la matriz de confusión.

La interpretación de una posición (i, j) en la matriz de confusión depende de la clase k observada. Para una clase k , el valor en la posición $(k=i, k=j)$ es el número de verdaderos positivos (clasificaciones correctas), las posiciones $(k=i, j)$ sobre un renglón corresponden a falsos negativos (valores que se asignaron a las otras clases, pero pertenecen a la clase k), y las posiciones $(i, k=j)$ sobre una columna corresponden a falsos positivos (valores asignados a la clase k pero que pertenecen a las otras clases). La figura 5.27 muestra dos ejemplos de interpretación de las matrices de confusión, que dicho en otra forma, la cantidad a_{ij} representa el número de casos de la clase i que tras aplicar el proceso de clasificación se adscriben a la clase j [50].

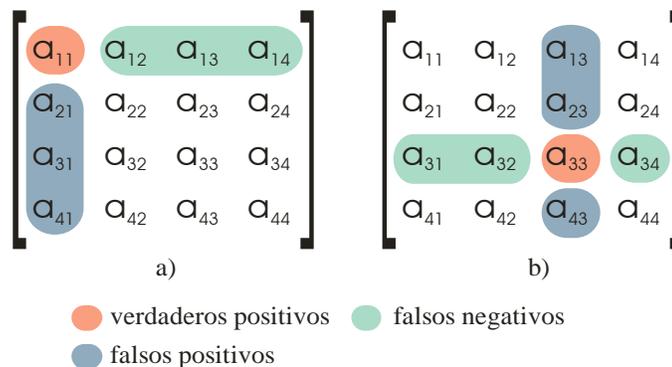


Figura 5.27. Dos ejemplos de interpretación de los elementos de las matrices de confusión, a) para la clase $k=1$, b) para la clase $k=3$.

Debido a que es difícil visualizar los resultados de la clasificación en términos del número de verdaderos positivos, falsos positivos, falsos negativos y verdaderos negativos, entonces es común encontrar que los elementos de la matriz de confusión se presentan como porcentajes, calculados utilizando el número total de píxeles pertenecientes en la realidad a la clase k , dado que el número de píxeles pertenecientes en la realidad a una clase k cualquiera, se encuentran en un mismo renglón [51].

5.7.5. Medida de Similitud de Probabilidad Corregida (Kappa).

Al igual que en otras evaluaciones de resultados, para una tarea de segmentación es de gran utilidad emplear algún parámetro cuantitativo que pueda indicar de manera global el resultado de la segmentación sobre todas las clases, para ello, se utiliza el parámetro “*Kappa*”, que fue propuesto por Cohen [51, 52, 53] y que ha sido utilizado en varios trabajos de clasificación de imágenes cerebrales [6, 26, 27].

El parámetro Kappa es una medida de similitud de probabilidad corregida, que hace una ponderación entre el número de clasificaciones correctas e incorrectas utilizando todas las clases, a continuación se describe de manera formal el cálculo del parámetro Kappa.

Para M número de clases ($k = 1, \dots, M$), sean:

v_k : Número de verdaderos positivos de la clase k .

c_k : Número de píxeles clasificados como pertenecientes a la clase k
(verdaderos positivos + falsos positivos).

r_k : Número de píxeles que en la realidad pertenecen a la clase k
(verdaderos positivos + falsos negativos).

N : Número total de píxeles en la imagen.

Entonces, se define la proporción de concordancia correcta o exactitud de clasificación P_v como:

$$P_v = \frac{1}{N} \sum_{k=1}^M v_k \quad (5.24)$$

Y se define la proporción de concordancia esperada P_e como:

$$P_e = \frac{1}{N^2} \sum_{k=1}^M [c_k * r_k] \quad (5.25)$$

Finalmente, Kappa se define como:

$$\text{Kappa} = \frac{P_v - P_e}{1 - P_e} \quad (5.26)$$

La ecuación 5.26 produce una medición de manera que $\text{Kappa} \rightarrow P_v$ a medida que $P_e \rightarrow 0$, en tal situación el valor de Kappa indica que el error de clasificación disminuye, siendo el caso ideal cuando $P_v = 1$.

Al utilizar Kappa como medida de similitud se deben tener en cuenta algunas consideraciones [51, 52, 53]:

1. El valor de Kappa es relativo y sólo es significativo en el mismo contexto de comparación.
2. Kappa considera todas las diferencias y similitudes de clasificación de los píxeles de igual modo sin importar su ubicación en la imagen.

CAPÍTULO 6

RESULTADOS

Una vez que se ha descrito la metodología y la manera para realizar la evaluación, en las siguientes secciones se presentan los resultados obtenidos con la imagen de referencia y con las imágenes sintéticas disponibles con la Universidad de McGill [45, 46, 47, 48, 49] que se han obtenido expofeso para la evaluación de segmentaciones en IRM.

También se muestran los resultados de partes importantes de la metodología, como la determinación de las clases principales de la imagen usando el algoritmo de Corrimiento de Media, la interconexión entre la capa de patrones y la capa de clases, y la obtención de las probabilidades a posteriori usando la Red Neuronal Probabilística.

Por otra parte, es muy importante mostrar los resultados obtenidos sobre la susceptibilidad de los parámetros, ya que varios de ellos afectan la calidad de las segmentaciones, así como resultados en IRM reales.

6.1. OBTENCIÓN DE LAS CLASES PRINCIPALES USANDO EL ALGORITMO DE CORRIMIENTO DE MEDIA

En la tabla 6.1 se muestran los parámetros para las clases encontradas en la imagen de referencia (empleada en el capítulo anterior), puede hacerse una comparación con los valores ideales proporcionados para la imagen de prueba (círculos con $\vec{\mu} = [60 \ 140 \ 220]$, nivel de

fondo = 30) y notarse la eficiencia de la técnica a pesar del nivel de 20% del campo de ganancia y del 3% del nivel del ruido aditivo añadidos.

Clases	Nivel de gris de las clases en la imagen de prueba	Nivel de gris de la clase ($\vec{\theta}_{EM}$)	Desviación Estándar (\vec{S}_{EM})
1	30	30.29	2.85
2	60	64.99	2.78
3	140	150.26	2.82
4	220	234.40	2.86

Tabla 6.1. Clases encontradas en la imagen con el algoritmo de Corrimiento de Media.

En la figura 6.1, se observan los resultados del algoritmo de Corrimiento de Media (utilizando color rojo), mapeados sobre un estimado de la densidad del espacio de los vectores de entrenamiento que se obtuvo calculando el histograma de las características de dichos vectores. Se aprecia que los errores de aproximación más grandes ocurren en la tercera y cuarta clases, ello se debe a que en esas clases la intensidad de la inhomogeneidad de campo es mayor (además del error de cuantificación), no obstante las segmentaciones obtenidas son aceptables, como se verá más adelante.

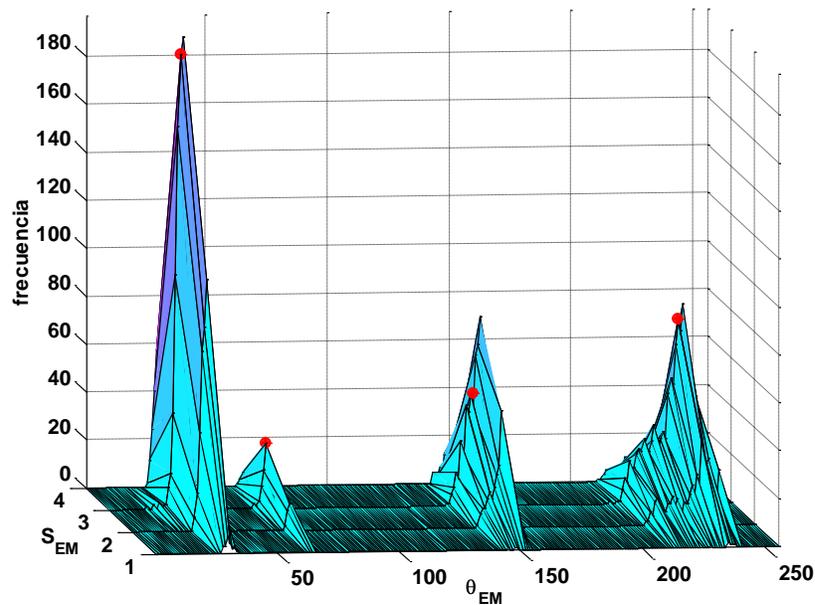


Figura 6.1. Resultados (color rojo) del algoritmo de Corrimiento de Media mapeados en el histograma de características de los vectores de entrenamiento.

6.2 DESEMPEÑO DEL CLASIFICADOR DE DISTANCIA DE MAHALANOBIS.

Para evaluar el desempeño del Clasificador de Distancia de Mahalanobis con la imagen de prueba, se ha realizado un estimado de las probabilidades a priori, como el número de vectores de entrenamiento conectados a cada clase entre el número total de vectores de entrenamiento. Los resultados obtenidos se muestran en la tabla 6.2., donde se comparan los estimados con las proporciones de cada clase verdaderas obtenidas de la imagen de prueba ideal. Calculando el porcentaje de error, puede verse que utilizar el Clasificador de Mahalanobis otorga una buena aproximación para la interconexión entre capas, recordando que los vectores de entrenamiento se obtuvieron de la imagen ya contaminada con ruido aditivo e inhomogeneidad del campo.

Nivel de gris de la clase encontrada	Estimado de probabilidad a priori	Proporciones Verdaderas	Porcentaje de error en presencia de: 3% ruido aditivo 20% bias
30.29	0.3692	0.3525	4.7376
64.99	0.0308	0.0317	2.8391
150.26	0.2048	0.2093	2.1500
234.40	0.3952	0.4065	2.7798

Tabla 6.2. Resultados de la interconexión entre las capas de patrones y de clases.

6.3. RESULTADOS DE LOS ESTIMADOS DE LAS PROBABILIDADES A POSTERIORI.

Para esta tarea, se obtuvieron los estimados de probabilidades a posteriori para una imagen ideal de prueba con tres círculos concéntricos con valores de $\vec{\mu} = [90 \ 150 \ 210]$ (del círculo interior al exterior) y nivel de fondo de 10, considerando los casos de un nivel de campo de ganancia de 0% con ruido aditivo del 3%, el caso de 20% de campo de ganancia con 3% de ruido y otro más con 40% de campo de ganancia con 3% de ruido. Puesto que para cada píxel se generan un número de estimados de probabilidades a posteriori igual al número de clases

encontradas, entonces se puede visualizar el valor de las probabilidades a posteriori obtenidas para cada clase como una imagen. En la figura 6.2 se muestran las imágenes con el “*aspecto*” de las probabilidades posteriores para cada clase, cuyos valores se encuentran entre cero (color azul) y uno (color rojo).

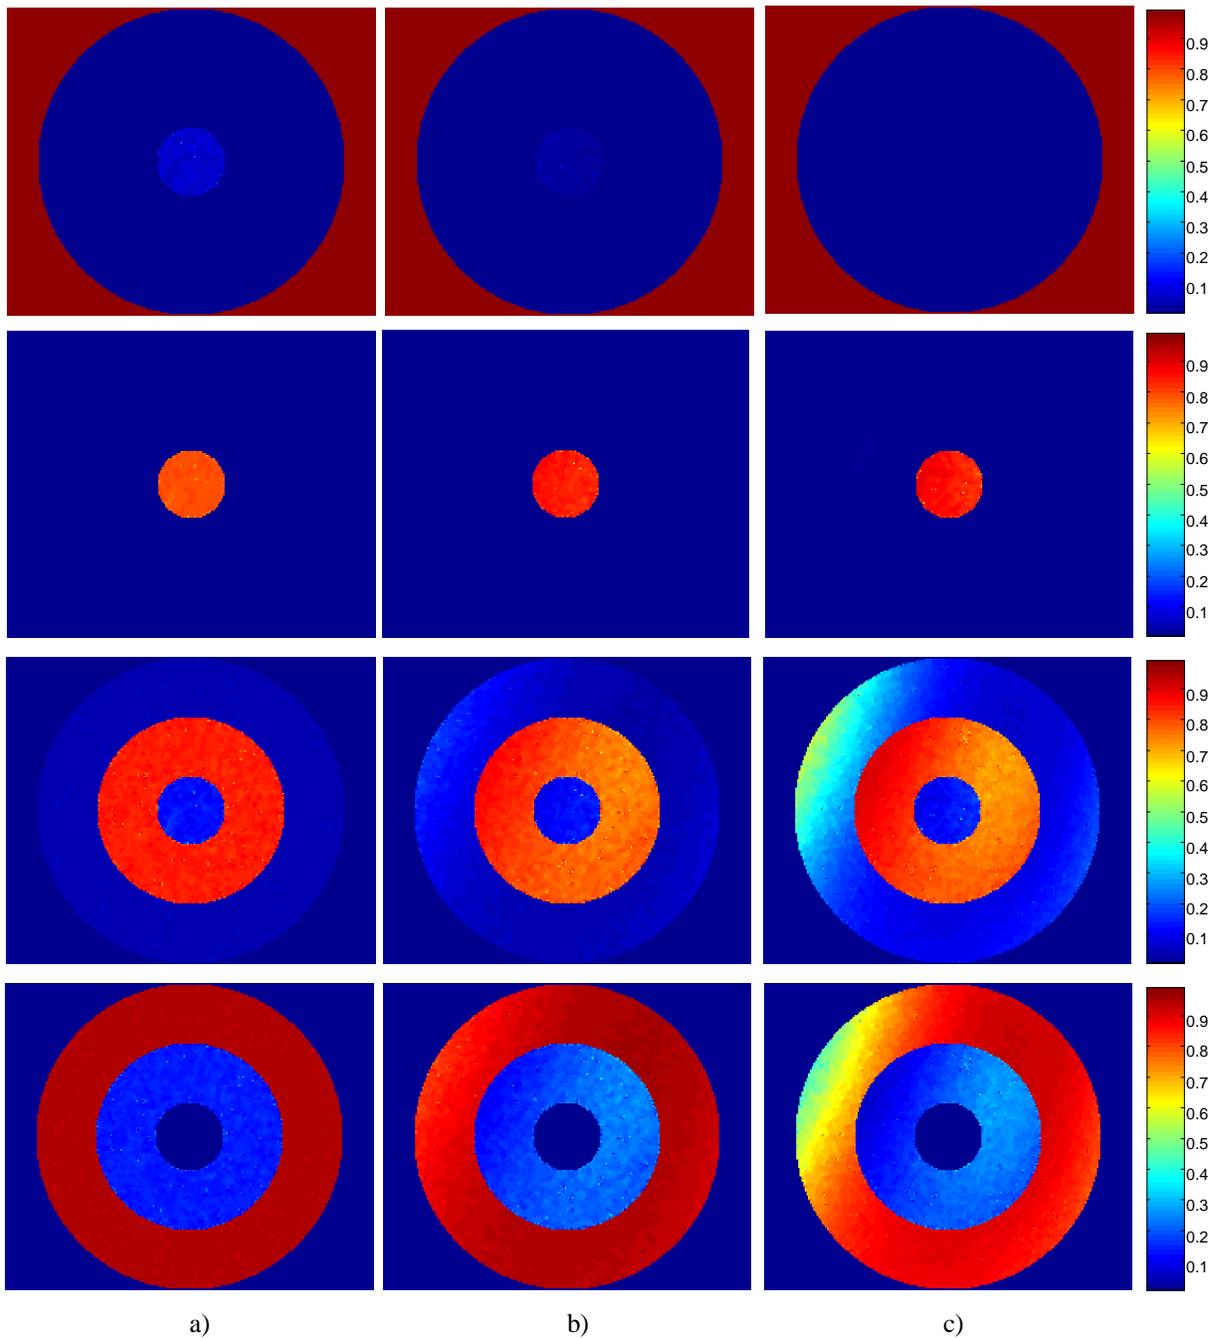


Figura 6.2. Imágenes de aspecto de las probabilidades posteriores obtenidas para cada clase en una imagen de prueba. a) 3% ruido y 0% de campo de ganancia. b) 3% ruido y 20% de campo de ganancia. c) 3% ruido y 40% de campo de ganancia.

6.4. RESULTADOS DEL FACTOR DE CONFIANZA EN LA CLASIFICACIÓN.

Se calculó un factor de confianza para cada píxel de la imagen de prueba, entonces, al igual que con los estimados de probabilidades a posteriori, se puede generar una imagen que represente el grado de confiabilidad en la clasificación. La figura 6.3, muestra diferentes imágenes de factores de confianza para diferentes niveles de campo de ganancia y de ruido aditivo, también se muestran las segmentaciones obtenidas a fin de verificar que los factores de confianza ofrecen una buena medida cuantitativa de la clasificación.

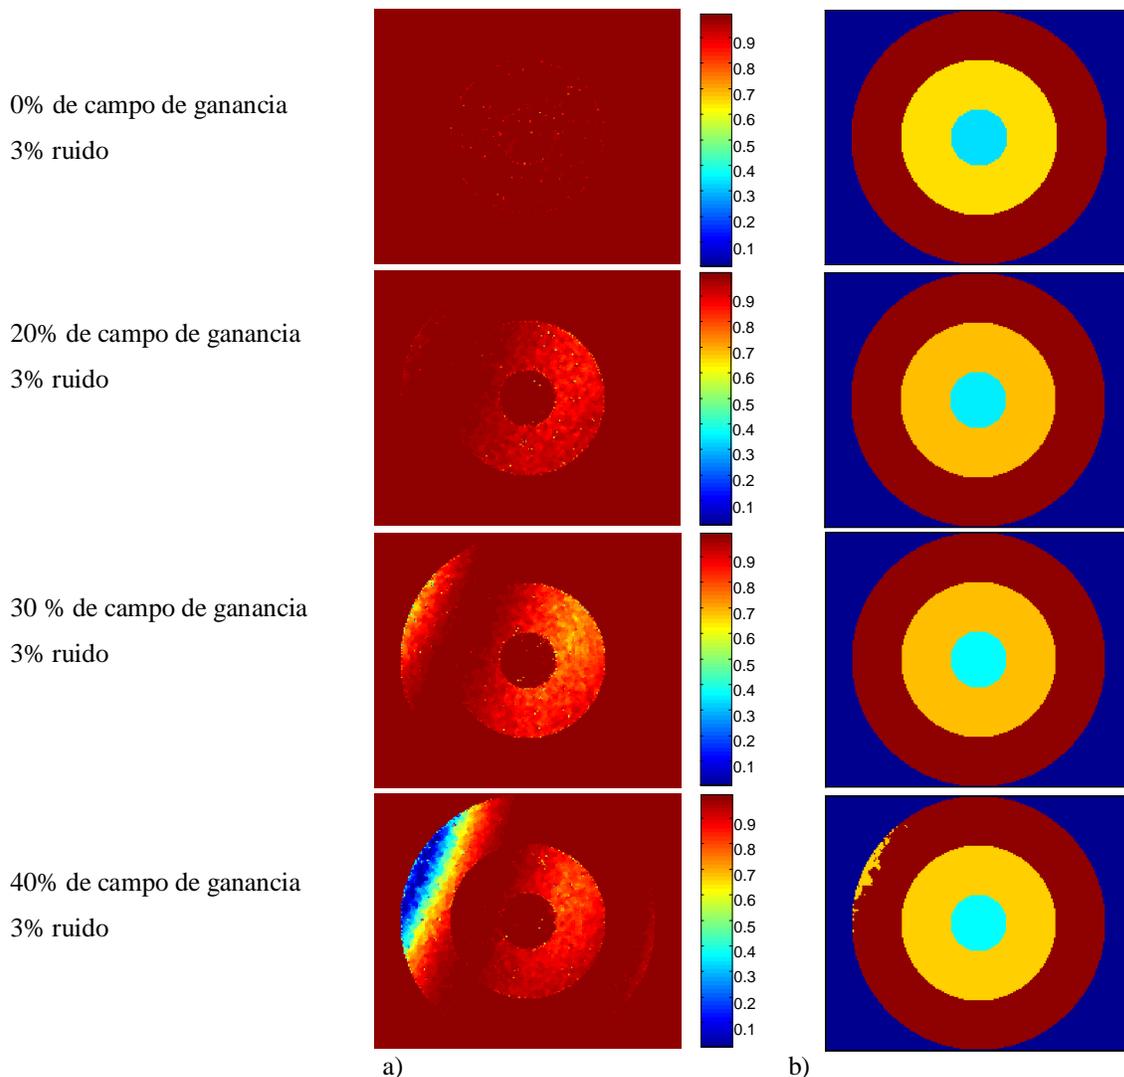


Figura 6.3. Evaluación de la clasificación. a) Aspecto con los Factores de Confianza. b) Segmentaciones obtenidas.

Las imágenes de los factores de confianza mostradas en la figura 6.3 se despliegan en una escala de color de 0 a 1, donde el valor de 1 corresponde a un factor de confianza de 1 y un tono de color rojo, por lo tanto, se aprecia que a medida que el factor de confianza aumenta se mejora la segmentación.

6.5. ANÁLISIS DE SUSCEPTIBILIDAD A VARIACIÓN DE LOS PARÁMETROS.

Como es deseable realizar una restauración y una segmentación de la imagen de manera automática, es muy importante presentar un análisis de susceptibilidad a la variación de los parámetros en la metodología para considerar sus limitaciones.

Es necesario que dicho análisis se realice por una parte en condiciones lo más parecido posible a las situaciones reales y, por otra parte, sin perder los datos del experimento entre las alteraciones hechas a la imagen y sus valores ideales. Por estas razones se utiliza una imagen sintética de IRM, que permite observar la sensibilidad del método. La figura 6.4 muestra una imagen sintética de IRM, obtenida del conjunto de imágenes disponibles en el simulador del Instituto de Neurología de Montreal – Universidad de McGill [45, 46]. La imagen de prueba está contaminada con un 20% de nivel de campo de ganancia y un 3% de nivel de ruido aditivo (valores comunes en la práctica).

6.5.1. Tamaño de las Ventanas de Datos y de Análisis en el Algoritmo de Modas Realzadas.

El algoritmo de Modas Realzadas, que actúa como extractor de características generando los vectores de entrada a la red neuronal, hace un compromiso entre considerar tanto información local (ventanas de análisis, $w_{a_{x,y}}$) como global (ventanas de datos, $w_{d_{x,y}}$). Un primer aspecto a analizar es la sensibilidad al tamaño de dichas ventanas. En la figura 6.4 se muestra la segmentación ideal y las segmentaciones obtenidas para distintos valores de las ventanas.

