



**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO
PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA
INGENIERÍA ELÉCTRICA - PROCESAMIENTO DIGITAL DE SEÑALES**

*Proyecto correspondientes al
Examen General de Conocimientos*

Alumno: Hernández Delgado Armando Salomón

Revisor: Dr. Boris Escalante Ramírez

AM UNAM UNAM UNAM
UNAM UNAM UNAM UNAM
UNAM UNAM UNAM UNAM
UNAM UNAM UNAM UNAM
UNAM UNAM UNAM UNAM

Contenido

Planteamiento del problema.....	1
1. INTRODUCCIÓN.....	2
1.1 Segmentación de imágenes.....	2
1.2 Preprocesamiento	2
1.2.1 Filtros lineales espaciales.	3
1.2.2 Filtros pasobajas (reducción de ruido/suavizado de imagen).....	4
1.2.3 Realce de bordes	5
1.2.4 Mejoramiento de nitidez basado en segunda derivada.....	5
1.3 Modelo de degradación y restauración.....	7
Filtro Wiener.....	8
1.4 Enfoques de segmentación.....	9
1.4.1 Detección óptima, detector óptimo	9
1.4.2 Umbralización.....	10
1.4.3 Crecimiento de regiones.....	11
1.4.4 Agrupamiento por K-medias.....	11
1.4.5 Clasificador Bayesiano.....	12
2. HIPÓTESIS.....	14
3. OBJETIVO.	14
4. METODOLOGÍA PROPUESTA	15
5. DESARROLLO.....	16
5.1 Proceso de Degradación Restauración	16
5.2 Segmentación con el algoritmo de k-medias.	25
5.3 Post procesamiento: Filtros morfológicos. Indexación.	25
5.4 Segmentación con clasificador Bayesiano.	27
6. RESULTADOS.....	29
7. EVALUACIÓN.....	36

8. CONCLUSIONES.....	38
9. BIBLIOGRAFÍA.....	40

Planteamiento del problema.

En la imagen de la figura 1, la estructura central (con forma de mariposa) es el mesencéfalo. El problema consiste en segmentar el mesencéfalo de tal forma que el resultado final consistirá en la delimitación del contorno del mesencéfalo, es decir, debes entregar una imagen similar a las que te anexo, con el contorno del mesencéfalo marcado con una línea blanca sobrepuesta.

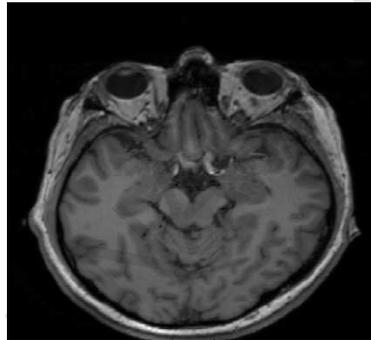


Figura 1. Imagen de trabajo.

Puedes utilizar o desarrollar cualquier método para lograr este objetivo, pero debes utilizar métodos que te permitan contestar las siguientes preguntas:

1. Desde el punto de vista de la teoría de la detección, ¿aplicar un filtro lineal ya sea pasobajas para suavizar el ruido o del tipo unsharp masking para realzar los bordes de la estructura, debe mejorar el desempeño de un detector óptimo? ¿Existe un filtro lineal óptimo que optimice el proceso de detección en imágenes con ruido? ¿Cuál es?
2. Aplica sendos filtros de Wiener para reducir ruido y para mejorar la nitidez y comprueba si el desempeño de tu algoritmo de segmentación mejora con la aplicación de estos dos filtros. Compara tus resultados con la respuesta a la pregunta anterior.
3. Explica qué métodos de segmentación utilizaste y justifica la elección.
4. Conclusiones finales

Además del resultado, deberás entregar un reporte del proyecto que contenga introducción, hipótesis, metodología propuesta, desarrollo, resultados, evaluación, conclusiones y bibliografía. El software utilizado lo deberás anexar en un apéndice, además de agregarlo en un CD, o puedes enviármelo por correo electrónico. Puedes utilizar la plataforma de desarrollo que desees: matlab, C, itk, etc.

Si usas metodologías o software ajenas, de otros autores, debes mencionarlo en el reporte y citarlos en la bibliografía.