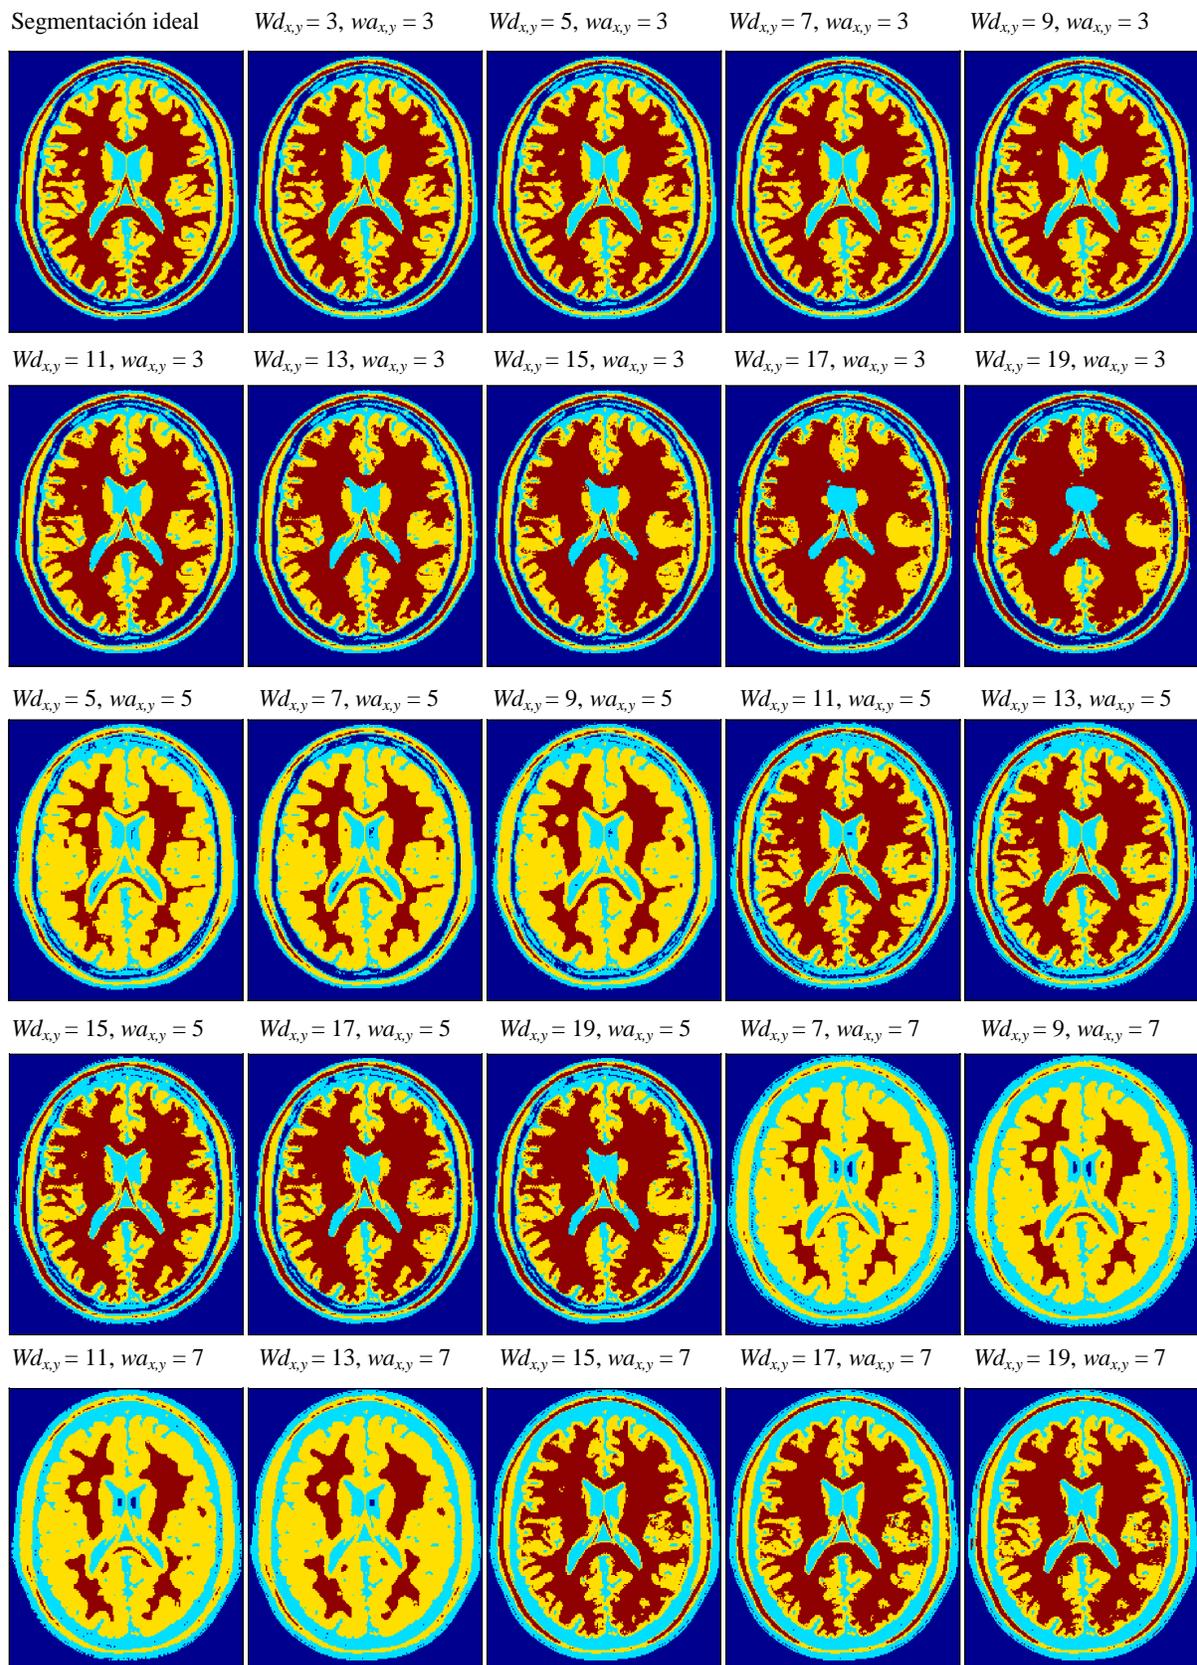


Figura 6.4. Análisis de sensibilidad al tamaño de las ventanas de datos y de análisis.

Para caracterizar cuantitativamente el tamaño de las ventanas de datos y de análisis se obtuvieron las matrices de confusión y sus valores de Kappa correspondientes para cada una de las segmentaciones anteriores, tanto para todos los píxeles de la imagen (TI) como para aquellos pertenecientes a la región de interés (ROI) formada por materia gris, materia blanca y líquido cefalorraquídeo; en las tablas 6.3 y 6.4 se pueden observar dichos resultados.

$w_{a,x,y}$	$w_{d,x,y}$	Matriz de confusión en la región de interés (ROI)				Kappa (ROI)	Matriz de confusión en toda la imagen (TI)				Kappa (TI)	
3	3	100.00	0	0	0	0.9626	99.80	0.19	0	0	0.9420	
		1.30	92.52	6.17	0		7.15	89.00	3.83	0		
		0	0.48	92.53	6.98		0	2.22	92.25	5.52		
		0	0	2.01	97.98		0	0	2.67	97.32		
		5	100.00	0	0	0	0.9623	99.80	0.19	0	0	0.9419
		1.34	92.41	6.24	0	7.18		88.91	3.89	0		
		0	0.45	92.07	7.46	0		2.16	91.91	5.91		
		0	0	1.71	98.28	0		0	2.35	97.64		
		7	100.00	0	0	0	0.9648	99.79	0.20	0	0	0.9441
	1.30	92.37	6.31	0	7.07	88.93		3.98	0			
	0	0.41	93.73	5.84	0	2.05		93.30	4.63			
	0	0	2.34	97.65	0	0		3.00	96.99			
	9	100.00	0	0	0	0.9552	99.79	0.20	0	0	0.9348	
	1.30	91.68	7.00	0	7.39		88.07	4.53	0			
	0	0.69	90.23	9.06	0		2.24	90.58	7.17			
	0	0	1.95	98.04	0		0	2.58	97.41			
	11	100.00	0	0	0	0.9369	99.78	0.21	0	0	0.9187	
	1.19	90.88	7.69	0.21	7.30		87.64	4.94	0.11			
	0	0.76	84.88	14.34	0		2.30	86.42	11.27			
	0	0	2.43	97.56	0		0	2.87	97.12			
	13	100.00	0	0	0	0.9103	99.80	0.19	0	0	0.8942	
	1.52	87.90	8.85	1.70	8.03		85.65	5.42	0.88			
	0	0.73	77.56	21.69	0		2.32	80.63	17.03			
	0	0.01	2.92	97.06	0		0	3.16	96.82			
	15	100.00	0	0	0	0.8844	99.85	0.14	0	0	0.8686	
	1.81	82.28	9.73	6.17	9.38		81.80	5.63	3.18			
	0	0.93	71.15	27.90	0		2.70	75.37	21.91			
	0	0.01	3.14	96.84	0		0	3.29	96.69			
	17	99.98	0	0.01	0	0.8586	99.86	0.10	0.02	0	0.8362	
	1.81	78.06	8.60	11.51	12.93		76.22	4.90	5.93			
	0	1.22	64.26	34.51	0.40		3.18	69.10	27.30			
	0	0.02	3.30	96.66	0		0.01	3.32	96.65			
	19	99.97	0	0.02	0	0.8325	99.87	0.08	0.04	0	0.8059	
	2.06	73.67	7.58	16.66	15.93		71.07	4.39	8.59			
	0	1.35	57.01	41.63	0.80		3.05	62.97	33.15			
	0	0.06	3.14	96.78	0.03		0.05	3.04	96.86			
5	5	99.97	0.02	0	0	0.8019	95.31	4.68	0	0	0.7572	
		1.08	91.86	7.04	0		1.04	94.51	4.43	0		
	0	0.36	99.54	0.09	0		1.95	97.97	0.07			
	0	0	51.63	48.36	0		0	54.42	45.57			
	7	100.00	0	0	0	0.8182	99.59	0.40	0	0	0.7815	
	2.61	89.46	7.91	0	8.36		86.59	5.03	0			
	0	0.25	99.69	0.05	0		1.65	98.30	0.04			
	0	0	46.53	53.46	0		0	49.18	50.81			

Tabla 6.3. Matrices de confusión y sus valores de Kappa correspondientes para distintos valores de las ventanas de datos y de análisis.

$w_{a,y}$	$Wd_{x,y}$	Matriz de confusión en la región de interés (ROI)				Kappa (ROI)	Matriz de confusión en toda la imagen (TI)				Kappa (TI)		
5	9	99.96	0.03	0	0	0.8335	94.42	5.57	0	0	0.7867		
		0.58	91.68	7.73	0		0.52	94.55	4.92	0			
		0	0.26	99.73	0		0	1.72	98.27	0			
		0	0	42.98	57.01		0	0	45.74	54.25			
	11	99.95	0.04	0	0		0.9574	90.71	8.70	0		0.58	0.9078
		0.43	92.37	7.18	0			0.24	95.20	4.51		0.03	
	0	0.38	91.83	7.77	0	1.96		91.91	6.11				
	0	0	2.76	97.23	0	0		3.40	96.59				
13	99.95	0.04	0	0	0.9565	89.02		10.96	0	0.01	0.8994		
	0	91.83	8.16	0		0		94.83	5.16	0			
	0	0.33	92.51	7.14		0	1.73	92.66	5.60				
	0	0	3.38	96.61		0	0	4.08	95.91				
15	99.96	0.03	0	0		0.9406	94.06	5.93	0	0		0.9093	
	0	91.57	8.09	0.32			0.09	94.72	5.01	0.16			
	0	0.64	85.26	14.09	0		2.08	86.86	11.04				
	0	0	1.86	98.13	0		0	2.34	97.65				
17	99.96	0.03	0	0	0.9228		94.79	5.20	0	0	0.8953		
	0	88.34	9.69	1.96			0.76	91.93	6.29	1.01			
	0	0.64	80.08	19.26		0	1.85	83.00	15.13				
	0	0.01	1.60	98.38		0	0	2.06	97.93				
19	99.96	0.03	0	0		0.9060	95.08	4.88	0	0.02		0.8807	
	0	84.60	9.91	5.48			1.44	89.40	6.32	2.82			
	0	0.73	75.46	23.79	0		1.91	79.43	18.65				
	0	0.02	1.34	98.63	0		0.01	1.80	98.17				
7	7	99.90	0.09	0	0		0.7507	73.05	26.95	0	0		0.6089
		2.21	85.29	12.49	0			1.14	90.20	8.65	0		
		0	0.12	99.74	0.13	0		0.77	99.12	0.10			
		0	0	63.89	36.10	0		0	67.50	32.49			
	9	99.903	0.09	0	0	0.7681		71.74	28.25	0	0	0.6193	
		2.28	88.19	9.51	0			1.17	92.69	6.12	0		
		0	0.22	99.62	0.14		0	1.34	98.54	0.11			
		0	0	59.83	40.16		0	0	63.88	36.11			
11	99.90	0.09	0	0	0.7763		72.69	27.30	0	0	0.6310		
	1.85	88.59	9.54	0			0.95	92.82	6.21	0			
	0	0.22	99.77	0		0	1.33	98.66	0				
	0	0	57.79	42.20		0	0	61.95	38.04				
13	99.90	0.09	0	0		0.7777	72.35	27.64	0	0		0.6320	
	0.72	89.21	10.05	0			0.37	93.03	6.59	0			
	0	0.21	99.78	0	0		1.26	98.73	0				
	0	0	57.63	42.36	0		0	61.48	38.51				
15	99.90	0.09	0	0	0.9352		72.41	27.58	0	0	0.8068		
	0	91.24	8.42	0.32			0.01	94.40	5.41	0.16			
	0	0.26	84.70	15.03		0	1.52	86.79	11.67				
	0	0	2.66	97.33		0	0	3.51	96.48				
17	99.90	0.09	0	0		0.9300	73.23	26.76	0	0		0.8057	
	0	91.83	7.84	0.32			0.13	94.66	5.03	0.16			
	0	0.33	82.31	17.35	0		1.66	84.85	13.48				
	0	0	2.34	97.65	0		0	3.16	96.83				
19	99.90	0.09	0	0	0.9278		72.40	27.06	0	0.52	0.7993		
	0	91.83	7.73	0.43			0.03	94.45	4.94	0.56			
	0	0.42	81.75	17.81		0	1.77	84.26	13.95				
	0	0	2.49	97.50		0	0	3.26	96.73				

Tabla 6.4. Matrices de confusión y sus valores de Kappa correspondientes para distintos valores de las ventanas de datos y de análisis (continuación).

Los valores más grandes de Kappa corresponden a $w_{a_{x,y}}=3$ y $Wd_{x,y}<9$. Para apreciar de mejor manera los resultados en la figura 6.5 se muestra la gráfica de Kappa contra el tamaño de la ventana de datos, se observa que el mejor valor de Kappa ocurre cuando $Wd_{x,y}=7$ y $w_{a_{x,y}}=3$.

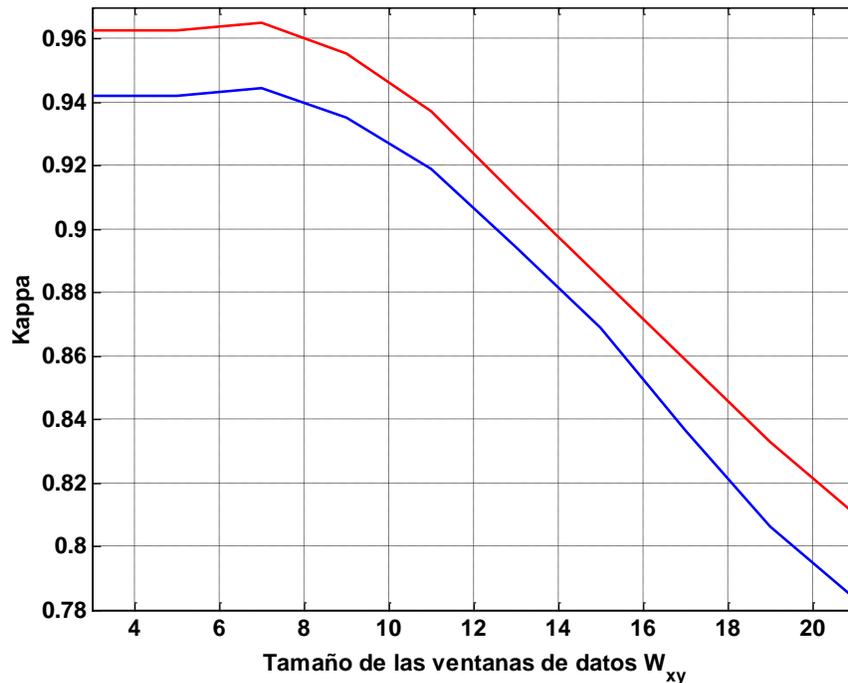


Figura 6.5 Análisis de sensibilidad al tamaño de las ventanas de datos y con $w_{a_{x,y}} = 3$.
ROI en color rojo, TI en color azul.

6.5.2. Nivel del Umbral para la Desviación Estándar Máxima Permitida.

El algoritmo de Modas Realzadas es utilizado no sólo como extractor de características sino que al mismo tiempo elimina el ruido aditivo en la imagen. Sin embargo, en los bordes entre diferentes clases de la imagen se presentan variaciones muy altas de la desviación estándar lo que genera clases falsas en el espacio de características y los consecuentes errores de clasificación. La figura 6.6, muestra los resultados del algoritmo de Corrimiento de Media (para la misma imagen sintética de IRM utilizada anteriormente) cuando no se aplica ningún

criterio de corrección en los bordes tanto para la imagen de modas realzadas $\vec{\theta}_{EM}$ como para la imagen de los valores de dispersión \vec{S}_{EM} . Hay que recordar que el valor real de desviación estándar es 3 ó para el espacio de características $\vec{S}_{EM} * 10 = 30$.

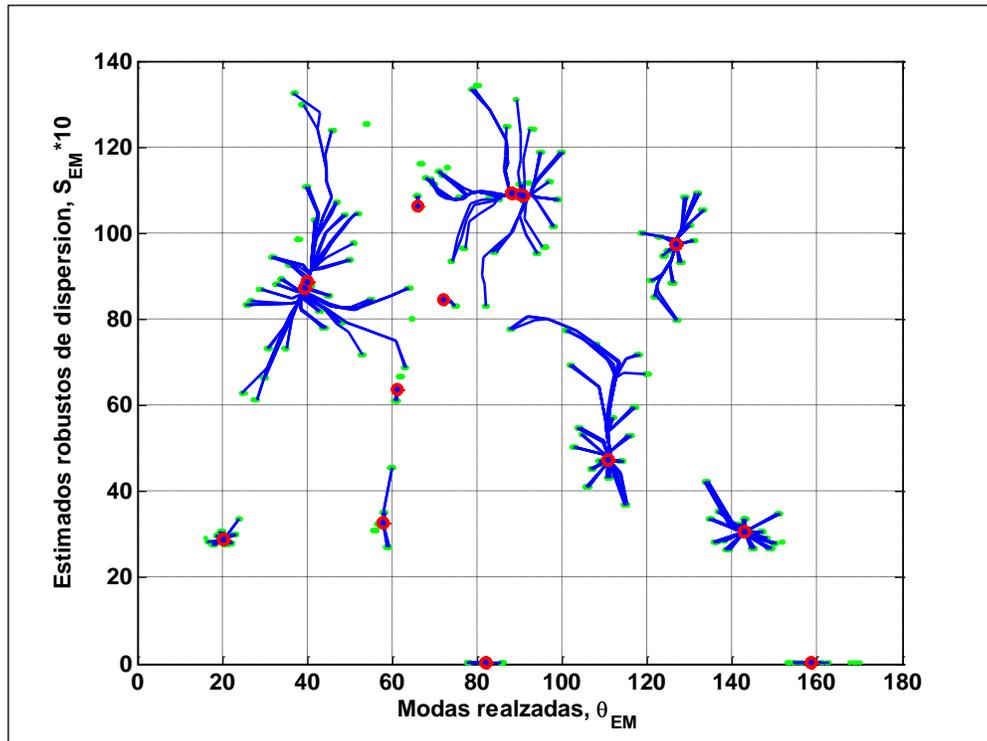


Figura 6.6 Clases encontradas por el algoritmo de Corrimiento de Media, se aprecia la generación de clases falsas cuando no se realiza la corrección de bordes en las imágenes de $\vec{\theta}_{EM}$ y \vec{S}_{EM} .

La figura 6.7 muestra las segmentaciones resultantes al aplicar la corrección de los bordes en las imágenes de $\vec{\theta}_{EM}$ y de \vec{S}_{EM} mediante diferentes valores del umbral de censurado para la desviación estándar máxima permitida; en algunos casos se obtuvieron clases adicionales y fue necesario mezclarlas con sus similares a fin de tener el mismo número de clases en la comparación (se muestran ejemplos A y B de las mezclas realizadas). Se aprecia que la calidad de las segmentaciones disminuye a medida que el valor del umbral se incrementa por arriba de 2. En las tablas 6.5 y 6.6, se puede observar el análisis cuantitativo a detalle (matrices de confusión y sus valores de Kappa correspondientes) ante las variaciones del umbral. Las figuras 6.8 y 6.9 muestran gráficamente los valores de Kappa obtenidos para ilustrar la sensibilidad al valor del umbral de censurado para la desviación estándar.

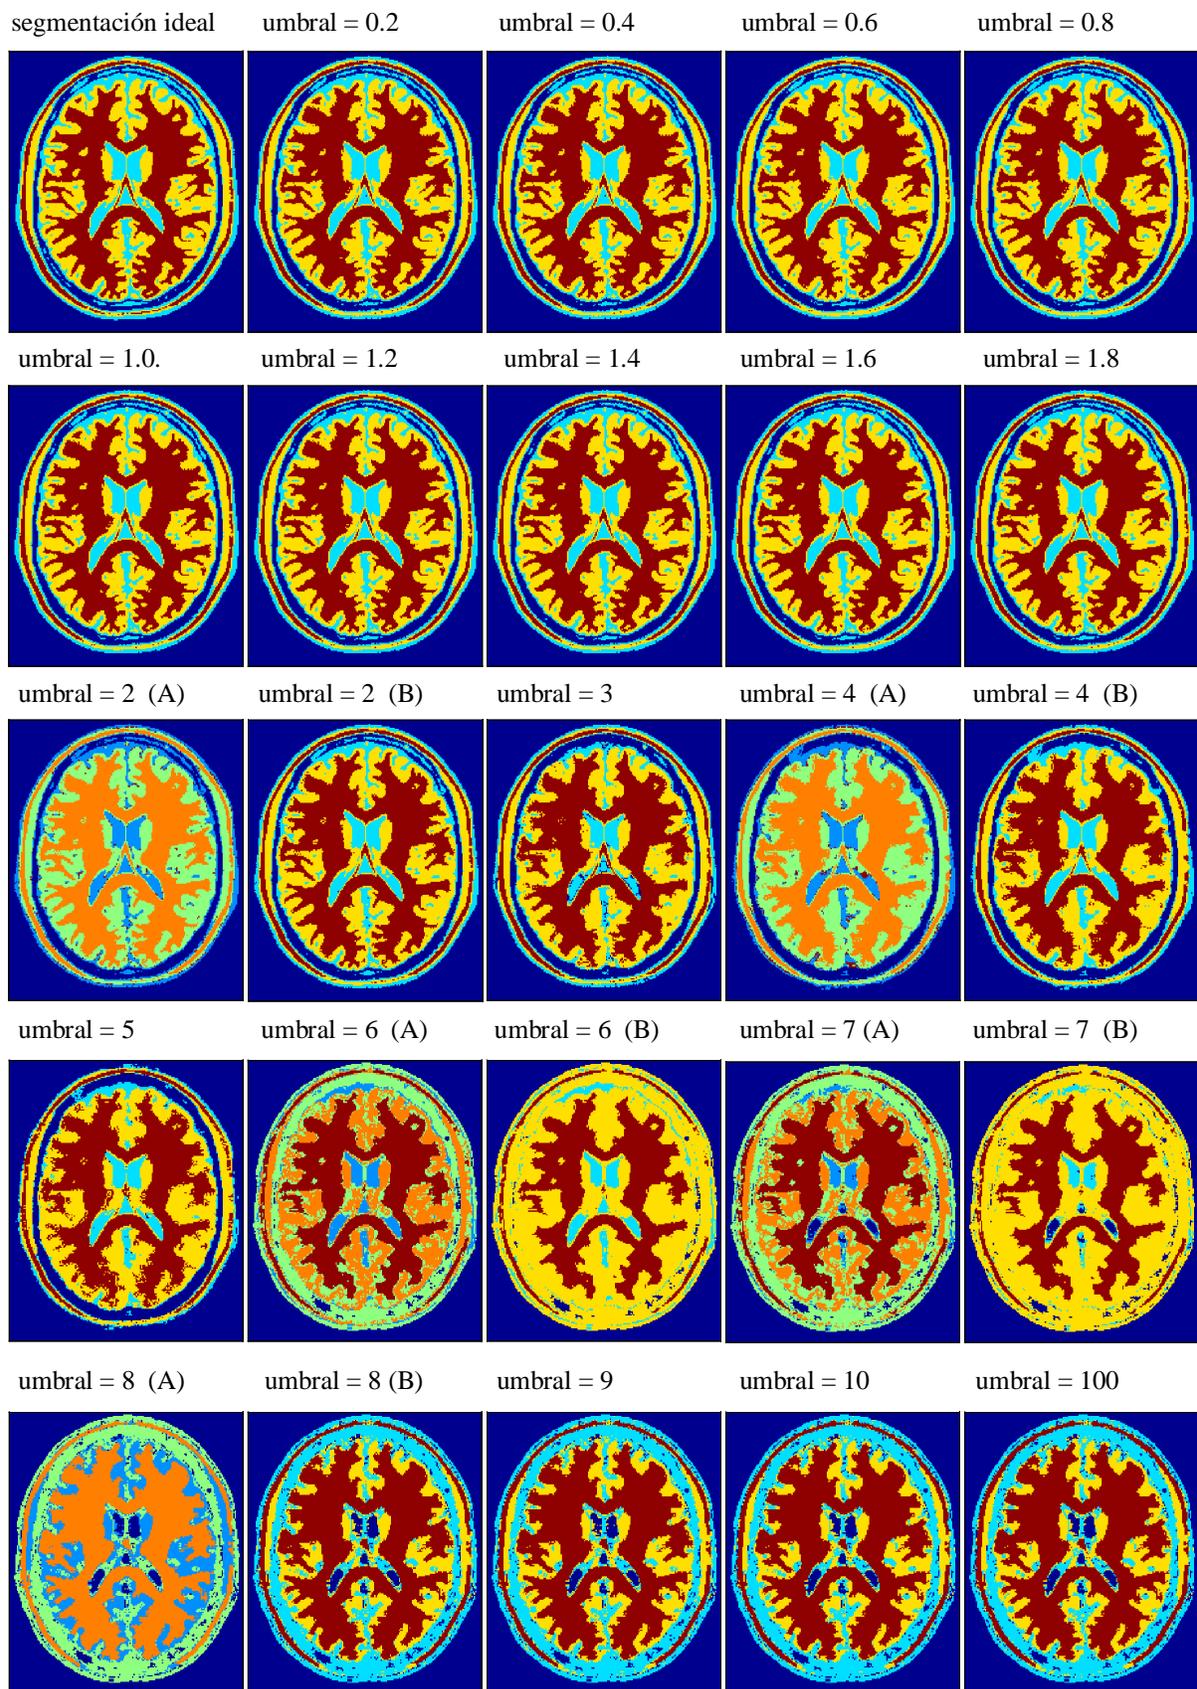


Figura 6.7 Efecto en la segmentación por la variación del umbral de censurado para la desviación estándar.