1. INTRODUCCIÓN.

1.1 Segmentación de imágenes.

La segmentación de imágenes es una técnica de procesamiento que se refiere a la extracción de información útil de una escena para facilitar su observación y análisis. El objetivo principal del proceso de segmentación es particionar una imagen en diversas regiones también llamadas clases o subimágenes, que son homogéneas con respecto a una o más características o atributos.

La segmentación es una herramienta importante en procesamiento de imágenes médicas y ha sido útil en varias aplicaciones, tales como: cuantificación de lesiones en esclerosis múltiple, planeación y simulación de cirugías, medición de volumen de tumores, clasificación automática de células en la sangre, estudios de desarrollo cerebral, detección de microcalcificación en mastografías, detección de tumores, etc. También es importante para extracción de atributos en una imagen, medición y despliegue; en otras aplicaciones es útil para diferenciar regiones anatómicas, órganos, músculos y sistema circulatorio de regiones con alguna patología como tumores, deformidades o lesiones. En algunos otros estudios el objetivo es dividir la imagen completa en secciones en el cerebro como materia gris, materia blanca y espacios de fluido cerebroespinal, y en otros se debe extraer por ejemplo una sección específica.

Se enfrenta tres problemas principales en la segmentación de imágenes médicas vinculados a su adquisición y a la fuente que la genera:

- Las imágenes contienen gran cantidad de ruido, lo cual dificulta la clasificación de píxeles por intensidad.
- La intensidad en los tejidos y órganos, no es uniforme.
- La intensidad de un pixel está indirectamente relacionado con el tejido de interés pero también con otros que se desean suprimir.

Tomando en cuenta estos retos, se han empleado diversas técnicas de segmentación y combinación de éstas, sin embargo no hay una técnica estándar que produzca resultados satisfactorios para todas las aplicaciones. La definición del objetivo de la segmentación varía de acuerdo al objetivo del estudio o aplicación y al tipo de imagen.

1.2 Preprocesamiento

Con frecuencia, las imágenes médicas contienen bajo contraste, contornos borrosos. También es común que los modos del histograma correspondientes a los diferentes tipos de regiones en la imagen se traslapen, haciendo que la segmentación por umbralización se dificulte. La aplicación de técnicas un preprocesamiento pueden ayudar a diferenciar los modos en el histograma.

1.2.1 Filtros lineales espaciales.

Se denominan operaciones por vecindad a aquellas técnicas de procesamiento en las que el valor resultante de un píxel de coordenadas (x_0, y_0) , el cual llamaremos el píxel referencia, es función del valor original del píxel en ese punto así como de los valores de los píxeles vecinos. La forma en la que los valores se combinan para producir el resultado puede variar significativamente entre algoritmos. Muchos algoritmos trabajan en forma lineal y usan la convolución en dos dimensiones, mientras que otros procesan los valores de una forma no lineal. Al tipo de operaciones que se realizan directamente en los píxeles de una imagen se denominan filtros espaciales, para diferenciarlos de los filtros en el dominio de la frecuencia.

Como se mencionó anteriormente, la operación asociada con un filtro lineal es la convolución y en general opera con dos funciones de la misma dimensionalidad, ambos discretos, para el caso de imágenes digitales.

La mecánica del filtrado lineal espacial consiste en mover el centro de la máscara filtro (kernel o ventana) de punto a punto en la imagen, realizando en cada punto la suma de productos de los coeficientes del kernel con los píxeles vecinos, contenidos en el área cubierta por el kernel del filtro, como se muestra gráficamente en la figura 2.