Umbral para el censurado de la desv. estándar	Matriz de confusión en la región de interés (ROI)				Kappa (ROI)	Matriz de confusión en toda la imagen (TI)				Kappa (TI)
0.2	100.00	0	0	0	0.9620	99.88	0.11	0	0	0.9399
	1.63	92.12	6.24	0		8.33	87.75	3.91	0	
	0	0.42	92.07	7.49		0	2.12	91.94	5.93	
	0	0	1.71	98.28		0	0	2.40	97.59	
0.4	100.00	0	0	0	0.9620	99.87	0.12	0	0	0.9402
	1.63	92.08	6.28	0		8.21	87.83	3.95	0	
	0	0.42	92.04	7.52		0	2.10	91.94	5.95	
	0	0	1.68	98.31		0	0	2.36	97.63	
0.6	100.00	0	0	0	0.9547	99.70	0.29	0	0	0.9369
	0.72	83.33	15.94	0		5.76	83.16	11.06	0	
	0	0.05	93.53	6.40		0	0.45	94.47	5.07	
	0	0	2.27	97.72		0	0	2.96	97.03	
0.8	100.00	0	0	0	0.9623	99.81	0.18	0	0	0.9415
	1.45	91.72	6.82	0		7.43	88.27	4.28	0	
	0	0.40	92.79	6.79		0	2.00	92.62	5.37	
	0	0	2.09	97.90		0	0	2.79	97.20	
1	100.00	0	0	0	0.9628	99.79	0.20	0	0	0.9425
	1.23	91.61	7.15	0		7.02	88.48	4.49	0	
	0	0.36	93.17	6.46		0	1.94	92.94	5.11	
	0	0	2.20	97.79		0	0	2.90	97.09	
1.2	100.00	0	0	0	0.9624	99.79	0.20	0	0	0.9424
	1.19	91.21	7.58	0		6.96	88.22	4.81	0	
	0	0.29	93.14	6.55		0	1.77	93.03	5.18	
	0	0	2.17	97.82		0	0	2.85	97.14	
1.4	100.00	0	0	0	0.9638	99.79	0.20	0	0	0.9436
	1.19	91.28	7.51	0		6.96	88.31	4.71	0	
	0	0.30	93.79	5.89		0	1.80	93.51	4.68	
	0	0	2.33	97.66		0	0	3.01	96.98	
1.6	100.00	0	0	0	0.9648	99.79	0.20	0	0	0.9441
	1.30	92.37	6.31	0		7.07	88.93	3.98	0	
	0	0.41	93.73	5.84		0	2.05	93.30	4.63	
	0	0	2.34	97.65		0	0	3.003	96.99	
1.8	100.00	0	0	0	0.9631	99.79	0.20	0	0	0.9426
	1.30	92.41	6.28	0		7.11	88.97	3.91	0	
	0	0.46	93.37	6.15		0	2.16	92.93	4.89	
	0	0	2.52	97.47		0	0	3.09	96.90	
2	100.00	0	0	0	0.9529	99.85	0.14	0	0	0.9304
	2.39	89.21	8.38	0		10.16	84.42	5.41	0	
	0	0.25	91.15	8.59		0	1.48	91.60	6.90	
	0	0	2.58	97.41		0	0	2.91	97.08	
3	100.00	0	0	0	0.9164	99.92	0.07	0	0	0.8835
	12.67	77.41	9.91	0		22.16	71.54	6.29	0	
	0.10	0.42	87.59	11.86		0.15	1.90	88.40	9.53	
	0	0	6.11	93.88		0	0	5.96	94.03	
4	100.00	0	0	0	0.9125	99.62	0.37	0	0	0.8691
	6.57	80.53	12.89	0		21.43	70.69	7.86	0	
	0	1.48	85.39	13.11		0	3.29	86.30	10.39	
	0	0	6.38	93.61		0	0	7.09	92.90	
5	100.00	0	0	0	0.8868	99.75	0.24	0	0	0.8207
	10.49	66.26	23.20	0.03		32.70	52.57	14.69	0.01	
	0.09	1.27	85.66	12.96		0.21	3.09	85.91	10.76	
	0	0	9.29	90.70		0	0	10.35	89.63	

Tabla 6.5. Matrices de confusión y sus valores de Kappa correspondientes para distintos valores del umbral de censurado de la desviación estándar.

Umbral para el censurado de la desv. estándar	Matriz de confusión en la región de interés (ROI)				Kappa (ROI)	Matriz de confusión en toda la imagen (TI)				Kappa (TI)
6	99.90	0	0.09	0	0.8676	81.37	0.10	18.51	0	0.7029
	0	45.75	54.24	0		0.09	34.65	65.25	0	
	0	0.44	94.97	4.58		0	1.61	94.41	3.97	
	0	0	15.79	84.20		0	0	17.88	82.11	
7	99.90	0	0.09	0	0.8477	81.51	0.05	18.42	0	0.6744
	8.42	28.54	63.03	0		6.79	20.85	72.34	0	
	0.02	0.42	94.95	4.58		0.17	1.15	94.53	4.13	
	0	0	15.92	84.07		0	0	18.48	81.51	
8	99.90	0.091	0	0	0.8349	81.14	18.81	0.03	0	0.7101
	23.38	60.13	16.26	0.21		16.88	72.12	10.82	0.16	
	0.67	13.56	62.83	22.92		1.40	18.77	59.12	20.69	
	0.02	0.09	2.90	96.97		0.02	0.60	3.32	96.03	
9	99.90	0.09	0	0	0.8387	80.92	19.01	0.05	0	0.7128
	23.20	59.51	17.06	0.21		16.75	71.69	11.38	0.16	
	0.67	12.02	64.37	22.92		1.39	17.23	60.54	20.82	
	0.02	0.06	2.93	96.97		0.02	0.54	3.41	96.00	
10	99.90	0.09	0	0	0.8337	80.91	19.01	0.06	0	0.7048
	24.61	61.11	14.05	0.21		17.63	72.45	9.66	0.24	
	0.87	14.11	62.08	22.92		1.80	19.38	57.64	21.16	
	0.02	0.09	2.90	96.97		0.03	0.66	3.25	96.04	
100	99.90	0.09	0	0	0.8395	80.96	18.97	0.05	0	0.7109
	24.61	60.85	14.30	0.21		17.67	72.49	9.32	0.50	
	0.87	12.02	64.17	22.92		1.81	17.10	59.46	21.61	
	0.02	0.06	2.93	96.97		0.03	0.55	3.37	96.03	

Tabla 6.6. Matrices de confusión y sus valores de Kappa correspondientes para distintos valores del umbral de censurado de la desviación estándar (continuación).

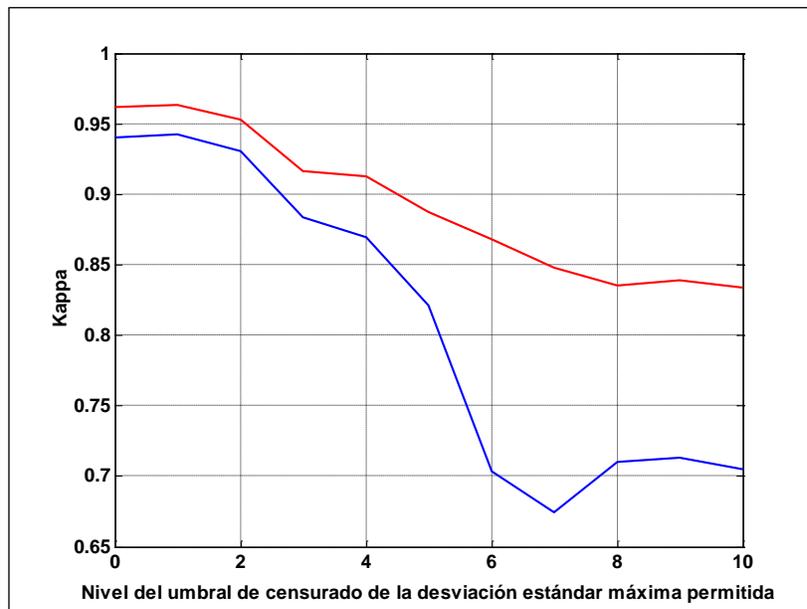


Figura 6.8 Sensibilidad a la variación del umbral de censurado de la desviación estándar. Para valores del umbral menores a 2 se obtienen mejores segmentaciones. ROI en color rojo, TI en color azul.

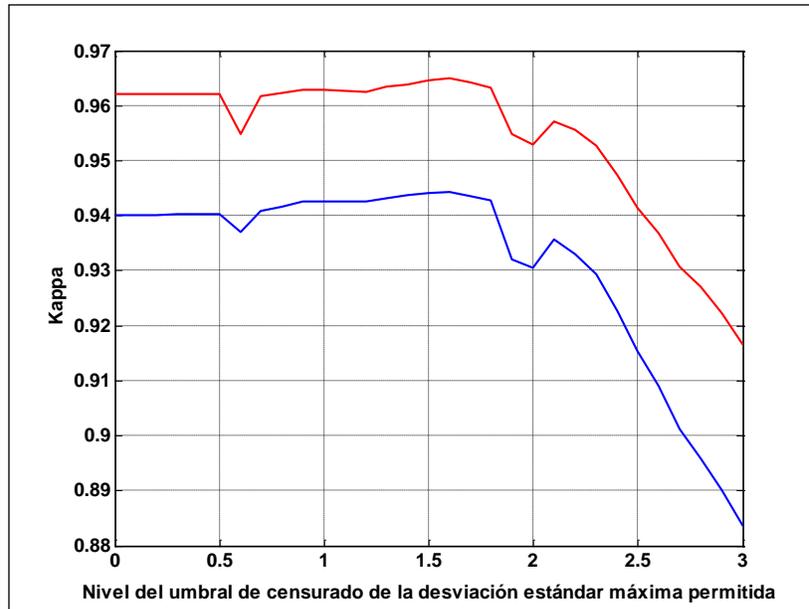


Figura 6.9 Cuando el umbral de censurado de desviación estándar =1.6 el valor de Kappa es máximo. ROI en color rojo, TI en color azul.

6.5.3. Ajuste del Radio del Kernel para el Algoritmo de Corrimiento de Media.

La búsqueda de las clases principales en la imagen se realiza con el algoritmo de Corrimiento de Media, el ajuste del radio del Kernel es esencial para el buen desempeño de dicha labor. En las figuras 6.10, 6.11, 6.12 y 6.13, se muestran los resultados del algoritmo de Corrimiento de Media para diferentes radios del Kernel. En la figura 6.14 se muestran las segmentaciones obtenidas con las variaciones en el radio, aclarando que en algunos casos se obtuvo un número de clases mayor al de la segmentación de referencia, por lo cual, fue necesario mezclar las clases más parecidas a fin de obtener una aproximación cuantitativa. En las tablas 6.7 y 6.8 se muestra el análisis cuantitativo para el radio del Kernel.

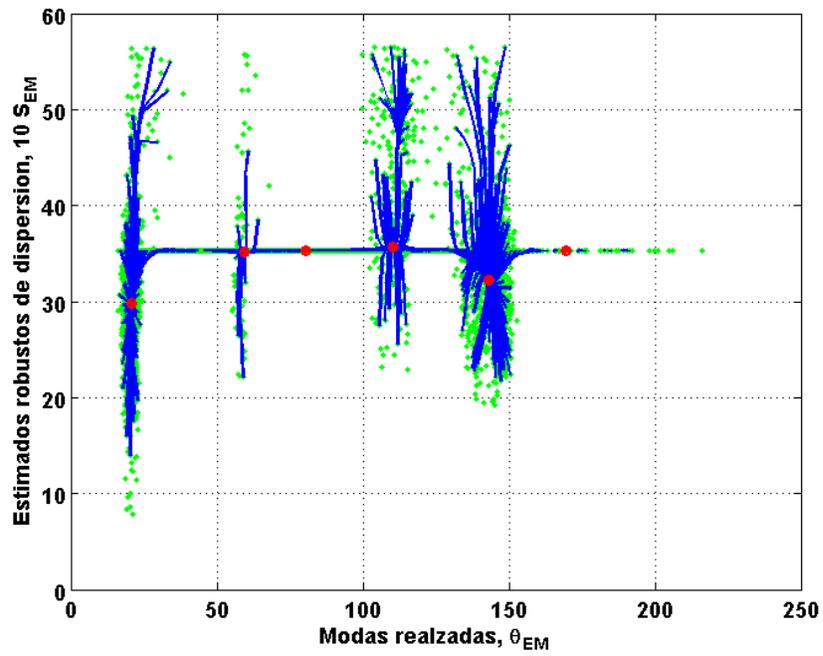


Figura 6.10 Resultados del algoritmo de Corrimiento de Media para un radio del Kernel de 10. Datos en color verde, trayectorias de corrimiento de media en color azul y clases encontradas en color rojo.

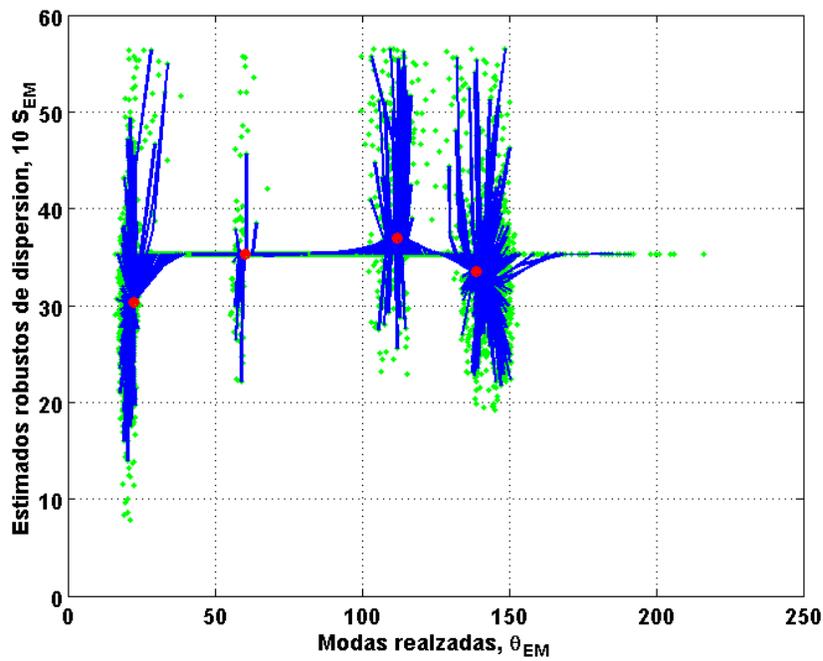


Figura 6.11 Resultados del algoritmo de Corrimiento de Media para un radio del Kernel de 20. Datos en color verde, trayectorias de corrimiento de media en color azul y clases encontradas en color rojo.

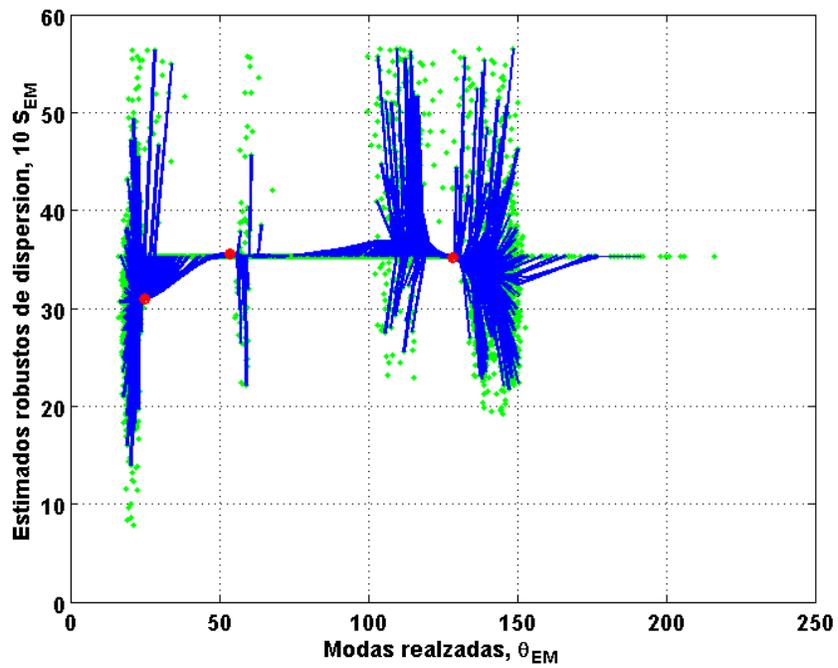


Figura 6.12 Resultados del algoritmo de Corrimiento de Media para un radio del Kernel de 30. Datos en color verde, trayectorias de corrimiento de media en color azul y clases encontradas en color rojo.

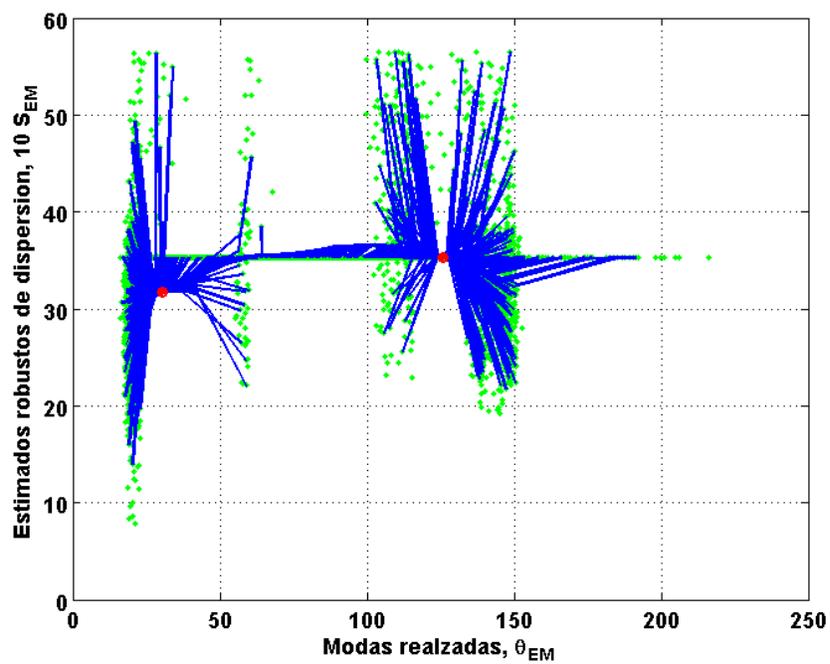


Figura 6.13 Resultados del algoritmo de Corrimiento de Media para un radio del Kernel de 40. Datos en color verde, trayectorias de corrimiento de media en color azul y clases encontradas en color rojo.

Radio	Matriz de confusión en la región de interés (ROI)				Kappa (ROI)	Matriz de confusión en toda la imagen (TI)				Kappa (TI)
5	100.00	0	0	0	0.9613	99.80	0.19	0	0	0.9403
	1.41	93.50	5.08	0		7.37	89.49	3.12	0	
	0	0.67	91.01	8.31		0	2.67	90.73	6.59	
	0	0	1.47	98.52		0	0	2.00	97.99	
10	100.00	0	0	0	0.9596	99.89	0.10	0	0	0.9369
	1.77	86.34	11.87	0		9.19	82.73	8.06	0	
	0	0.17	95.02	4.80		0	0.90	95.30	3.78	
	0	0	3.00	96.99		0	0	3.74	96.25	
15	100.00	0	0	0	0.9599	99.91	0.08	0	0	0.9374
	1.88	87.69	10.42	0		9.38	83.65	6.96	0	
	0	0.21	93.48	6.30		0	1.17	93.82	5.00	
	0	0	2.08	97.91		0	0	2.74	97.25	
16	100.00	0	0	0	0.9640	99.78	0.21	0	0	0.9438
	1.19	90.84	7.95	0		6.90	88.03	5.05	0	
	0	0.24	94.58	5.17		0	1.64	94.23	4.12	
	0	0	2.77	97.22		0	0	3.46	96.53	
17	100.00	0	0	0	0.9642	99.78	0.21	0	0	0.9440
	1.19	90.84	7.95	0		6.92	88.01	5.05	0	
	0	0.24	94.44	5.30		0	1.63	94.14	4.22	
	0	0	2.62	97.37		0	0	3.30	96.69	
18	100.00	0	0	0	0.9643	99.79	0.20	0	0	0.9439
	1.23	90.95	7.80	0		7.00	88.01	4.98	0	
	0	0.25	94.47	5.26		0	1.67	94.13	4.19	
	0	0	2.64	97.35		0	0	3.34	96.65	
19	100.00	0	0	0	0.9643	99.79	0.20	0	0	0.9439
	1.30	91.75	6.93	0		7.03	88.59	4.36	0	
	0	0.38	93.77	5.83		0	1.96	93.40	4.62	
	0	0	2.33	97.66		0	0	2.99	97.00	
20	100.00	0	0	0	0.9643	99.79	0.20	0	0	0.9438
	1.30	92.41	6.28	0		7.09	88.95	3.95	0	
	0	0.42	92.96	6.61		0	2.10	92.64	5.24	
	0	0	1.87	98.12		0	0	2.52	97.47	
21	100.00	0	0	0	0.9655	99.79	0.20	0	0	0.9438
	1.30	93.60	5.08	0		7.03	89.83	3.12	0	
	0	0.67	93.63	5.69		0	2.67	92.79	4.52	
	0	0	2.42	97.57		0	0	3.08	96.91	
22	100.00	0	0	0	0.9648	99.79	0.20	0	0	0.9432
	1.30	93.28	5.41	0		7.09	89.55	3.35	0	
	0	0.63	93.10	6.26		0	2.58	92.44	4.97	
	0	0	2.12	97.87		0	0	2.78	97.21	
23	100.00	0	0	0	0.9648	99.79	0.20	0	0	0.9414
	1.30	95.27	3.41	0		7.03	90.91	2.04	0	
	0	1.30	92.16	6.52		0	3.87	90.93	5.18	
	0	0	1.94	98.05		0	0	2.58	97.41	
24	100.00	0	0	0	0.7060	99.78	0.21	0	0	0.6484
	1.19	98.80	0	0		6.87	93.12	0	0	
	0	24.29	0	75.70		0	31.54	0	68.45	
	0	0	0	100.00		0	0.01	0	99.98	
25	100.00	0	0	0	0.7049	99.78	0.21	0	0	0.6471
	1.16	98.83	0	0		6.83	93.16	0	0	
	0	16.21	0	83.78		0	22.60	0	77.39	
	0	0	0	100.00		0	0	0	100.00	

Tabla 6.7. Matrices de confusión y sus valores de Kappa correspondientes para distintos radios del Kernel en el algoritmo de Corrimiento de Media..

Radio	Matriz de confusión en la región de interés (ROI)				Kappa (ROI)	Matriz de confusión en toda la imagen (TI)				Kappa (TI)	
30	100.00	0	0	0	0.7029	99.76	0.23	0	0	0.6448	
	1.08	98.51	0	0.39			6.59	93.16	0		0.24
	0	5.13	0	94.86			0	9.26	0		90.73
	0	0	0	100.00			0	0	0		100.00
35	100.00	0	0	0	0.7018	99.91	0.08	0	0	0.6389	
	2.28	97.45	0	0.25			10.11	89.73	0		0.14
	0	6.89	0	93.10			0	11.43	0		88.56
	0	0	0	100.00			0	0	0		100.00
40	100.00	0	0	0	0.5774	100.00	0	0	0	0.4491	
	77.81	0	0	22.18			83.13	0	0		16.86
	0	0	0	100.00			0.06	0	0		99.93
	0	0	0	100.00			0	0	0		100.00
45	100.00	0	0	0	0.5772	100.00	0	0	0	0.4490	
	79.52	0	0	20.47			84.87	0	0		15.12
	0	0	0	100.00			0.07	0	0		99.92
	0	0	0	100.00			0	0	0		100.00
50	100.00	0	0	0	0.5770	100.00	0	0	0	0.4489	
	80.75	0	0	19.24			86.05	0	0		13.94
	0.01	0	0	99.98			0.17	0	0		99.82
	0	0	0	100.00			0	0	0		100.00

Tabla 6.8. Matrices de confusión y sus valores de Kappa correspondientes para distintos radios del Kernel en el algoritmo de Corrimiento de Media (continuación).

En la figura 6.14 se muestra una gráfica del valor de Kappa contra el tamaño del radio del Kernel, donde se observa la sensibilidad a este último parámetro en un rango de variación grande. La figura 6.15 muestra a detalle el intervalo de valores para ajustar el radio donde se consiguen los valores de Kappa más grandes.

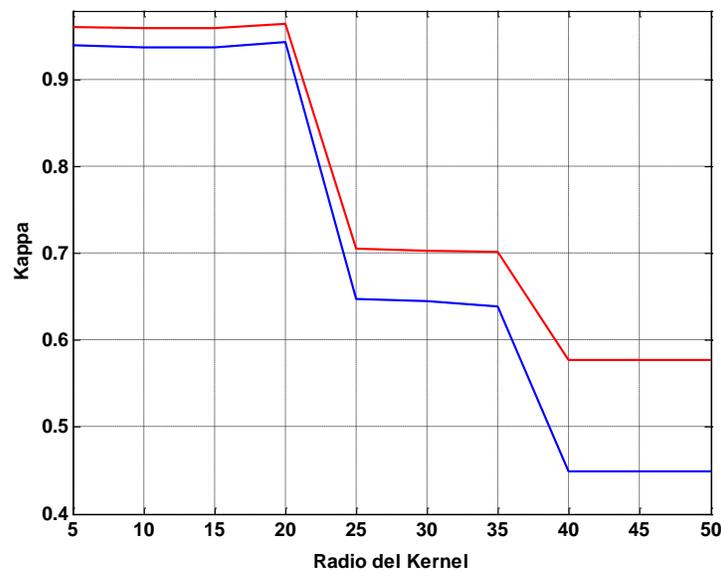


Figura 6.14 Sensibilidad al tamaño del radio del Kernel. ROI en color rojo, TI en color azul.

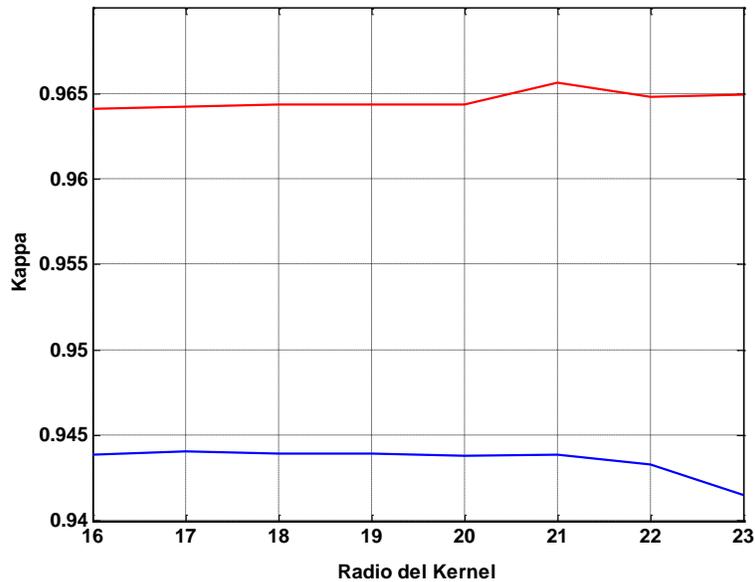


Figura 6.15 Ajuste del radio del Kernel, el mayor valor de Kappa ocurre para radio = 21. ROI en color rojo, TI en color azul.

6.5.4. Variaciones del Parámetro de Suavizamiento σ^2 en la Red Neuronal Probabilística.

Una vez generado el espacio de características y ya conocidos los valores de clases más probables de la imagen, ahora la tarea de clasificación descansa en la red neuronal probabilística. Dado que la activación de los nodos P_N en la capa de patrones depende de la función Kernel exponencial contenida y, ésta a su vez es función del parámetro de suavizamiento σ^2 , entonces el valor de σ^2 debe ser ajustado a fin de lograr el mejor desempeño en la clasificación. Para diferentes valores de σ^2 , en la figura 6.16, se presentan de izquierda a derecha las imágenes de las probabilidades a posteriori para las cuatro clases principales con su respectiva imagen de factores de confianza. En la figura 6.17 se muestran las segmentaciones obtenidas variando σ^2 . Las tablas 6.9 y 6.10 contienen los resultados cuantitativos para el análisis de sensibilidad de σ^2 .

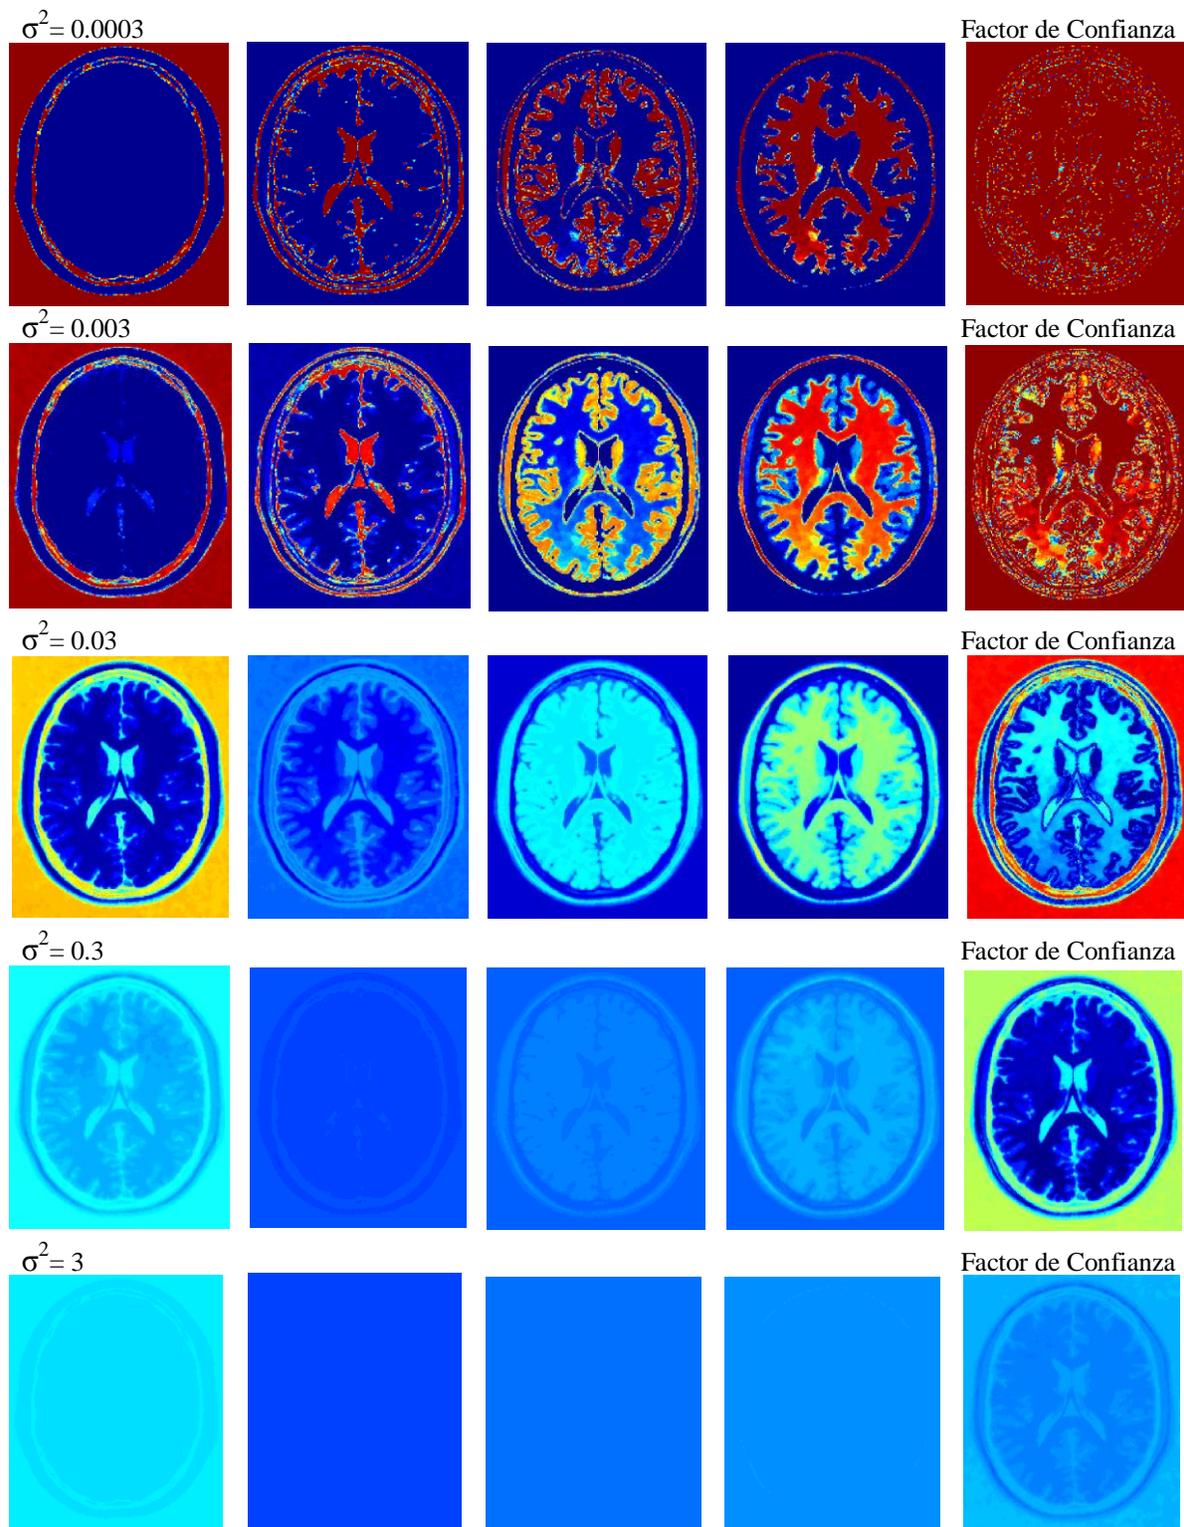


Figura 6.16 De izquierda a derecha, imágenes de las probabilidades a posteriori para las cuatro clases principales y su imagen de factores de confianza, para diferentes valores de σ^2 .

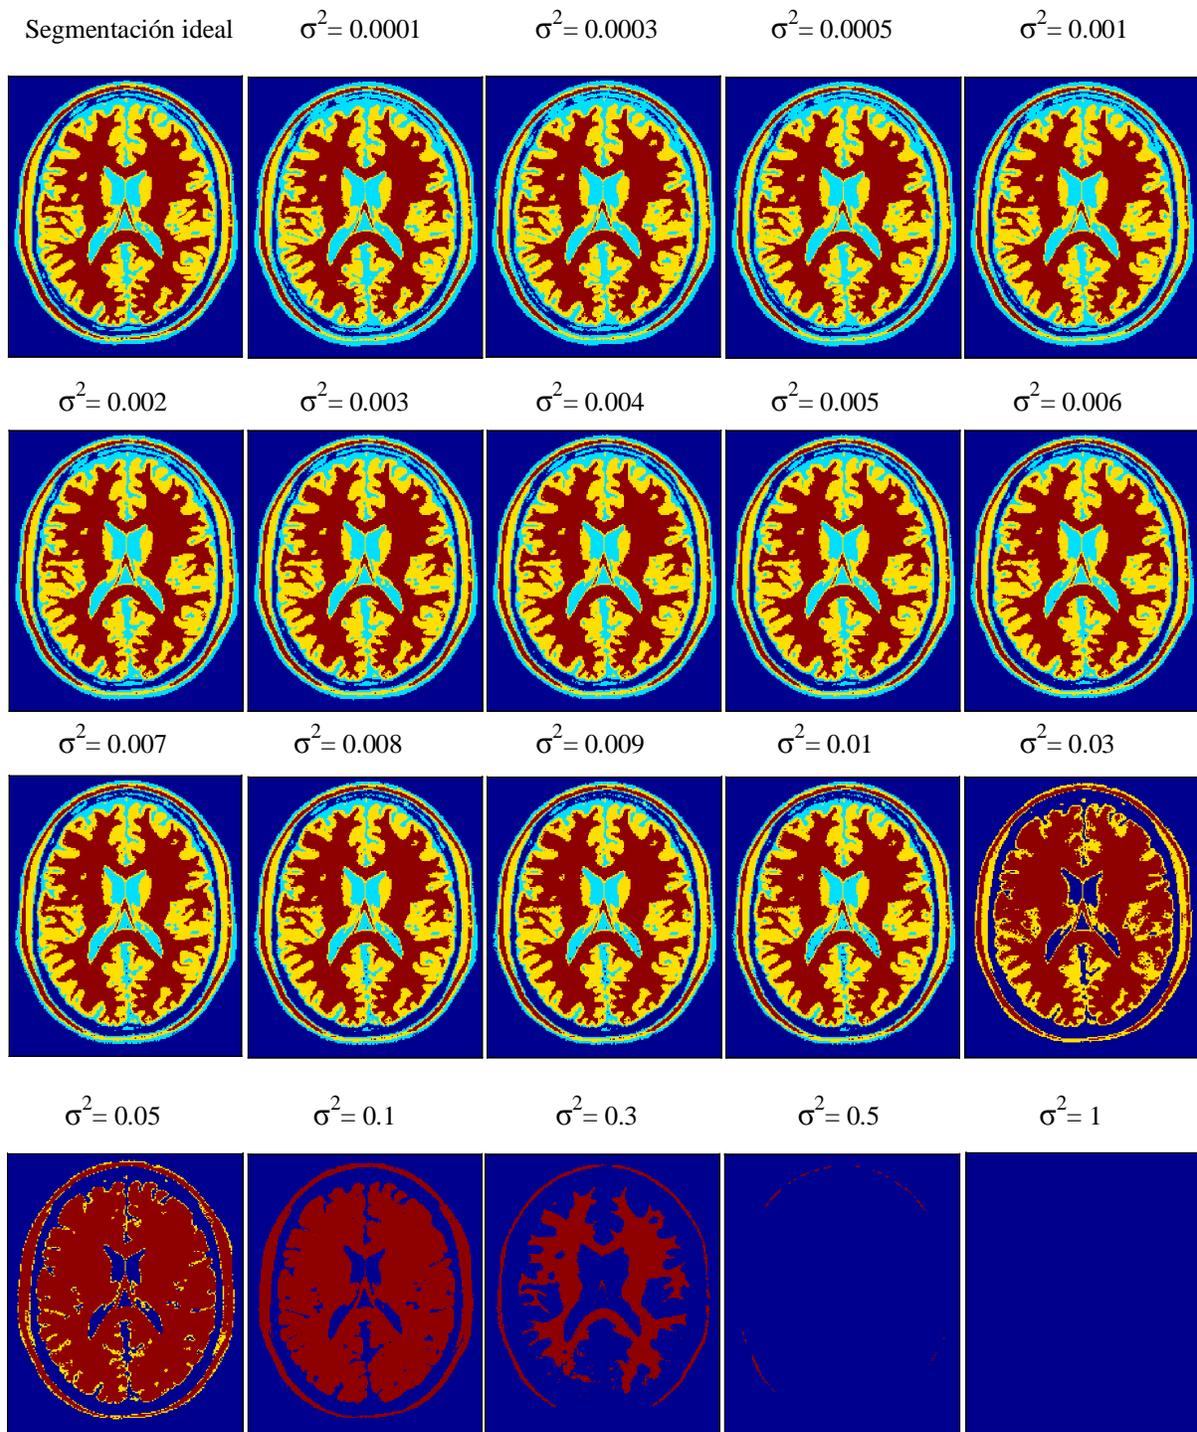


Figura 6.17 Segmentaciones obtenidas para diferentes valores de σ^2 .

σ^2	Matriz de confusión en la región de interés (ROI)				Kappa (ROI)	Matriz de confusión en toda la imagen (TI)				Kappa (TI)
0.0001	99.96	0.03	0	0	0.951166	95.48	4.51	0	0	0.908113
	0	99.78	0.21	0		0.29	99.56	0.13	0	
	0	7.58	89.59	2.81		0	12.13	85.66	2.20	
	0	0	4.95	95.04		0	0	5.86	94.13	
0.0003	99.96	0.03	0	0	0.955898	95.81	4.18	0	0	0.915691
	0	99.74	0.25	0		0.33	99.51	0.14	0	
	0	6.30	90.52	3.17		0	10.63	86.88	2.47	
	0	0	4.37	95.62		0	0	5.29	94.70	
0.0005	99.97	0.02	0	0	0.959234	96.21	3.78	0	0	0.921896
	0.03	99.56	0.39	0		0.41	99.34	0.24	0	
	0	5.20	91.40	3.39		0	9.33	88.01	2.65	
	0	0	4.12	95.88		0	0	5.03	94.96	
0.001	99.98	0.01	0	0	0.964473	97.32	2.67	0	0	0.934810
	0.07	98.83	1.08	0		0.63	98.74	0.61	0	
	0	3.36	92.89	3.74		0	6.95	90.10	2.94	
	0	0	3.67	96.32		0	0	4.51	95.48	
0.002	99.98	0.01	0	0	0.967689	98.57	1.42	0	0	0.945384
	0.07	97.63	2.28	0		1.59	97.00	1.40	0	
	0	1.85	93.88	4.26		0	4.66	91.97	3.36	
	0	0	3.23	96.76		0	0	4.02	95.97	
0.0025	100.00	0	0	0	0.967796	98.96	1.03	0	0	0.946834
	0.10	96.80	3.08	0		2.26	95.88	1.85	0	
	0	1.44	94.07	4.47		0	4.13	92.33	3.53	
	0	0	3.12	96.87		0	0	3.89	96.10	
0.003	100.00	0	0	0	0.967788	99.18	0.81	0	0	0.947144
	0.18	96.29	3.52	0		3.01	94.83	2.15	0	
	0	1.22	94.06	4.71		0	3.76	92.51	3.71	
	0	0	2.96	97.03		0	0	3.72	96.27	
0.0035	100.00	0	0	0	0.967468	99.41	0.58	0	0	0.947245
	0.32	95.89	3.77	0		3.85	93.84	2.30	0	
	0	1.04	93.99	4.96		0	3.42	92.65	3.92	
	0	0	2.88	97.11		0	0	3.60	96.39	
0.004	100.00	0	0	0	0.966831	99.60	0.39	0	0	0.946290
	0.61	95.09	4.28	0		4.94	92.39	2.65	0	
	0	0.84	93.89	5.25		0	3.07	92.73	4.18	
	0	0	2.74	97.25		0	0	3.43	96.56	
0.005	100.00	0	0	0	0.965596	99.79	0.20	0	0	0.943836
	1.30	93.60	5.08	0		7.03	89.83	3.12	0	
	0	0.67	93.63	5.69		0	2.67	92.79	4.52	
	0	0	2.42	97.57		0	0	3.08	96.91	
0.006	100.00	0	0	0	0.964008	99.90	0.09	0	0	0.939971
	1.85	92.22	5.91	0		9.26	87.04	3.68	0	
	0	0.50	93.16	6.32		0	2.31	92.66	5.02	
	0	0	2.07	97.92		0	0	2.72	97.27	
0.007	100.00	0	0	0	0.961544	99.94	0.05	0	0	0.935006
	3.23	90.41	6.35	0		11.92	84.06	4.00	0	
	0	0.41	92.69	6.89		0	2.05	92.47	5.46	
	0	0	1.82	98.17		0	0	2.42	97.57	
0.008	100.00	0	0	0	0.957740	99.96	0.03	0	0	0.927269
	4.50	88.30	7.18	0		15.10	80.37	4.51	0	
	0	0.36	91.92	7.70		0	1.91	91.97	6.11	
	0	0	1.62	98.37		0	0	2.18	97.81	
0.009	100.00	0	0	0	0.953764	99.97	0.02	0	0	0.919397
	6.17	86.02	7.80	0		18.44	76.57	4.98	0	
	0	0.25	91.19	8.55		0	1.67	91.52	6.79	
	0	0	1.43	98.56		0	0	1.95	98.04	

Tabla 6.9. Matrices de confusión y sus valores de Kappa correspondientes para distintos valores de σ^2 .

σ^2	Matriz de confusión en la región de interés (ROI)	Kappa (ROI)	Matriz de confusión en toda la imagen (TI)	Kappa (TI)
0.01	100.00 0 0 0 8.89 82.60 8.49 0 0 0.24 90.48 9.27 0 0 1.22 98.77	0.948654	99.98 0.01 0 0 22.01 72.55 5.42 0 0 1.51 91.09 7.38 0 0 1.76 98.23	0.910966
0.03	100.00 0 0 0 80.97 0 19.02 0 0.01 0 52.22 47.76 0 0 0.07 99.92	0.740374	100.00 0 0 0 86.20 0 13.79 0 0.19 0 60.53 39.26 0 0 0.25 99.74	0.665234
0.05	100.00 0 0 0 92.22 0 7.7705 0 0.26 0 15.8756 83.85 0 0 0 100.00	0.625772	100.00 0 0 0 95.03 0 4.96 0 1.72 0 20.56 77.71 0 0 0 100.00	0.522354
0.1	100.00 0 0 0 99.81 0 0 0.18 7.96 0 0 92.03 0 0 0 100.00	0.571831	100.00 0 0 0 99.88 0 0 0.11 12.53 0 0 87.46 0 0 0 100.00	0.446304
0.3	100.00 0 0 0 100.00 0 0 0 99.59 0 0 0.40 18.36 0 0 81.63	0.447540	100.00 0 0 0 100.00 0 0 0 99.69 0 0 0.31 19.12 0 0 80.87	0.353313
0.5	100 0 0 0 100 0 0 0 100 0 0 0 100 0 0 0	0.000000	100.00 0 0 0 100.00 0 0 0 100.00 0 0 0 98.71 0 0 1.28	0.005735
1	100 0 0 0 100 0 0 0 100 0 0 0 100 0 0 0	0.000000	100 0 0 0 100 0 0 0 100 0 0 0 100 0 0 0	0.000000

Tabla 6.10. Matrices de confusión y sus valores de Kappa correspondientes para distintos valores de σ^2 (continuación).

En las figuras 6.18 y 6.19 se muestran gráficamente las variaciones de Kappa contra σ^2 , donde se aprecia que el valor de σ^2 puede elegirse fácilmente en el intervalo comprendido entre 0.0001 y 0.01, el cual es un intervalo prácticamente lineal para ROI. En el análisis cuantitativo mostrado en las tablas anteriores se observa que el mejor valor de Kappa corresponde a $\sigma^2=0.0025$.

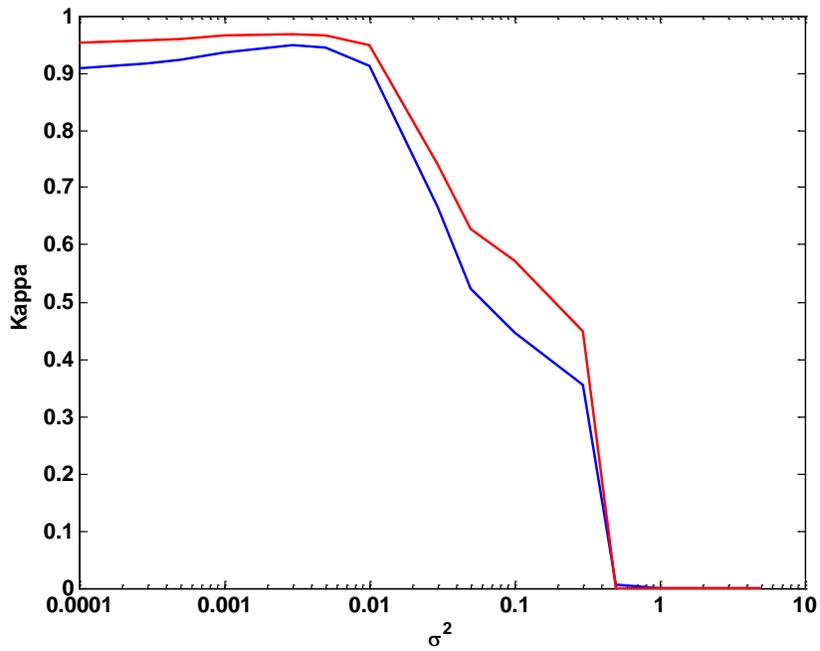


Figura 6.18 Sensibilidad al parámetro de suavizamiento σ^2 . Se observa que para valores de σ^2 menores a 0.01 se tiene una región de operación casi invariante. ROI en color rojo, TI en color azul.