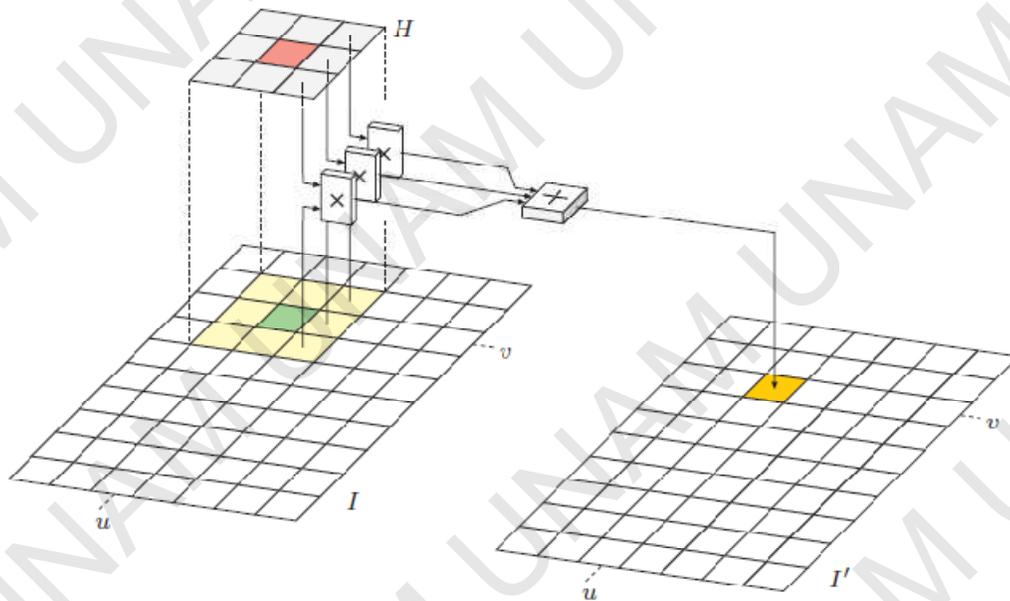


Figura 2. Proceso de obtención de los píxeles procesados, por medio de la suma de productos de los valores de píxeles de la imagen original I y los coeficientes del kernel H . Imagen adaptada de [5].

Existen dos conceptos estrechamente relacionados al realizar filtrado lineal espacial: la correlación y la convolución. La correlación es el proceso de realizar la operación anteriormente descrita con el kernel y la imagen. La convolución es operacionalmente el mismo proceso excepto que el kernel es reflejado en ambas direcciones, horizontal y vertical.

1.2.2 Filtros pasobajas (reducción de ruido/suavizado de imagen).

Uno de los usos principales del filtrado en imágenes es para eliminar ruido de la imagen; homogeneizar regiones afectadas por ruido, suavizando el gradiente de intensidad de la imagen, que puede ser sometida a un proceso posterior de procesamiento mejorando el desempeño de éste. A continuación se describen los filtros más comunes, es una lista no exhaustiva pero representante [1].

Filtro de media

Una técnica de filtro pasobajas o suavizado de imagen es empleando un filtro promediador (**filtro de media**). El filtro de media reemplaza el valor de cada pixel por el promedio de los valores de intensidad de los pixeles vecinos. Este filtro es razonablemente efectivo para eliminar ruido Gaussiano pero con el costo de perder detalles finos, es decir, atenuando las altas frecuencias. Es evidente también que este filtro no es efectivo para remover ruido de tipo 'salt & pepper'. En resumen, las desventajas del filtro de media son: poca robustez para eliminar ruido causado por valores atípicos (outliers), cuando actúa en bordes finos o bien definidos, los hará borrosos.

Filtro de mediana

En el filtro **de mediana**, el valor de cada pixel se reemplaza por la mediana del valor de intensidad de los pixeles vecinos. El filtro de mediana a diferencia del filtro de media no difumina los bordes de las regiones más grandes que el kernel del filtro, mientras que suaviza pequeñas variaciones de textura, preserva las altas frecuencias y elimina efectivamente el ruido impulsivo (como el tipo salt & pepper). El filtro de mediana agudiza las crestas en el histograma de la imagen permitiendo distinguir los modos y facilitando la elección de un umbral. El filtro de mediana es un tipo de filtro espacial no lineal.

Filtro Gaussiano

El filtro **Gaussiano** es un filtro suavizador de imagen; los valores de los coeficientes $[x, y]$ del kernel $g(x, y)$ están basados en una función Gaussiana

$$g(x, y) = e^{-\frac{(x^2 + y^2)}{2\sigma^2}}$$

Donde σ es el parámetro de dispersión (desviación estándar) que define el grado de suavizado. Un σ grande implica un filtro Gaussiano amplio y por tanto un nivel grande de suavizado. El kernel de un filtro Gaussiano con un valor σ relativamente grande es un ejemplo de filtro paso bajas en el que el contenido de alta frecuencia espacial de una imagen (por ejemplo bordes nítidos) se suprime.

1.2.3 Realce de bordes

El realce de bordes permite enfatizar la textura y la percepción de nitidez en la imagen. Por ejemplo, un sensor de una cámara digital y las lentes siempre producirán en cierto grado efectos no deseados de pérdida de nitidez y esto requerirá corrección.

Filtro Unsharp Masking.