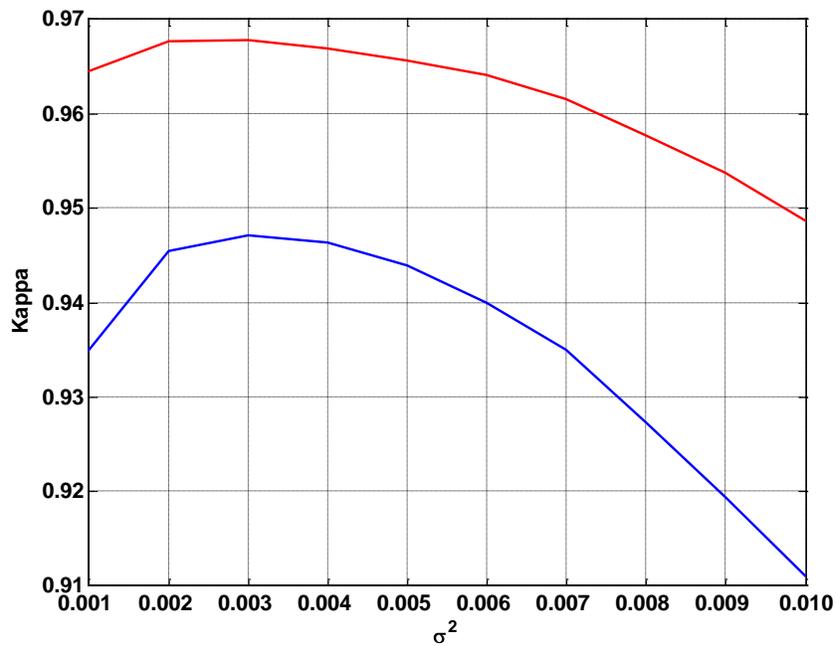


Figura 6.19 Ajuste del parámetro de suavizamiento σ^2 , el mejor valor de Kappa corresponde a $\sigma^2 = 0.0025$. ROI en color rojo, TI en color azul.

6.6. RESULTADOS CON IMÁGENES SINTÉTICAS DE IRM.

En esta sección se mostrarán los resultados obtenidos para una imagen sintética de RMN generada por el simulador descrito en [45, 46, 47, 48, 49]. La imagen tiene un nivel de campo de ganancia de 20% y un nivel de ruido de 3%. En la figura 6.20, se muestran los resultados del uso de los estimadores de localización y dispersión.

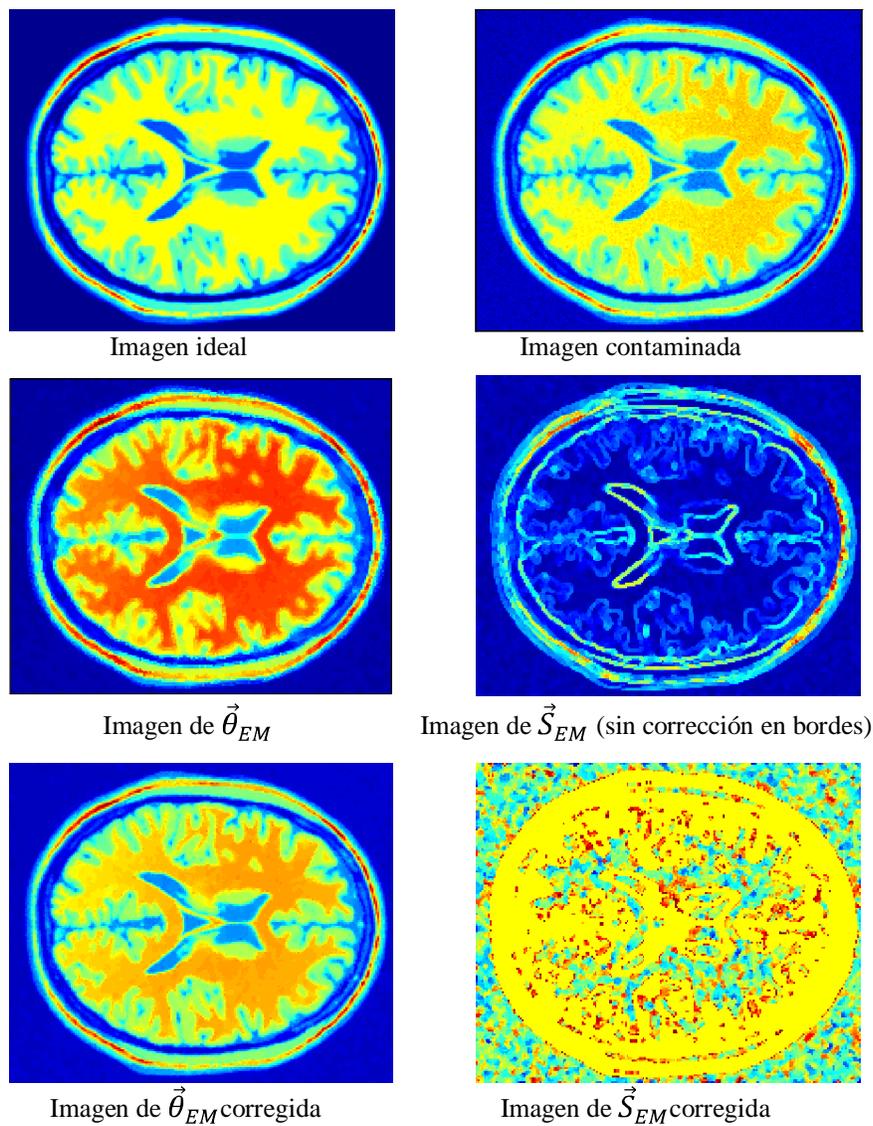


Figura 6.20. Aspecto de los estimadores robustos de localización y dispersión, con una imagen sintética con 3% de ruido aditivo y 20% de campo de ganancia (valores típicos).

En la figura 6.21 se muestran los resultados obtenidos por el algoritmo de Corrimiento de Media después de 20 iteraciones.

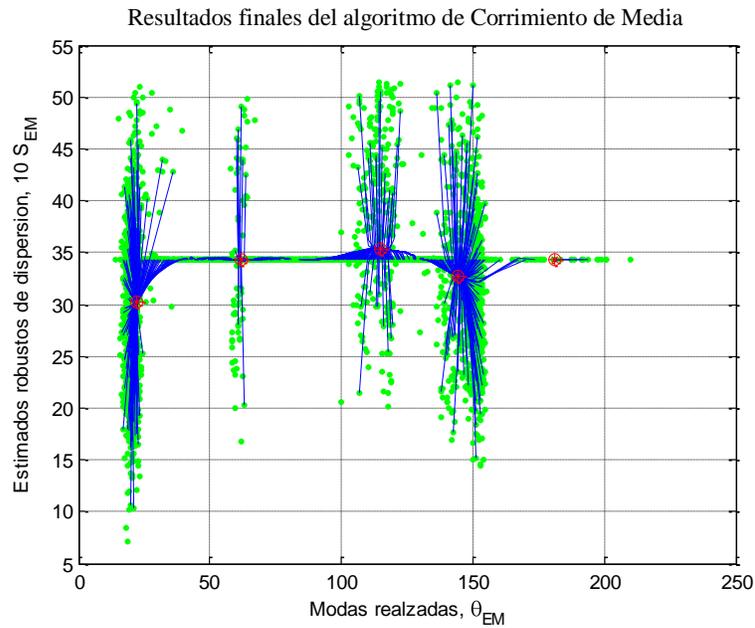


Figura 6.21. Clases encontradas por el algoritmo de Corrimiento de Media.

La figura 6.22 muestra las imágenes de las probabilidades a posteriori para cada clase y la imagen del factor de confianza.

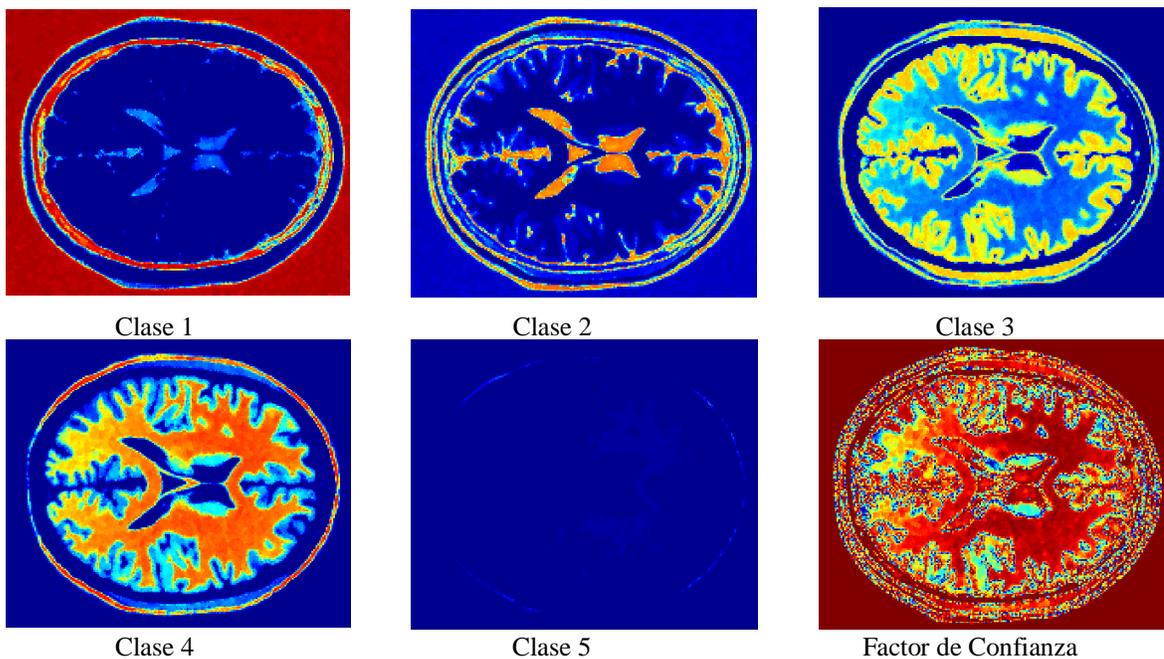
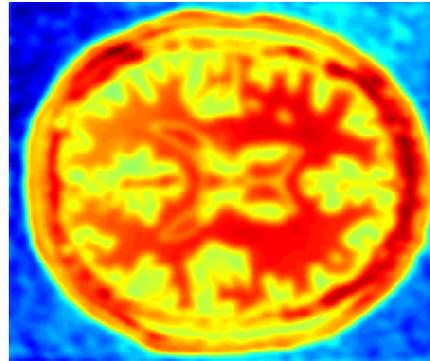
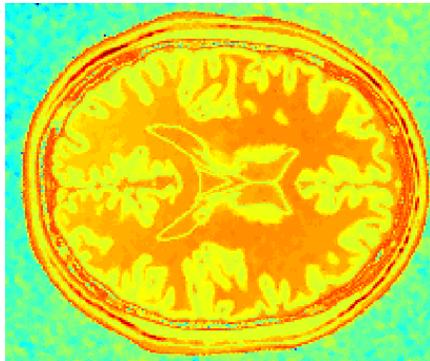
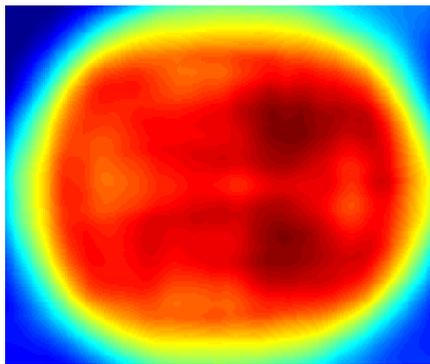


Figura 6.22. Aspecto de las probabilidades posteriores para cada clase y del factor de confianza.

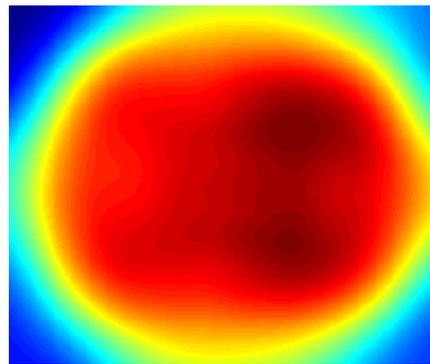
La siguiente figura, 6.23, muestra las estimaciones del campo de ganancia alcanzando el criterio de paro en cuatro iteraciones.



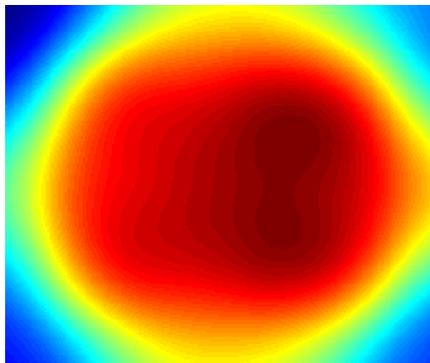
Estimado inicial del campo de ganancia Campo de ganancia después del filtro pasa-bajas



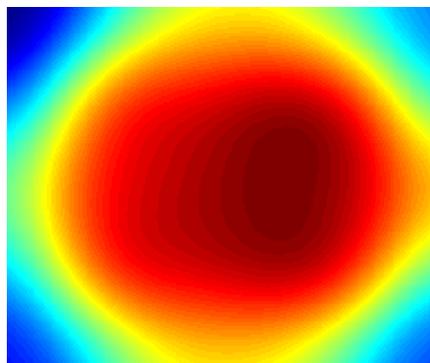
Iteración de suavizado 1



Iteración de suavizado 2



Iteración de suavizado 3



Iteración de suavizado 4

Figura 6.23. Estimación del campo de ganancia.

En la figura 6.24 se muestran los resultados principales al término del procedimiento de restauración-segmentación.

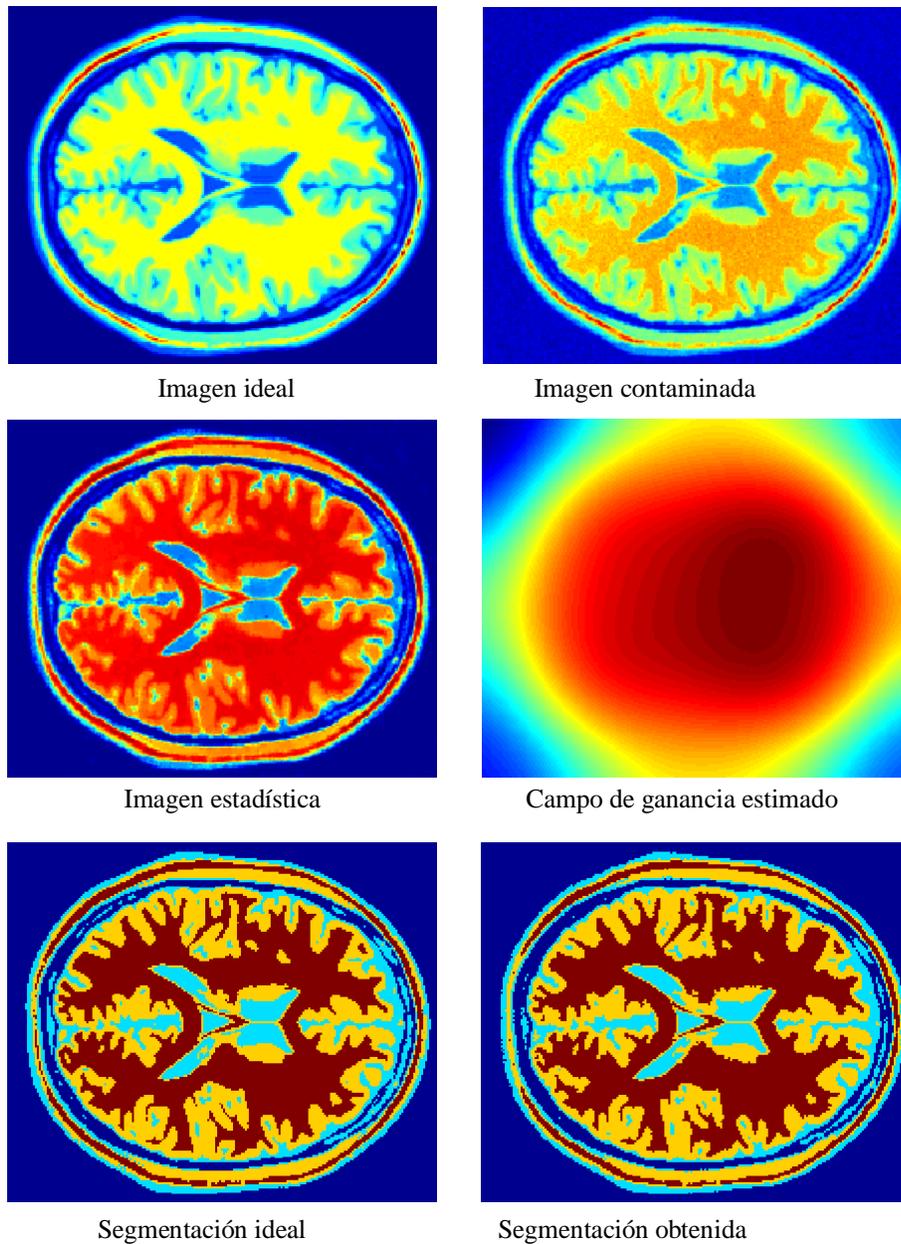


Figura 6.24. Principales resultados del procedimiento realizado a la imagen.

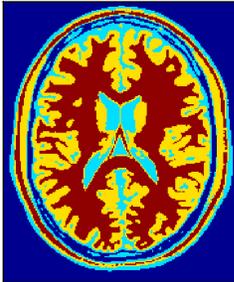
A continuación en la tabla 6.11, se muestran las matrices de confusión y los valores de Kappa tanto para la región de interés como para toda la imagen.

Matriz de confusión en la región de interés (ROI)				Kappa (ROI)	Matriz de confusión en toda la imagen (TI)				Kappa (TI)
100.00	0	0	0	0.9657	99.84	0.16	0	0	0.9406
1.34	93.12	5.54	0		8.24	88.49	3.28	0	
0	0.61	93.12	6.27		0	2.80	92.32	4.88	
0	0	1.83	98.17		0	0	2.89	97.11	

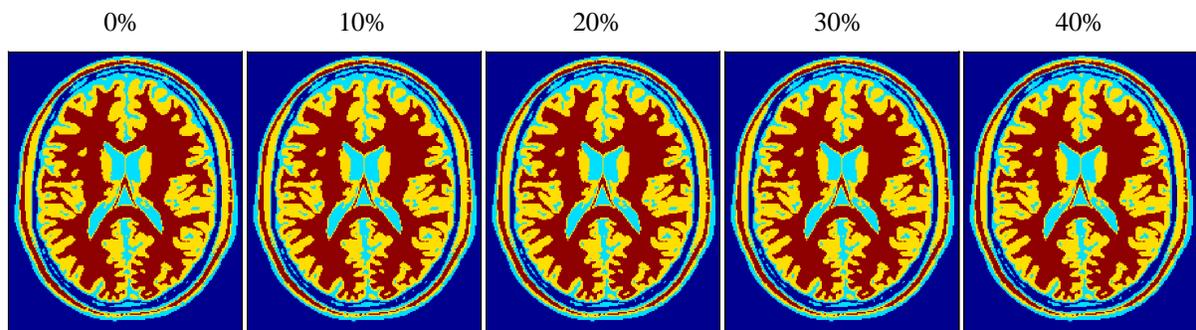
Tabla 6.11. Resultados de la imagen analizada.

En la figura 6.25, se muestran las segmentaciones obtenidas variando el nivel de ruido aditivo y del campo de ganancia presentes en la imagen analizada.

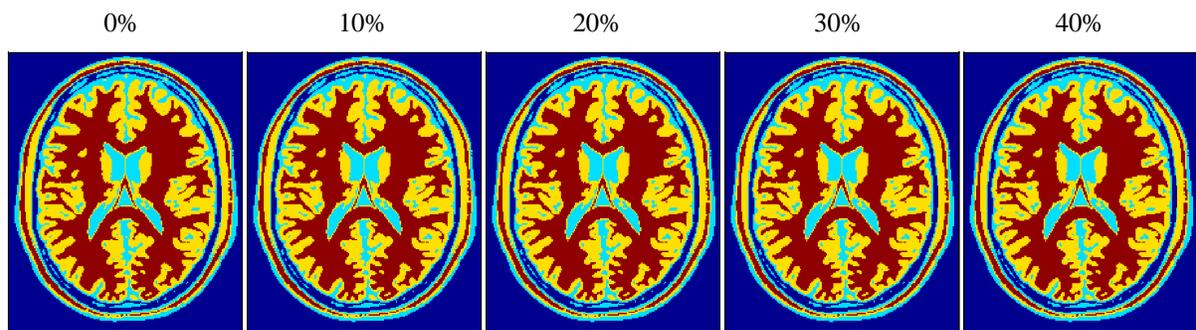
Segmentación ideal



Ruido = 1% y nivel del campo de ganancia en:



Ruido = 3% y nivel del campo de ganancia en:



Ruido = 5% y nivel del campo de ganancia en:

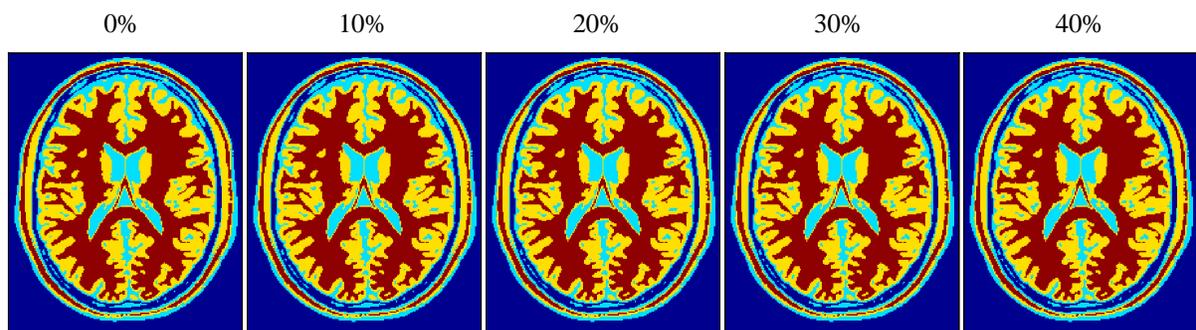


Figura 6.25. Resultados para diferentes niveles de intensidad del campo de ganancia y de ruido aditivo.

También se analizaron tres imágenes con ruido aditivo de 3% y dos morfologías diferentes del campo de ganancia (denominados campo “A” y campo “B”) que también son proporcionados por el simulador de la Universidad de McGill [45, 46]. Se hicieron variaciones en los niveles de intensidad del campo de ganancia, los resultados se muestran en la tabla 6.12.

Campo de ganancia A												
Imagen	Campo de ganancia de 10%				Campo de ganancia de 20%				Campo de ganancia de 30%			
Imagen 1	Kappa (ROI) = 0.9701				Kappa (ROI) = 0.9657				Kappa (ROI) = 0.9585			
	Matriz de confusión (ROI)				Matriz de confusión (ROI)				Matriz de confusión (ROI)			
	100.00	0	0	0	100.00	0	0	0	100.00	0	0	0
	1.27	92.97	5.76	0	1.34	93.12	5.54	0	1.92	93.19	4.89	0
	0	0.36	93.42	6.22	0	0.61	93.12	6.27	0	1.22	93.00	5.78
0	0	0.82	99.18	0	0	1.83	98.17	0	0	3.73	96.27	
Kappa (TI) = 0.9498				Kappa (TI) = 0.9406				Kappa (TI) = 0.9280				
Matriz de confusión (TI)				Matriz de confusión (TI)				Matriz de confusión (TI)				
99.88	0.12	0	0	99.84	0.16	0	0	99.84	0.16	0	0	
7.62	88.93	3.45	0	8.24	88.49	3.27	0	8.86	88.35	2.79	0	
0	1.89	93.24	4.87	0	2.80	92.32	4.88	0	4.25	91.25	4.50	
0	0	1.58	98.42	0	0	2.89	97.11	0	0	5.19	94.81	
Imagen 2	Kappa (ROI) = 0.9625				Kappa (ROI) = 0.9510				Kappa (ROI) = 0.9376			
	Matriz de confusión (ROI)				Matriz de confusión (ROI)				Matriz de confusión (ROI)			
	100.00	0	0	0	100.00	0	0	0	100.00	0	0	0
	1.05	91.94	7.01	0	0.89	86.39	12.72	0	1.12	87.50	11.38	0
	0	0.52	98.52	0.96	0	0.15	96.27	3.58	0	0.36	95.79	3.85
0	0	7.68	92.32	0	0	6.41	93.59	0	0	10.87	89.13	
Kappa (TI) = 0.9417				Kappa (TI) = 0.9322				Kappa (TI) = 0.9129				
Matriz de confusión (TI)				Matriz de confusión (TI)				Matriz de confusión (TI)				
99.42	0.58	0	0	99.35	0.65	0	0	99.29	0.71	0	0	
4.27	91.43	4.30	0	3.77	88.48	7.75	0	5.13	87.94	6.93	0	
0	1.74	97.48	0.78	0	1.06	96.05	2.89	0	1.71	95.19	3.10	
0	0	8.85	91.15	0	0	7.93	92.07	0	0	12.51	87.49	
Imagen 3	Kappa (ROI) = 0.9618				Kappa (ROI) = 0.9542				Kappa (ROI) = 0.9372			
	Matriz de confusión (ROI)				Matriz de confusión (ROI)				Matriz de confusión (ROI)			
	100.00	0	0	0	100.00	0	0	0	100.00	0	0	0
	0.92	89.49	9.59	0	0.85	93.49	5.66	0	0.88	89.76	9.36	0
	0	0.32	97.78	1.90	0	0.76	96.27	2.97	0	0.60	95.12	4.28
0	0	5.88	94.12	0	0	8.05	91.95	0	0	10.81	89.19	
Kappa (TI) = 0.9407				Kappa (TI) = 0.9268				Kappa (TI) = 0.9068				
Matriz de confusión (TI)				Matriz de confusión (TI)				Matriz de confusión (TI)				
99.45	0.55	0	0	99.54	0.46	0	0	99.25	0.75	0	0	
4.16	89.75	6.09	0	4.44	92.17	3.39	0	4.77	89.51	5.72	0	
0	1.63	96.86	1.51	0	3.22	94.43	2.35	0	2.74	93.89	3.37	
0	0	6.96	93.04	0	0	9.66	90.34	0	0	12.95	87.05	

Tabla 6.12. Resultados en tres imágenes para el campo de ganancia “A”.

A continuación se muestran las matrices de confusión y los valores de Kappa obtenidos con la morfología del campo de ganancia “B” con las mismas tres imágenes, ver tabla 6.13.

Campo de ganancia B													
Imagen	Campo de Ganancia de 10%				Campo de Ganancia de 20%				Campo de Ganancia de 30%				
Imagen 1 Radio=15	Kappa (ROI) = 0.9609				Kappa (ROI) = 0.9567				Kappa (ROI) = 0.9473				
	Matriz de confusión (ROI)				Matriz de confusión (ROI)				Matriz de confusión (ROI)				
	100.00	0	0	0	100.00	0	0	0	100.00	0	0	0	
	2.10	85.09	12.81	0	0.98	90.51	8.51	0	0.85	92.30	6.85	0	
	0	0.04	98.28	1.68	0	0.38	93.00	6.62	0	1.05	90.32	8.63	
	0	0	5.13	94.87	0	0	2.39	97.61	0	0	2.99	97.01	
	Kappa (TI) = 0.9339				Kappa (TI) = 0.9308				Kappa (TI) = 0.9088				
	Matriz de confusión (TI)				Matriz de confusión (TI)				Matriz de confusión (TI)				
99.92	0.08	0	0	99.69	0.31	0	0	99.63	0.37	0	0		
8.11	84.00	7.89	0	4.60	90.73	4.67	0	5.19	91.24	3.57	0		
0	1.14	97.54	1.32	0	2.75	92.06	5.19	0	4.82	88.41	6.77		
0	0	6.93	93.07	0	0	4.91	95.09	0	0	7.21	92.79		
Imagen 2	Kappa (ROI) = 0.9671				Kappa (ROI) = 0.9563				Kappa (ROI) = 0.9473				
	Matriz de confusión (ROI)				Matriz de confusión (ROI)				Matriz de confusión (ROI)				
	100.00	0	0	0	100.00	0	0	0	100.00	0	0	0	
	1.08	92.64	6.28	0	0.83	86.87	12.30	0	1.02	88.52	10.46	0	
	0	0.56	97.68	1.76	0	0.16	94.86	4.98	0	0.39	91.81	7.80	
	0	0	5.28	94.72	0	0	2.98	97.02	0	0	2.89	97.11	
	Kappa (TI) = 0.9465				Kappa (TI) = 0.9346				Kappa (TI) = 0.9199				
	Matriz de confusión (TI)				Matriz de confusión (TI)				Matriz de confusión (TI)				
99.60	0.40	0	0	99.50	0.50	0	0	99.53	0.47	0	0		
4.05	92.37	3.58	0	4.56	88.41	7.03	0	4.66	89.54	5.80	0		
0	2.04	96.54	1.42	0	1.28	94.71	4.01	0	2.34	91.38	6.28		
0	0	6.95	93.05	0	0	5.54	94.46	0	0	6.61	93.39		
Imagen 3	Kappa (ROI) = 0.9683				Kappa (ROI) = 0.9652				Kappa (ROI) = 0.9612				
	Matriz de confusión (ROI)				Matriz de confusión (ROI)				Matriz de confusión (ROI)				
	100.00	0	0	0	100.00	0	0	0	100.00	0	0	0	
	1.49	91.45	7.06	0	1.74	91.67	6.59	0	1.23	91.41	7.36	0	
	0	0.21	93.15	6.64	0	0.53	92.03	7.44	0	0.64	91.64	7.72	
	0	0	0.65	99.35	0	0	0.67	99.33	0	0	1.36	98.64	
	Kappa (TI) = 0.9478				Kappa (TI) = 0.9383				Kappa (TI) = 0.9264				
	Matriz de confusión (TI)				Matriz de confusión (TI)				Matriz de confusión (TI)				
99.90	0.10	0	0	99.94	0.06	0	0	99.93	0.07	0	0		
7.68	88.22	4.10	0	8.48	87.94	3.58	0	9.32	86.84	3.84	0		
0	1.90	92.96	5.14	0	3.37	90.89	5.74	0	4.13	89.91	5.96		
0	0	1.50	98.50	0	0	2.08	97.92	0	0	3.77	96.23		

Tabla 6.13. Resultados en tres imágenes para el campo de ganancia “B”.

En seguida, se muestran las segmentaciones obtenidas con las tres imágenes variando la intensidad del campo de ganancia “A”, ver figura 6.26.

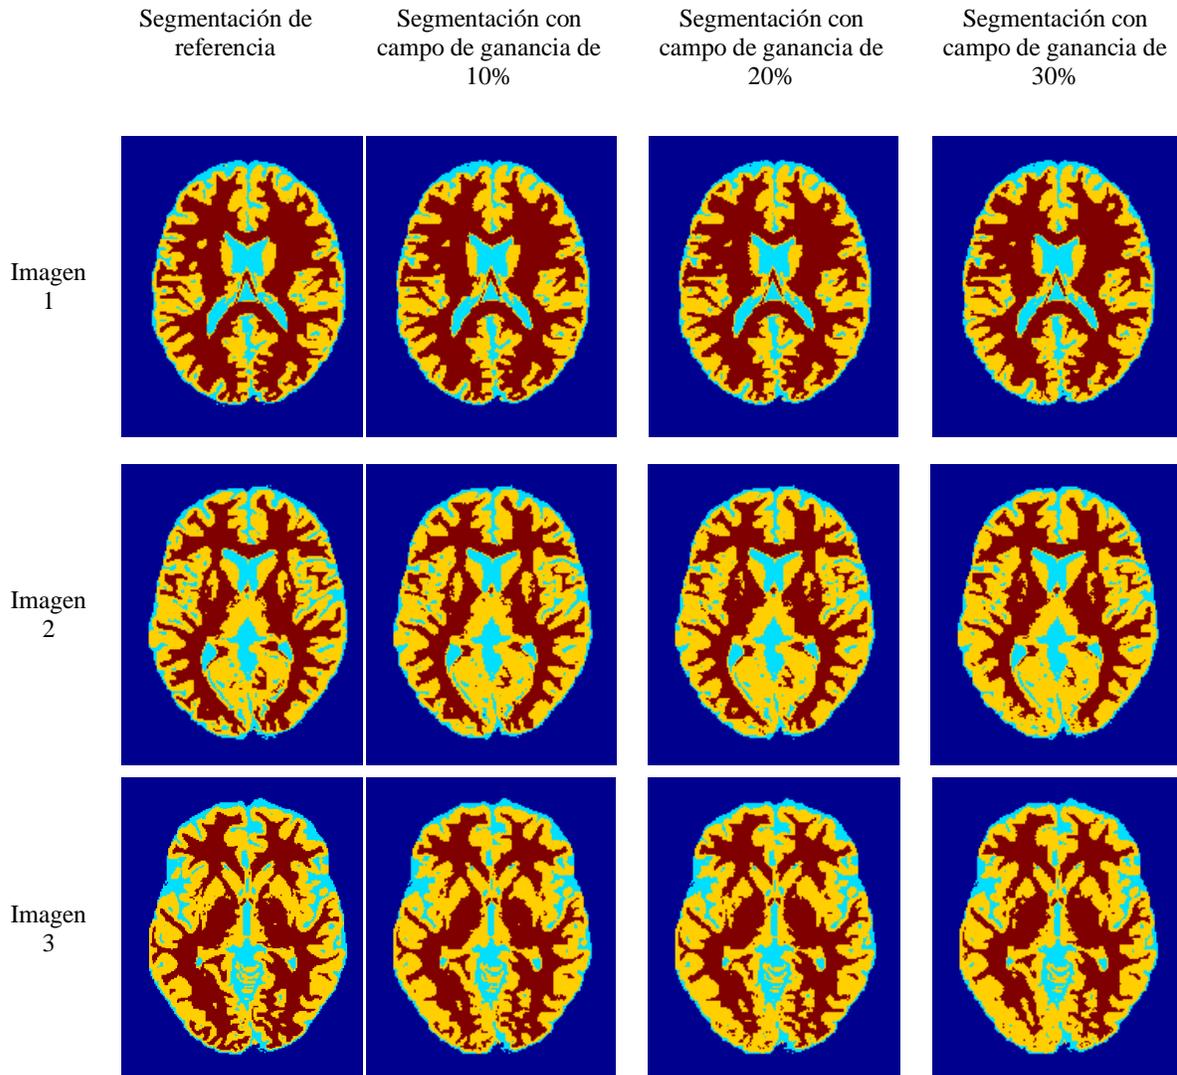


Figura 6.26. Segmentaciones obtenidas para las tres imágenes y con el campo de ganancia “A”.

En la siguiente figura se muestran las segmentaciones obtenidas en las tres imágenes, ahora para el campo de ganancia “B”, variando su intensidad, ver figura 6.27.

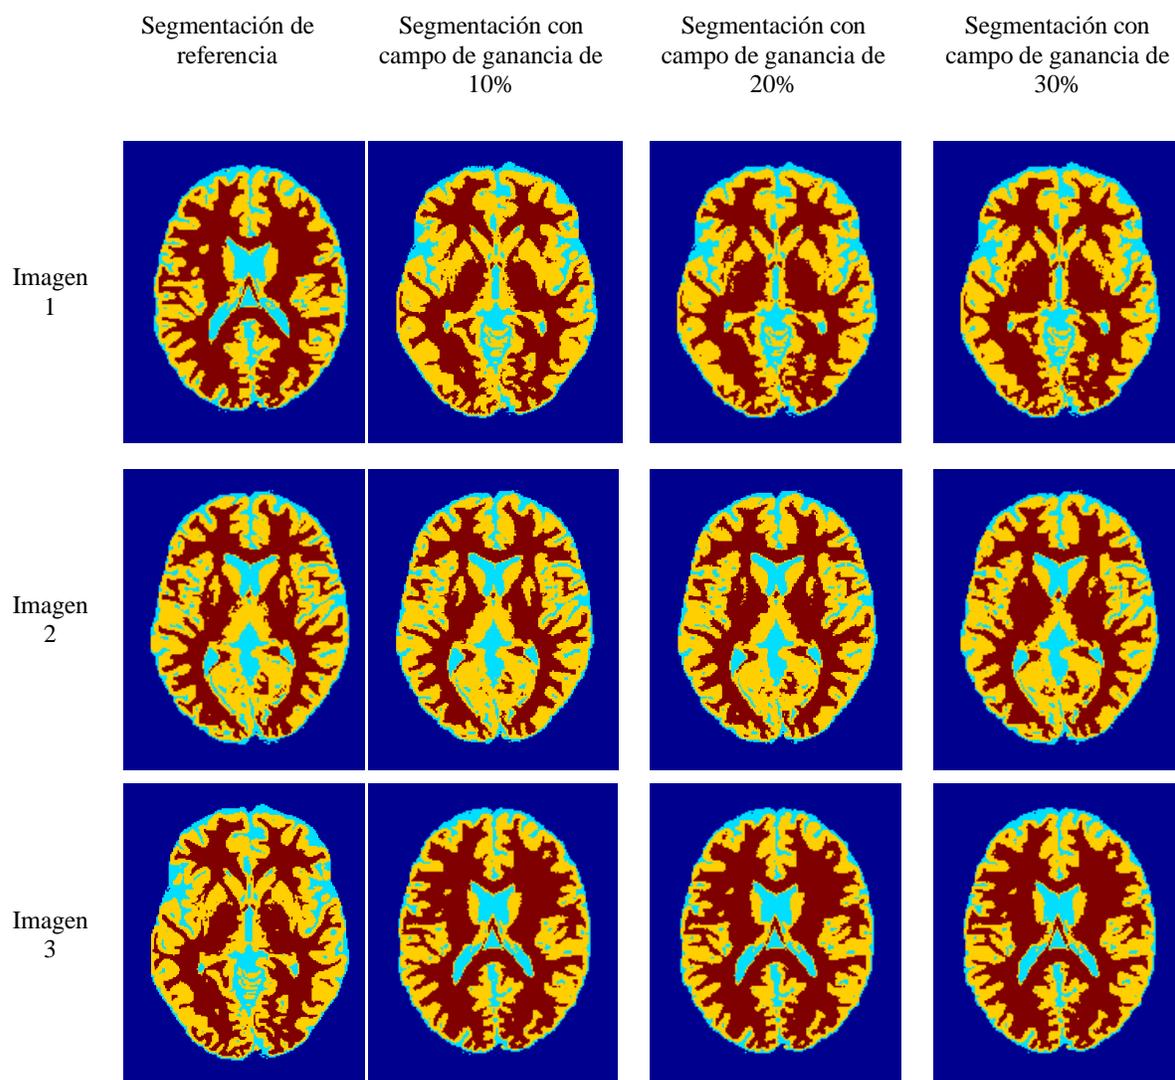


Figura 6.27. Segmentaciones obtenidas para las tres imágenes y con el campo de ganancia “B”.

También se hicieron las estimaciones de los campos de ganancia “A” y “B”, en la figura 6.28 se muestran los resultados obtenidos para las tres imágenes.

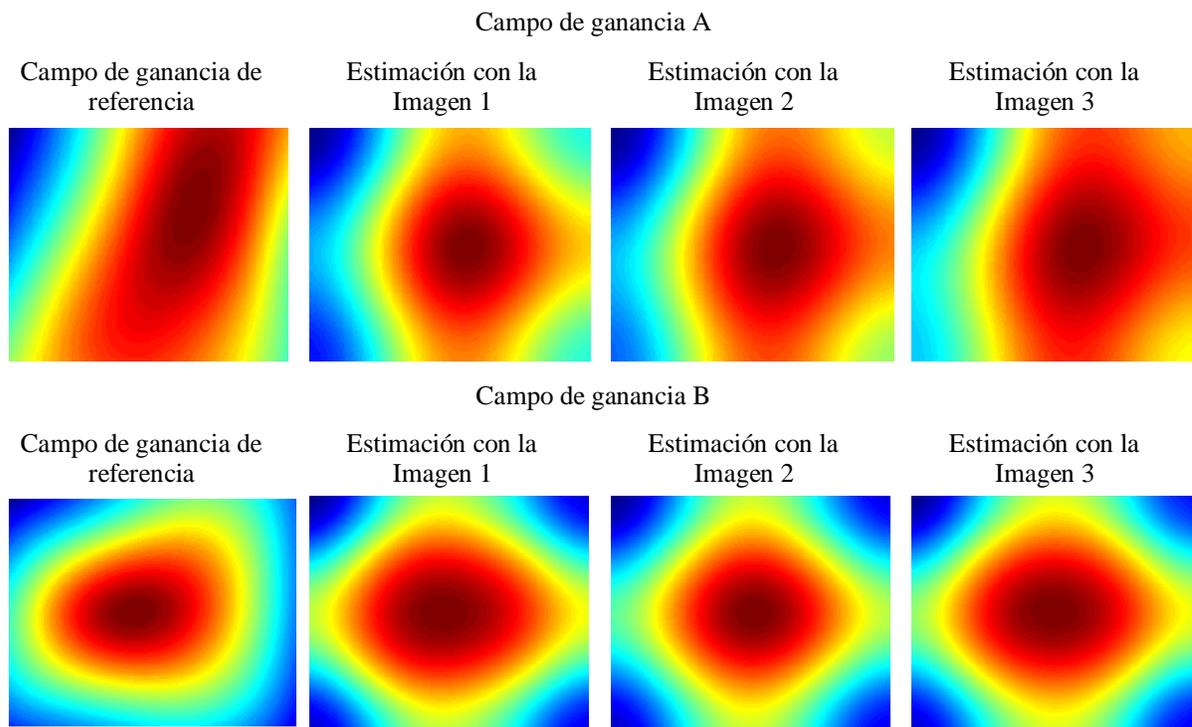


Figura 6.28. Resultados para dos morfologías de campo de ganancia.

6.7. RESULTADOS CON IMÁGENES REALES DE IRM.

En esta sección se mostrarán los resultados obtenidos para imágenes reales de RMN. Las imágenes muestran la vista coronal del cerebro de un sujeto y presentan un nivel de campo de ganancia desconocido. La segmentación de referencia tiene tres o cuatro clases dependiendo de la altura del corte. En la tabla 6.14, se muestran las matrices de confusión y los valores de Kappa obtenidos.

Imágenes Reales									
Imagen 1	Kappa = 0.8223				Imagen 6	Kappa = 0.9001			
	Matriz de confusión					Matriz de confusión			
	98.82	0	1.17	0.01		99.84	0	0.15	0.01
	0	55.93	42.37	1.70		0	95.00	0	5.00
	4.56	0.07	78.90	16.47		11.26	0	81.03	7.71
	1.48	0.03	18.11	80.38		0	1.56	7.61	90.83
Imagen 2	Kappa = 8461				Imagen 7	Kappa = 0.8855			
	Matriz de confusión					Matriz de confusión			
	99.21	0	0.79	0		99.91	0.09	0	
	0	83.49	16.51	0		14.18	73.25	12.57	
	8.00	0.39	87.69	3.92		0.05	3.56	96.39	
	0.06	0.20	28.61	71.13					
Imagen 3	Kappa = 0.8395				Imagen 8	Kappa = 0.9067			
	Matriz de confusión					Matriz de confusión			
	99.37	0.02	0.61	0		99.92	0.08	0	
	6.22	56.46	37.32	0		10.82	83.44	5.74	
	10.69	0.20	81.42	7.69		0	9.47	90.53	
	0	0	21.31	78.69					
Imagen 4	Kappa = 0.8518				Imagen 9	Kappa = 0.8974			
	Matriz de confusión					Matriz de confusión			
	99.57	0.01	0.41	0.01		99.94	0.06	0	
	0	54.68	45.32	0		10.64	84.02	5.34	
	12.91	0.06	77.88	9.15		0	16.96	83.04	
	0	0	10.83	89.17					
Imagen 5	Kappa = 0.8574				Imagen 10	Kappa = 0.8834			
	Matriz de confusión					Matriz de confusión			
	99.76	0.02	0.21	0.01		99.80	0.20	0	
	0	79.41	20.59	0		12.61	78.97	8.42	
	16.88	0.15	78.29	4.68		0	13.77	86.23	
	0	0.32	14.75	84.93					

Tabla 6.14. Resultados en diez imágenes reales de RMN.

Se obtuvieron las segmentaciones de las imágenes mencionadas, en algunos casos, se detectaron un número mayor de clases que las contenidas en la segmentación de referencia, por lo que fue necesario mezclar las clases adicionales con las más parecidas. En las figuras 6.29 y 6.30 se muestran las segmentaciones obtenidas para diez imágenes.

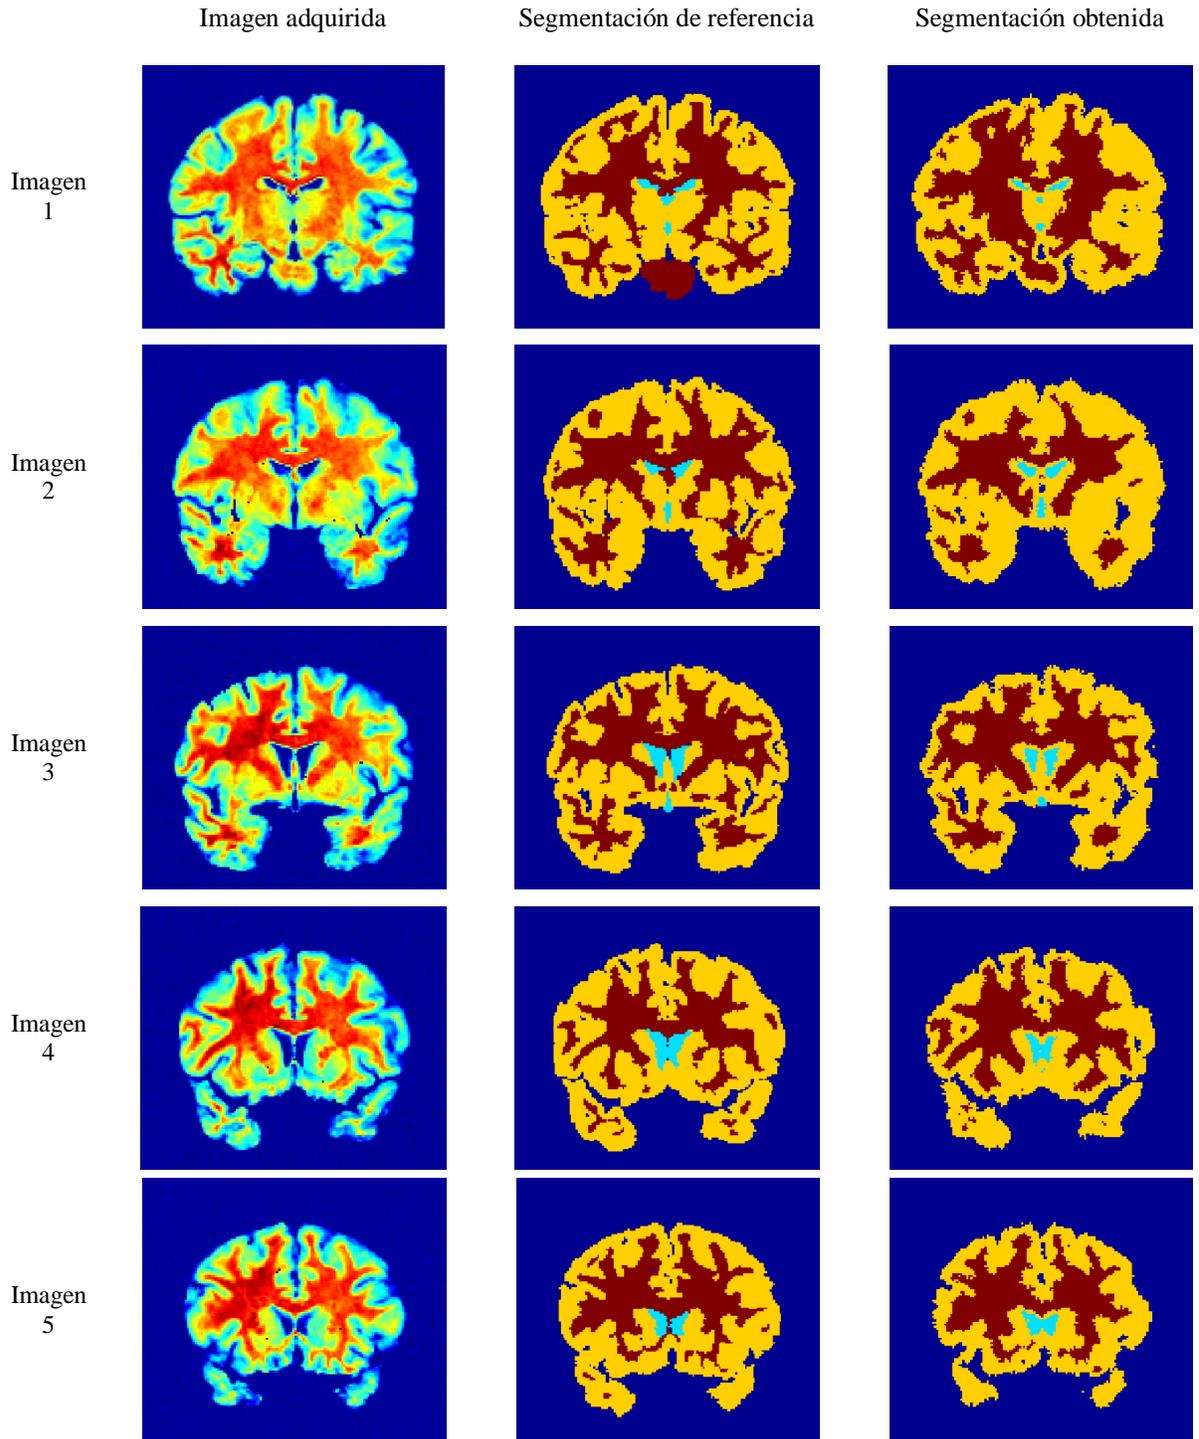


Figura 6.29. Segmentaciones obtenidas en imágenes reales de IRM (primeras cinco imágenes).

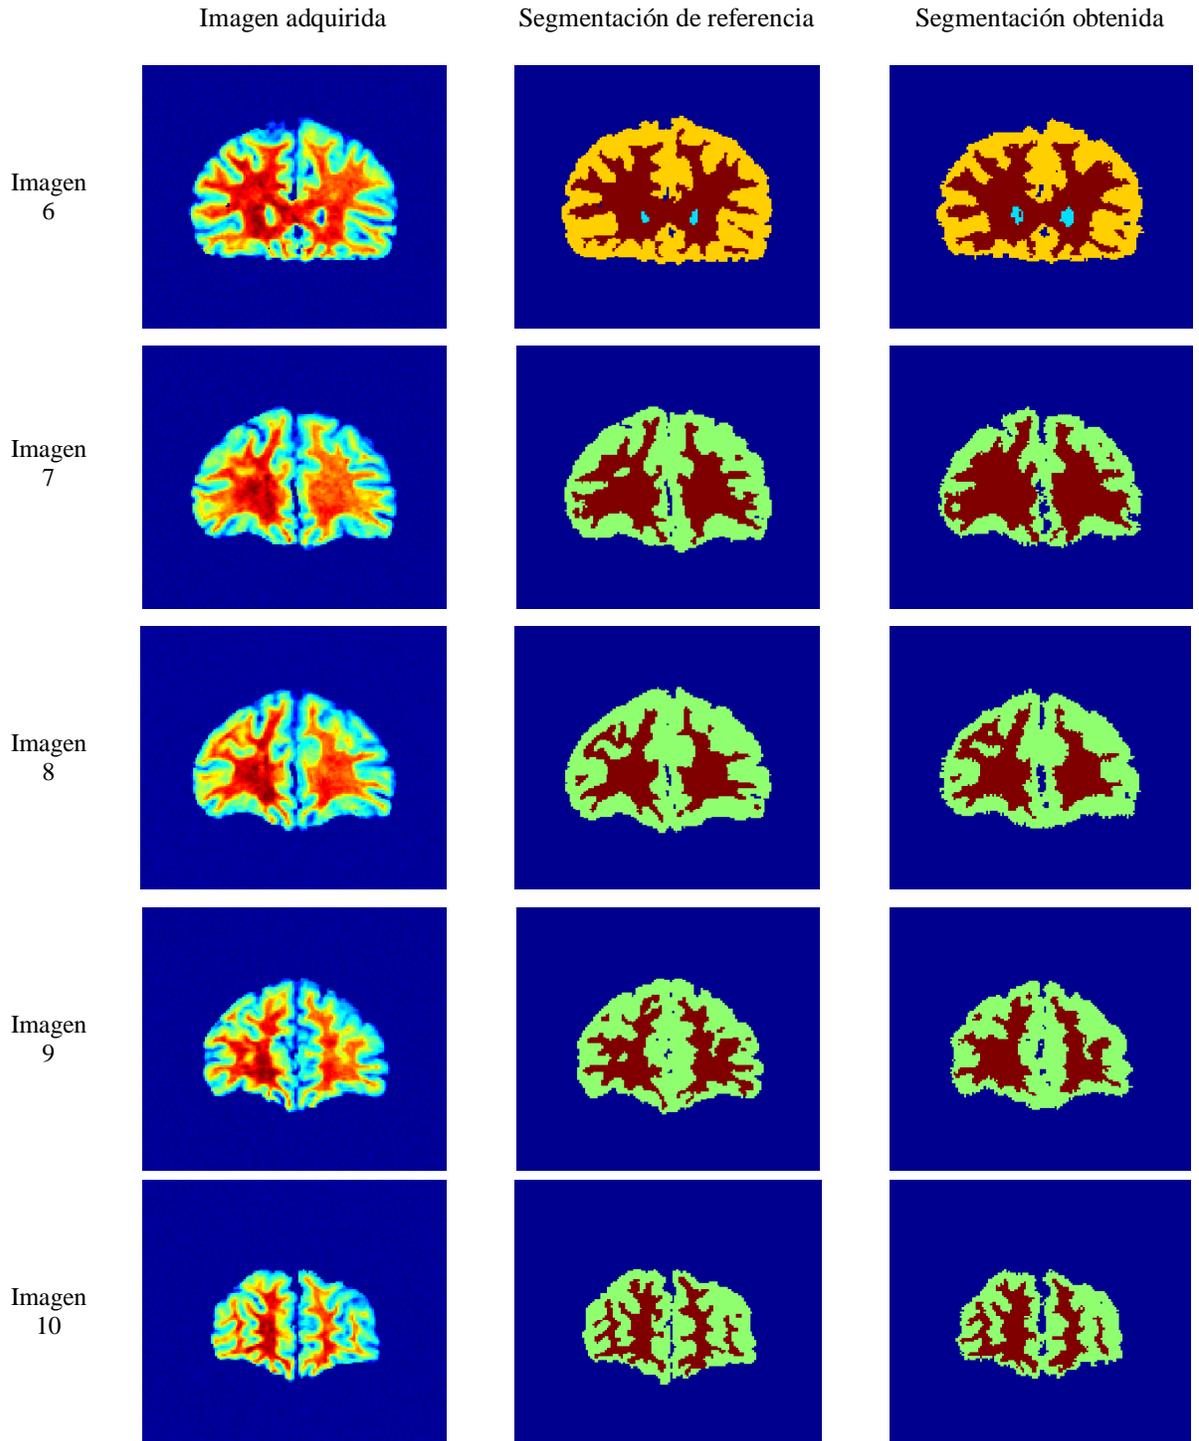


Figura 6.30. Segmentaciones obtenidas en imágenes reales de IRM (continuación).

Como se mencionó, en algunas imágenes se obtuvieron más clases que las indicadas en la segmentación de referencia. En la siguiente figura 6.31, para la imagen cuatro, se observa la imagen adquirida en escala de grises, la misma en falso color, la segmentación de referencia, la segmentación entregada por el algoritmo de restauración-segmentación y la segmentación obtenida al mezclar las clases parecidas, con la finalidad de poder hacer una medición cuantitativa de los resultados. Finalmente en la misma figura se muestra el campo de ganancia estimado, se aprecia en la imagen en falso color que efectivamente dicho campo se encuentra cargado hacia la izquierda.

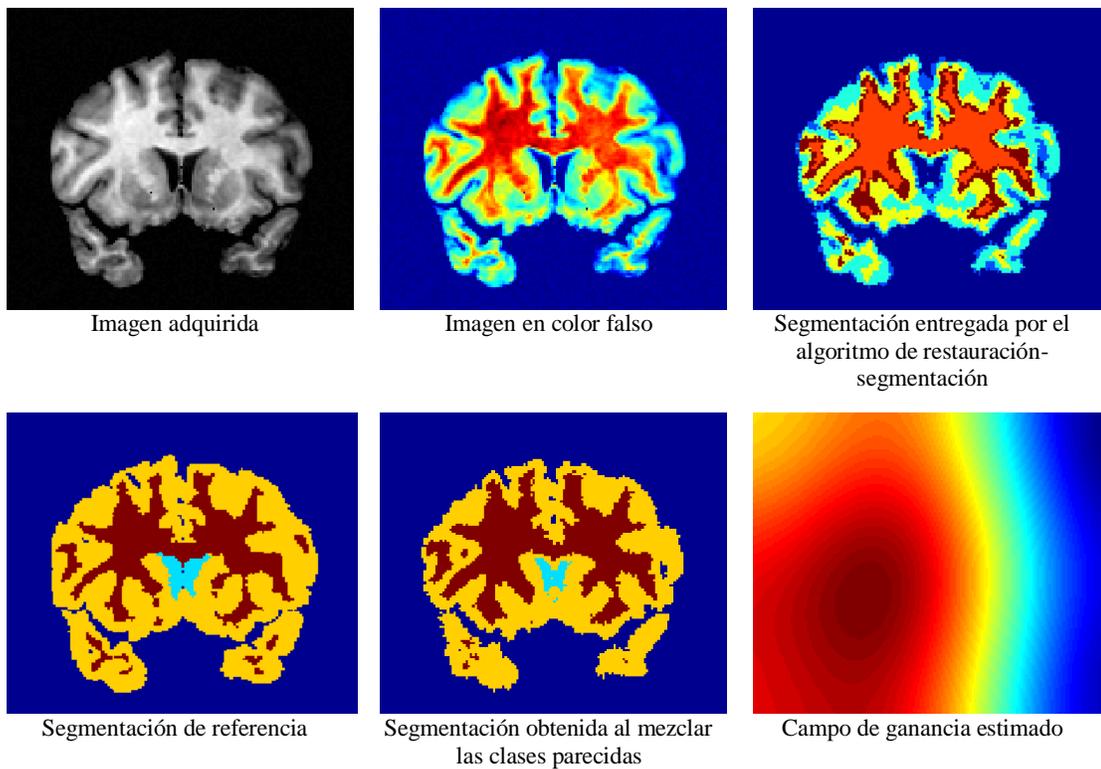


Figura 6.31. Comparación entre la imagen adquirida, la segmentación de referencia y las segmentaciones obtenidas, así como el campo de ganancia estimado.

6.8. CONSIDERACIONES SOBRE EL TIEMPO DE PROCESAMIENTO.

El tiempo de procesamiento para una imagen de 181 x 217 en una computadora Intel® Core 2 Duo T7500 a 2.20GHz, con una memoria RAM de 2.0 GB, ejecutando Matlab® en Windows Vista® es de 47 segundos para cada iteración de promediación del estimado del campo de ganancia (en el conjunto de imágenes hubo entre 11 y 18 iteraciones de promediación) y 1 minuto con 16 segundos por cada imagen para el resto del proceso implementado.

6.9. COMPARACIÓN DEL VALOR DE KAPPA OBTENIDO.

En la evaluación del método propuesto utilizando imágenes sintéticas de RMN [45,46] para diferentes niveles del campo de ganancia (10% a 30%) se obtuvo una medida de similitud de probabilidad (Kappa) entre 0.93 y 0.97, respecto de las segmentaciones ideales.

C. A. Cocosco [6] empleó la derivación de una *estructura jerárquica de datos* (*graph theoretical clustering*) para estimar la función de densidad de probabilidad, obteniendo valores de Kappa entre 0.90 y 0.95, para un conjunto de imágenes sintéticas también obtenidas del simulador de la Universidad de McGill [45,46], requiriendo además, un modelo a priori (mapa de probabilidad de tejidos) para la clasificación de los datos, así como conocimiento a priori acerca de la posición relativa de los agrupamientos de los datos en el espacio de características.

CAPÍTULO 7

DISCUSIÓN Y CONCLUSIONES

Cumpliendo con el objetivo general planteado en el capítulo 4, se ha presentado un método para la restauración-segmentación de IRM que puede corregir la imagen y realizar una estimación satisfactoria del campo de ganancia, obteniendo segmentaciones útiles.

El modelo asumido en la ecuación 3.1: $Y = (X * G) + R$, requiere considerar la eliminación del ruido aditivo, este fin se logra satisfactoriamente utilizando los estimadores robustos de localización y de dispersión asociados a cada pixel de la imagen, como pudo observarse en la figura 6.20, la ventaja de usar estos parámetros robustos, para obtener los vectores de características, es que son mejores descriptores del pixel al que están asociados porque consideran tanto información de una localidad pequeña (ventana de datos) como información global de la ubicación del pixel (ventana de análisis). Si sólo se emplea la media y la desviación estándar como descriptores, es muy probable que existan muchos vectores de características afectados por valores fuera de rango y por la cercanía a los bordes, la moda realzada es menos susceptible a que ello ocurra y su valor de dispersión asociado se obtiene excluyendo los valores fuera de rango.

Para evitar la generación de clases falsas por la presencia de los bordes se hizo la consideración en el método de cambiar los valores altos de dispersión por el valor de moda asociado en el histograma de los estimadores robustos de dispersión de toda la imagen. Inclusive si se presentaran diferentes valores de dispersión, dependiendo de las diferencias de los tejidos, el método puede asignar diferentes valores de dispersión asociados a su localidad.

El espacio de características obtenido con los parámetros mencionados se encuentra libre de pequeños agrupamientos, producto del efecto de los bordes, por lo que este objetivo específico se alcanzó.

También se logró el segundo objetivo específico. Para determinar las clases principales presentes en la imagen (centroides en el espacio de características) se empleó el algoritmo de Corrimiento de Media, que ofrece excelentes resultados a diferencia de los métodos que asumen modelos de mezclas de gaussianas, ya que la disposición de los agrupamientos no siempre puede modelarse con gaussianas.

Como se observó en la tabla 6.1, el algoritmo de Corrimiento de Media encontró solo las clases principales con una muy buena aproximación. En la figura 6.1, se apreció en tres dimensiones los resultados del algoritmo de Corrimiento de Media sobre el estimado de la densidad del espacio de los vectores de entrenamiento, también se observó que los errores de aproximación más grandes ocurren en la tercera y cuarta clases, debido a que en esa región de la imagen la intensidad de la inhomogeneidad del campo es mayor.

El ajuste del radio del kernel para el algoritmo de Corrimiento de Media es fundamental, ya que si es muy pequeño puede ignorar algunas clases importantes con pocos vectores en el espacio de características y, por otra parte, si es demasiado grande puede unir algunas clases muy próximas, como se apreció en las figuras 6.10, 6.11, 6.12 y 6.13. En el trabajo presentado el radio se ajustó experimentalmente y su valor óptimo se encontró cuando es menor a veinte, se plantea como trabajo futuro escribir una función que optimice el radio del kernel, inclusive que pueda ser variable dependiendo de la región.

Para cumplir con el tercer objetivo específico planteado, se construyó una Red Neuronal Probabilística, aprovechando los parámetros robustos de localización y dispersión como vectores para la capa de entrada, un subconjunto de los datos para la capa de patrones y las clases principales encontradas por el algoritmo de Corrimiento de Media para la capa de clases.

Para la interconexión entre la capa de patrones y la capa de clases se empleó un Clasificador de Distancia de Mahalanobis para unir los puntos a su centroide correspondiente. El desempeño del clasificador es aceptable como pudo apreciarse en la tabla 6.2 y ofrece rapidez para realizar esta tarea. Sin embargo, las ventajas del algoritmo de Corrimiento de Media incluyen poder seguir la ruta que cada punto toma hasta converger en alguna de las clases encontradas, entonces el uso del Clasificador de Distancia de Mahalanobis puede reemplazarse almacenando esta información, lo cual se plantea como trabajo futuro, con la debida consideración de que al trabajar con todos los puntos, y no con un subconjunto de ellos como en este trabajo, el algoritmo de Corrimiento de Media incrementa significativamente el gasto computacional.

Para cumplir con el cuarto objetivo específico se incorporó la Red Neuronal Probabilística construida al método de Restauración-Segmentación de Wells, ya que los valores a la salida de la red son un estimado de las probabilidades a posteriori, empleadas para la estimación de la imagen estadística, la estimación del campo de ganancia y aplicando el criterio de Bayes obtener la segmentación de la imagen. En la figura 6.24 se muestran los resultados con una imagen contaminada con valores típicos de ruido aditivo y de campo de ganancia, donde se observa que la segmentación obtenida es totalmente aprovechable.

Como se observó en la figura 6.23, las estimaciones obtenidas del campo de ganancia mejoran aplicando un suavizado iterativo, por lo que se propuso como criterio de paro las diferencias entre los valores máximos de los píxeles presentes de una iteración a otra. Con el proceso realizado, se logra atenuar la estructura cerebral que también se aprecia y se genera inherentemente en la estimación inicial del campo de ganancia.

Para validar la eficiencia del método se propusieron tanto elementos cualitativos como cuantitativos. En la sección 6.3 del capítulo de resultados se apreciaron los estimados de las probabilidades a posteriori a la salida de la red, mostrados como imagen para cada clase. En estas imágenes puede verse como van disminuyendo los valores de los estimados a medida que incrementa la intensidad del campo de ganancia y con ello la certidumbre en la clasificación, sin embargo se aprecia que el método puede dar buenos resultados aun en

presencia de inhomogeneidades severas, más allá de los valores típicos (30% de campo de ganancia).

En el mismo sentido de evaluación cualitativa en la sección 6.3, se presentaron los factores de confianza como una imagen cuya condición ideal es que todos sus valores sean uno, se observó en la figura 6.3 que la segmentación contiene muchos errores cuando hay una inhomogeneidad muy severa (40%), pero que en valores cercanos al 30% la segmentación puede ser útil, aún cuando el factor de confianza indique que las diferencias entre la primera y la segunda probabilidades a posteriori asociadas a un pixel sean del orden de 0.5.

Para la evaluación del método también se propuso obtener matrices de confusión y el valor Kappa, que proporcionan una medición cuantitativa de los resultados obtenidos. Se plantea como trabajo futuro que puedan incluirse otros criterios de evaluación cuantitativa como el coeficiente de Tanimoto, que permitan comparar directamente los resultados con otros trabajos.

Como es deseable que el método sea totalmente automatizado, en la sección 6.5, se presentó un análisis de susceptibilidad de los parámetros principales usados en el método y ajustados experimentalmente. En el caso de las ventanas de análisis, se observó en la figura 6.5 que el mejor valor de Kappa ocurre cuando $Wd_{x,y}=7$ y $wa_{x,y}=3$, lo cual es un compromiso entre la información local y global para la obtención de las modas realizadas, si la ventana de datos es mayor a nueve comienza a generarse un efecto de excesivo suavizamiento en la imagen que se usará en todo el proceso.

Para evitar la generación de clases falsas por los bordes entre los objetos de la imagen, como las que se mostraron en la figura 6.6, se analizó el umbral de censurado para la desviación estándar máxima permitida, encontrándose que el método puede funcionar adecuadamente si el umbral de censurado se encuentra por debajo de dos, como se apreció en las figura 6.8. y 6.9; esta característica es una ventaja respecto a otros métodos que no consideran la posibilidad de diferentes valores de dispersión presentes a lo largo de la imagen.

Sin lugar a dudas el valor de σ^2 de la Red Neuronal Probabilística es un parámetro crucial para la obtención de los estimados de las probabilidades posteriores, como se apreció en las figuras 6.18 y 6.19, los mejores valores de Kappa se encuentran por debajo de 0.01, esto se debe a que la función de activación de la red (que es exponencial) se vuelve muy pronunciada para el rango de valores pequeños, lo que permite una mayor sensibilidad de la red para determinar a cual clase tiene mayor pertenencia el pixel bajo análisis.

Se analizaron diferentes imágenes sintéticas obteniendo buenos resultados para la segmentación, como se apreció en las matrices de confusión (mostrados en las tablas 6.12 y 6.13) para diferentes niveles y morfologías del campo de ganancia. El procedimiento realizado a la imagen entrega un estimado del campo de ganancia con un aspecto que sigue su intensidad de manera global, como se observó en la figura 6.28, pero la estructura anatómica presente en la imagen sigue alterando de manera significativa la estimación ya que el campo se obtiene a partir del cociente entre la imagen observada y la imagen corregida. Como trabajo futuro se puede mejorar la estimación del campo de ganancia.

Los resultados de las segmentaciones para las imágenes reales son aceptables, como se observó en la tabla 6.14 y en las figuras 6.29 y 6.30. Entre la materia gris y la materia blanca existe la mayor confusión cuando los bordes son muy pronunciados y cuando hay zonas con pocos pixeles de una clase. En las imágenes donde sólo se segmentaron tres clases, se mejoran los resultados, ya que hay zonas más amplias y los estimadores de dispersión y localización se afectan menos.

En las imágenes reales, se logró obtener una buena aproximación del campo de ganancia, como se observó en la figura 6.31, ya que las imágenes analizadas presentaron un ligero sesgo hacia la parte izquierda que se logró aproximar en las escenas.

También para las imágenes reales, de la segmentación entregada por el método de Restauración-Segmentación, se mezclaron clases parecidas, con la finalidad de poder hacer una comparación cuantitativa con la segmentación de referencia. Sin embargo, como se observó en la figura 6.31, algunas veces el procedimiento realizado encuentra más clases, algo

que se puede apreciar al ver la gama de tonos visibles en la imagen adquirida en falso color, pero poco visible en escala de grises, que es como usualmente los médicos analizan las imágenes, entonces las clases adicionales encontradas pueden ser de poco valor en la práctica médica y ser útiles para otros fines de investigación o de análisis.

Por la susceptibilidad de los parámetros no puede concluirse que el método propuesto sea totalmente automatizado, ya que deben revisarse los mejores valores cuando se cambie de un conjunto de imágenes a otro obtenido en condiciones diferentes, e incluso de un equipo a otro. Sin embargo, se plantea como trabajo futuro analizar los mejores valores probando con diferentes conjuntos para que el método no requiera mayor intervención del usuario y los resultados sean útiles.

Con técnicas de estimación paramétricas se pueden obtener resultados favorables, pero tienen de manera implícita además del error bayesiano de clasificación, la desventaja de asumir un modelo gaussiano para la distribución de probabilidad de la imagen y son altamente dependientes de las condiciones iniciales. El modelado no paramétrico tiene la ventaja de no asumir un modelo para distribución, pero implica mayor tiempo de análisis.

Finalmente se concluye que el modelado no paramétrico en IRM continuará siendo objeto de diversos trabajos, buscando eliminar la influencia de los ruidos, los resultados dependientes del operador y analizar la mayor cantidad de información en el menor tiempo posible.

BIBLIOGRAFÍA

[1] M. José-León. (2003, Agosto) *Resonancia Magnética: Historia, Bases Físicas e Imágenes*. [En línea]. Disponible en: <http://members.fortunecity.es/reino1/>

[2] M. Canals. (2008, Diciembre) *Historia de la Resonancia Magnética de Fourier a Lauterbur y Mansfield*. [En línea]. Revista Chilena de Radiología, Vol.14, no.1, pp. 39-45. Disponible en: http://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0717-93082008000100009

[3] J. L. Prince, y J. M. Links, *Medical Imaging Signals and Systems*, 1st ed. New Jersey, USA: Pearson Prentice Hall, pp. 379-455, 2006.

[4] R. Valdés-Cristerna, J. Aspiroz-Leehan, E. Hernández-Matos, y M. Cadena-Méndez, *Imagenología Médica*, 1^a ed. México: Universidad Autónoma Metropolitana Unidad Iztapalapa – Editorial Marsa S.A., pp. 115-179, Octubre 1995.

[5] C. D. Gregory, J. Hanson. (2004, Enero) *MRI Artefact Gallery*. [En línea]. Disponible en: <http://chickscope.beckman.uiuc.edu/roosts/carl/artifacts.html>

[6] C. A. Cocosco, *Automatic Generation of Training Data for Brain Tissue Classification from MRI*, Montreal, Canada: Master of Engineering Thesis McGill University, pp 1-74, April 2002.

[7] J. G. Sled and G. B. Pike, “Standing-Wave and RF Penetration Artifacts Caused by Elliptic Geometry: an Electrodynamics Analysis of MRI”. *IEEE Trans. Med. Imag.*, vol. 17, pp. 653-662. 1998.

- [8] R. G. Roozbahani, M. H. Ghassemian, and A. R. Sharafat, "Estimating Gain Fields in Multispectral MRI", *IEEE Trans. Biomed. Eng.*, vol. 47, pp. 1610-1615, 2000.
- [9] H. Kucharova and A. Gottvald, "Identifying Inhomogeneity Functions in MRS", in *Proc. 13th International Conference Biosignal '96*, Czech Republic, June 1996.
- [10] G. A. Morris, *Direct Methods for Field Homogeneity Optimization in NMR Spectroscopy*, Manchester UK: Department of Chemistry, The Victoria University of Manchester, December 1998.
- [11] A. Wismuller, F. Vietze, D. R. Dersch, *Handbook of Medical Imaging - processing and analysis*, USA: Academic Press, chapter 7, pp. 107-126, 2000.
- [12] J. Bernd, *Digital Image Processing*, 6th ed. New York: Springer-Verlag, pp. 93-230, 2005.
- [13] K. R. Castleman, *Digital Image Processing*, New Jersey, USA: Prentice-Hall, pp. 447-482, 1996.
- [14] B. M. Dawant, A. P. Zijdenbos, *Handbook of Medical Imaging: Medical Image Processing and Analysis*, vol. 2, WA, USA: SPIE Press Bellingham, 2000.
- [15] K. Held , E. R. Kops, B. J. Krause, W. M. Wells, R. Kikinis, H. W. Muller, "Markov Random Field Segmentation of Brain MR Images". *IEEE Trans. Med. Imag.*, vol. 16, pp. 878-886, 1997.
- [16] J. C. Rajapakse, J. N. Giedd, J. L. Rapoport , "Statistical Approach to Segmentation of Single-Channel Cerebral MR Images". *IEEE Trans. Med. Imag.*, vol. 16, pp. 176-186, 1997.
- [17] M. X. H. Yan, J. S. Karp, "An Adaptive Bayesian Approach to Three Dimensional MR Brain Segmentation", *Information Processing in Medical Imaging (IPMI)*, pp. 201-213, 1995.

- [18] J. K. Udupa, S. Samarasekera, "Fuzzy Connectedness and Object Definition: Theory, Algorithms and Applications in Image Segmentation". *Graphical Models and image Processing*, vol. 58, pp 246-261, 1996.
- [19] W. J. Niessen, K. L. Vincken, J. Weickert, B. M. T. Romeny, M. A. Viergever, "Multiscale Segmentation of Three-Dimensional MR Brain Images". *International Journal of Computer Vision*, vol. 31, pp. 185-202. 1999.
- [20] S. K. Warfield, M. Kaus, F. A. Jolesz, R. Kikinis, "Adaptive, Template Moderated, Spatially Varying Statistical Classification", *Medical Image Analysis*, vol. 4, pp. 43-55, 2000.
- [21] W. M. Wells, W. E. L. Grimson, R. Kikinis, and F. A. Jolesz, "Adaptive Segmentation of MRI Data", *IEEE Trans. Med. Imag.*, vol. 15, pp. 429-442, 1996.
- [22] R. Guillemaud, and M. Brady, "Estimating the Bias Field of MR Images", *IEEE Trans. Med. Imag.*, vol. 16, pp. 238-251, 1997.
- [23] P. Schroeter, J. M. Vesin, T. Langenberger, R. Meuli, "Robust Parameter Estimation of Intensity Distributions for Brain Magnetic Resonance Images", *IEEE Trans. Med. Imag.*, vol. 17, pp. 172-186, 1998.
- [24] K. Van Leemput, F. Maes, D. Vandermeulen, and P. Suetens, "Automated Model-Based Bias Field Correction of MR Images of the Brain", *IEEE Trans. Med. Imag.*, vol. 18, pp. 885-896, 1999.
- [25] K. Van Leemput, F. Maes, D. Vandermeulen, and P. Suetens, "Automated Model-Based Tissue Classification of MR Images of the Brain", *IEEE Trans. Med. Imag.*, vol. 18, pp. 897-908, 1999.
- [26] J. Ashburner, *Computational Neuroanatomy*, London, UK: PhD Thesis University College, 2000.

- [27] J. Ashburner, K. J. Friston, "Voxel-Based Morphometry - the Methods", *Neuroimage*, vol. 11, pp. 805-821. 2000.
- [28] M. Garza-Jinich, V. Medina B., O. Yáñez S., P. Meer, "Automatic Correction of Bias Field in Magnetic Resonance Images", in *Proc. IEEE 10th International Conference on Image Analysis and Processing*, Venice, Italy, 1999, p.p.752-756.
- [29] M. Garza-Jinich, *Delineación Robusta de Estructuras Tridimensionales en Imágenes de Resonancia Magnética*, México: Tesis Doctoral Universidad Autónoma Metropolitana Unidad Iztapalapa, pp. 1-107, 1998.
- [30] M. Garza-Jinich, P. Meer, V. Medina B., "Robust Retrieval of Three-Dimensional Structures from Images Stacks", *Medical Image Analysis*, vol. 3, pp. 21-35, 1999.
- [31] M. Garza-Jinich, P. Meer, V. Medina B., "Robust Retrieval of 3D Structures from Magnetic Resonance Images", in *Proc. IEEE 13th International Conference on Pattern Recognition (ICPR '96)*, Vienna, Austria, 1996, vol. 3, p.p. 391-395.
- [32] S. Theodoridis, K. Koutroumbas, *Pattern Recognition*, San Diego, USA: Academic Press, pp. 1-625, 1999.
- [33] D. Comaniciu and P. Meer, "Distribution Free Decomposition of Multivariate Data", in *Proc. 2nd International Workshop on Statistical Techniques in Pattern Recognition*, Sydney, Australia, 1998.
- [34] J. R. Jiménez, V. Medina and O. Yáñez Suárez, "Segmentación no Paramétrica de Imágenes Cerebrales de RM usando Corrimiento de Media y Mapas de Confianza. *UAMI Jornadas del Posgrado Divisional en Ciencias Básicas e Ingeniería*, pp. 139-142, 2004.

- [35] J. R. Jiménez, V. Medina and O. Yáñez, “Data-Driven Brain MRI Segmentation Supported on Edge Confidence and *A Priori* Tissue Information”. *IEEE Transactions on Medical Imaging*, vol. 25, pp.74-83, 2006.
- [36] H. S. Choi, D. R. Haynor, and Y. Kim, “Partial Volume Tissue Classification of Multichannel Magnetic Resonance Images – a Mixel Model”, *IEEE Trans. Med. Imag.*, vol. 10, pp. 395-407, 1991.
- [37] D. H. Laidlaw, K. W. Fleischer, and A. H. Barr, *Handbook of Medical Imaging*, San Diego, USA: Academic Press, chapter 13, pp. 195-211, 2000.
- [38] D. L. Pham, J. L. Prince, “Adaptive Fuzzy Segmentation of Magnetic Resonance Images”, *IEEE Trans. Med. Imag.*, vol. 18, pp. 737-752, 1999.
- [39] W. E. Reddick, J. O. Glass, E. N. Cook, T. D. Elkin, and R. J. Deaton, “Automated Segmentation and Classification of Multispectral Magnetic Resonance Images of Brain Using Artificial Neural Networks”. *IEEE Trans. Med. Imag.*, vol. 16, pp. 911-918, 1997.
- [40] M. Morrison, and Y. Attikiouzel, “A Probabilistic Neural Network Based Image Segmentation Network for Magnetic Resonances Images”, in *Proc. of Conference on Neural Network*, Baltimore, USA , 1992, vol. 3, pp. 60-65.
- [41] S. Kollias, and D. Kalogeras, “A Multiresolution Probabilistic Neural Network for Image Segmentation”, in *Proc. IEEE International Conference on Acoustic, Speech and Signal Processing ICASSP-94*, Australia, 1994, vol. 2, pp. 569-572.
- [42] G. Harris, N. C. Andreasen, T. Cizadlo, J. M. Bailey, H. J. Bockholt, V. A. Magnotta, S. Arndt, “Improving Tissue Classification in MRI: a three-dimensional multispectral discriminant analysis method with automated training class selection”, *Journal of Computer Assisted Tomography*, vol. 23, pp. 144-154, 1999.

- [43] M. Kamber, R. Shinghal , D. L. Collins, G. S. Francis, A. C. Evans, “Model Based 3-D Segmentation of Multiple Sclerosis Lesions in Magnetic Resonance Brain Images”, *IEEE Trans. Med. Imag.*, vol. 14, pp. 442-453, 1995.
- [44] D. F. Specht, “Probabilistic Neural Networks”, *Neural Networks*, vol. 3, no. 1, pp. 109-118, 1990.
- [45] McConnell Brain Imaging Centre. (2003, febrero) *BrainWeb: Simulated Brain Database*. [En línea]. Disponible en: <http://www.bic.mni.mcgill.ca/brainweb/>
- [46] C. A. Cocosco, V. Kollokian, R. K. S. Kwan, A. C. Evans, “BrainWeb: Online Interface to a 3D MRI Simulated Brain Database”, in *Proc. of 3rd International Conference on Functional Mapping of the Human Brain*, Copenhagen, Dinamarca, 1997, vol. 5, no. 4.
- [47] R.K.-S. Kwan, A. C. Evans, G. B. Pike, *An Extensible MRI Simulator for Post-Processing Evaluation*, USA: Visualization in Biomedical Computing (VBC'96), Lecture Notes in Computer Science, Springer-Verlag, vol. 1131, pp. 135-140, 1996.
- [48] D. L. Collins, A. P. Zijdenbos, V. Kollokian, J. G. Sled, N. J. Kabani, C. J. Holmes, A. C. Evans, “Design and Construction of a Realistic Digital Brain Phantom”, *IEEE Trans. Med. Imag.*, vol. 17, pp. 463-468, 1998.
- [49] R. K.-S. Kwan, A. C. Evans, G. B. Pike, “MRI simulation-based evaluation of image-processing and classification methods”, *IEEE Trans. Med. Imag.*, vol. 18, pp. 1085-1097, 1999.
- [50] C. Pérez, y D. Santín, *Data Mining: Soluciones con Enterprise Miner*, 1ª ed. México: Alfaomega Grupo Editor, pp. 483-507, Julio 2006.

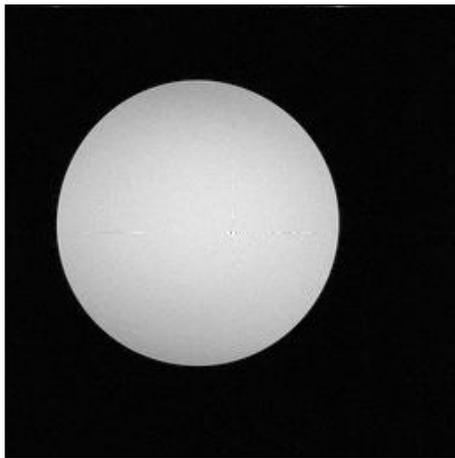
[51] J. Lira-Chávez, *Introducción al tratamiento digital de imágenes*, 1ª ed. México: Instituto Politécnico Nacional – Universidad Nacional Autónoma de México – Fondo de Cultura Económica, pp. 337-430, Septiembre 2002.

[52] S. Siegel, y N. J. Castellan, *Estadística no paramétrica: aplicada a las ciencias de la conducta*, 4ª ed. México: Trillas, pp. 260-356, enero 2005.

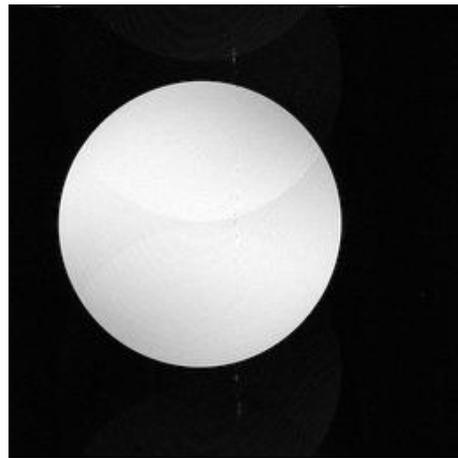
[53] J. Cohen, “A Coefficient of Agreement for Nominal Scales”, *Educational and Psychological Measurements*, vol. 20, pp. 37-46, 1960.

APÉNDICE A

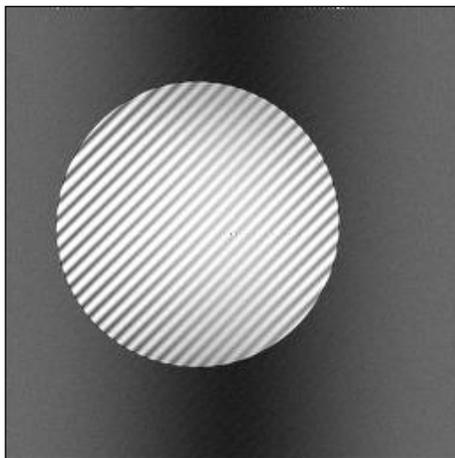
GALERIA DE ARTEFACTOS EN IRM



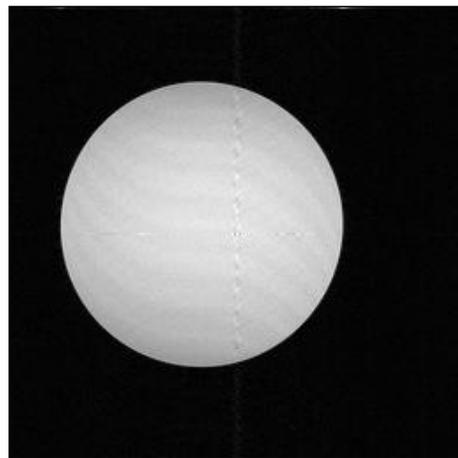
a). Imagen de RMN de referencia.



b). Imagen de RMN alterada con un Artefacto por Audio-Frecuencia.

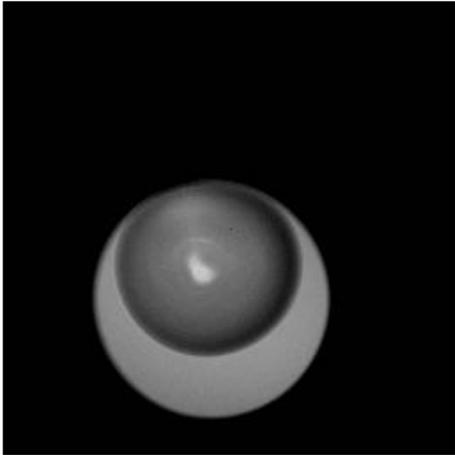


c). Imagen de RMN alterada posiblemente por un transitorio eléctrico.

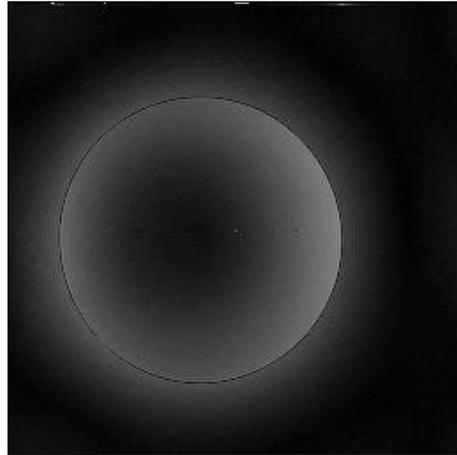


d). Imagen de RMN alterada posiblemente debido a una desconexión momentánea de algún cable.

FIGURA A.1



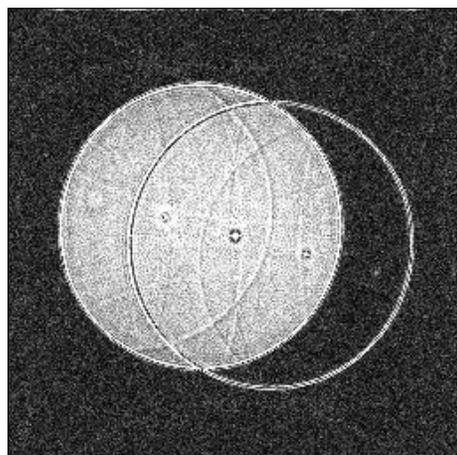
a). Artefacto por Corrimiento Químico.



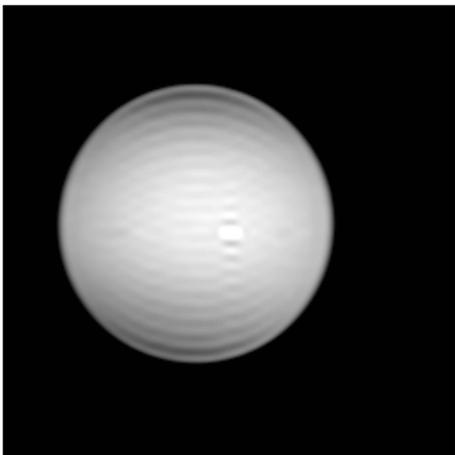
b). Artefacto por Desbordamiento del Convertidor Analógico-Digital (Clipping - ADC Overflow).



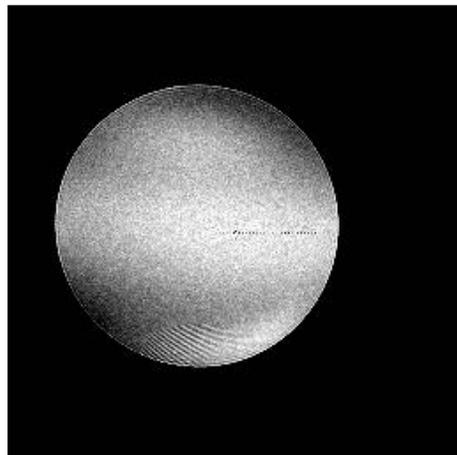
c). Artefacto por Desplazamiento de la Corriente Directa (DC offset).



d). Efecto de la disminución del rango de digitalización de 16 a 8 bits.

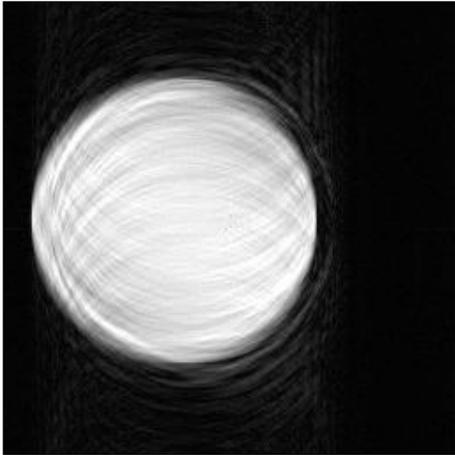


e). Artefacto de Gibss.

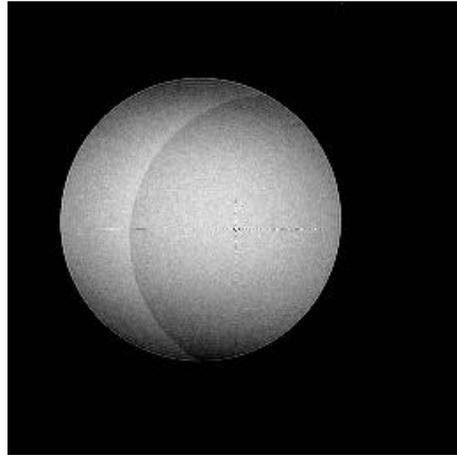


f). Artefacto de Moire.

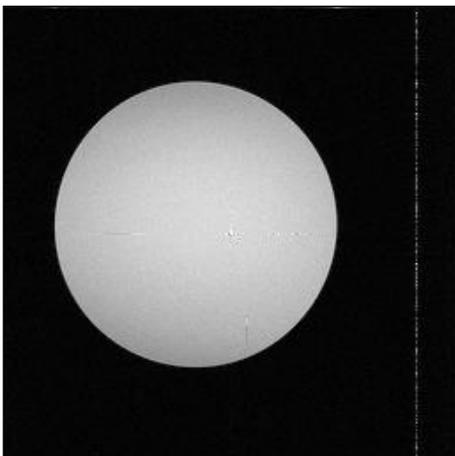
FIGURA A.2



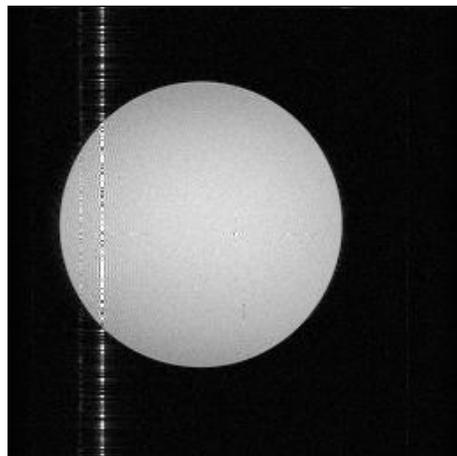
a). Alteración por Movimiento.



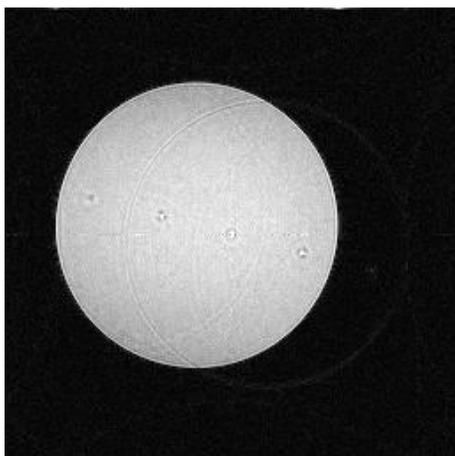
b). Artefacto por Fantasma de Cuadratura (Quadrature Ghost).



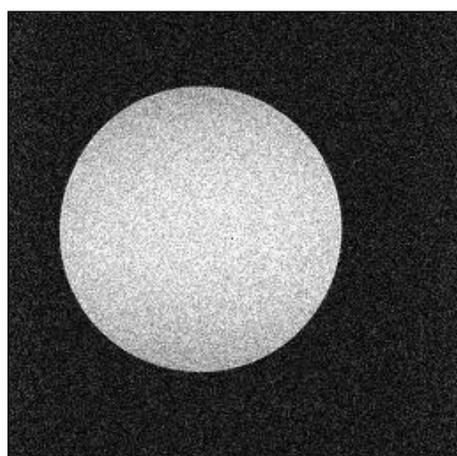
c) Alteración por Interferencia de RF a 170 MHz, con ancho de banda de 50KHz.



d) Alteración por Interferencia de RF 170 MHz, con ancho de banda de 100KHz.

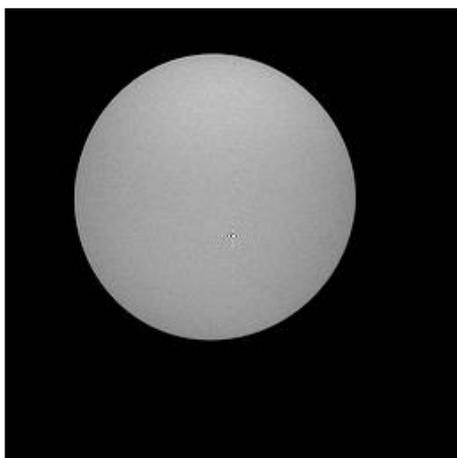


e). Artefacto por Dato Arrancado (Stuck Bit).

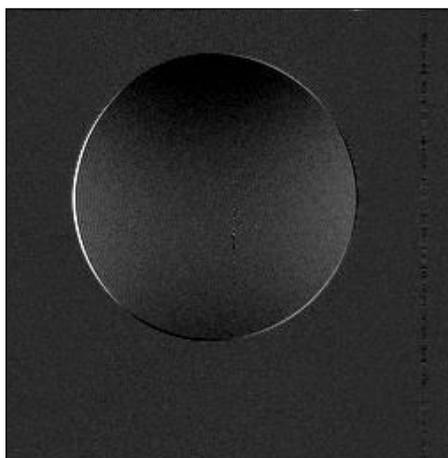


f). Artefacto por Ruido Aleatorio.

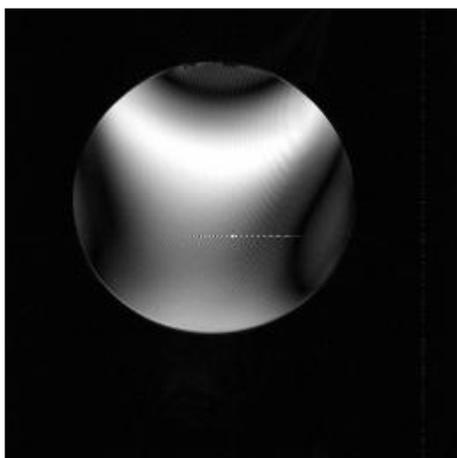
FIGURA A.3



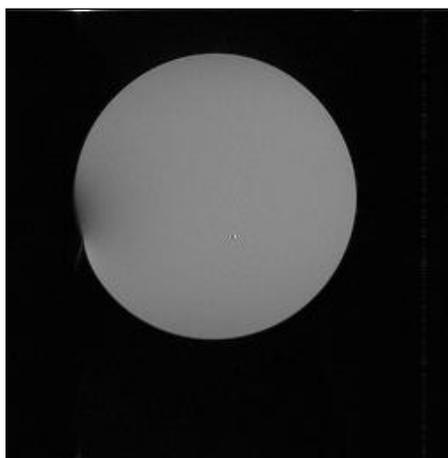
a) Artefacto por Desajuste de Compensación, con una secuencia spin-echo y un error de 1.86 A.



b) Artefacto por Desajuste de Compensación. Diferencia entre la imagen de referencia y la distorsionada.



c) Artefacto por Desajuste de Compensación, con una secuencia echo-gradient y un error de 0.61 A.



d). Artefacto por Susceptibilidad.



e). Artefacto por Inhomogeneidad de Campo Magnético.

FIGURA A.4