El filtrado Unsharp Masking es una técnica para agudizar, realzar o volver más nítidos los bordes en una imagen. El término se origina de la técnica en fotografía analógica, donde la nitidez de una imagen se mejoraba combinándola con una copia suavizada. Este proceso es en principio el mismo para el ámbito digital. El primer paso consiste en restar a la imagen original una versión suavizada de la misma, el resultado es denominado 'la máscara'. A continuación la máscara se suma de nuevo con la imagen original logrando con esto que los bordes se agudicen. La definición matemática de este proceso es el siguiente:

1. Obtener la versión suavizada \tilde{I} de la imagen original

$$\tilde{I} = I * H$$

Donde H es el filtro suavizador, y se asume que esta normalizado.

2. Obtener la máscara M , restando de la imagen original la versión suavizada \tilde{I}

$$M = I - \tilde{I}$$

3. Para obtener la imagen agudizada \check{I} se suma a la imagen original, la máscara M , ponderada por un factor α que controla el grado de nitidez

$$\check{I} = I + \alpha M$$

1.2.4 Mejoramiento de nitidez basado en segunda derivada.

Un enfoque tradicional es amplificar los componentes de alta frecuencia de la imagen, los cuales son responsables de la percepción de nitidez de una imagen y que espacialmente se componen de cambios rápidos de intensidad (en el sentido de derivada), es decir cambios amplios de intensidad en pixeles vecinos, los cuales se perciben como bordes de objetos en la imagen.

Un método común para localizar cambios rápidos de intensidad son los filtros basados en la segunda derivada de la imagen. En la figura 3 se muestra la idea con una función $f(x)$ continua unidimensional (que representa la intensidad de la parte de la imagen bajo prueba), la segunda derivada $f''(x)$ de la función escalón muestra un pulso positivo en el extremo inferior (donde hay niveles bajos de intensidad) y un pulso negativo en el extremo superior (donde hay niveles de intensidad altos). El borde es agudizado o más

nítido, al restar una cierta fracción w de la segunda derivada $f''(x)$ de la función original $f(x)$, obteniendo la función $\check{f}(x)$:

$$\check{f} = f(x) - w \cdot f''(x)$$

Dependiendo del factor de peso w provocará que la intensidad de la función resultante sobreactúe en ambos extremos del borde, lo que provoca un exagerado aumento de la nitidez percibida.

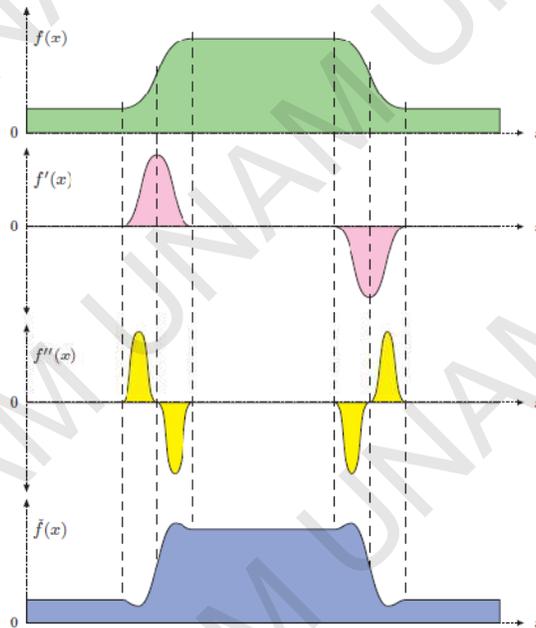


Figura 3. Proceso de mejoramiento de nitidez con la segunda derivada. De la figura superior a inferior: función original $f(x)$ (bordes); primera derivada $f'(x)$; segunda derivada $f''(x)$; función resultante (más nítida) $\check{f} = f(x) - w \cdot f''(x)$.

Filtro Laplaciano

El aumento de nitidez en una función de dos dimensiones (la imagen) se puede lograr con las segundas derivadas en ambas direcciones, horizontal y vertical, lo cual se obtiene con el operador Laplaciano. El operador Laplaciano ∇^2 es un operador de una función de dos dimensiones $f(x, y)$ y se define como la suma de las segundas derivadas parciales sobre las dos direcciones x e y :

$$\nabla^2 f(x, y) = \frac{\partial^2 f}{\partial^2 x} + \frac{\partial^2 f}{\partial^2 y}$$

Y la forma discreta del operador Laplaciano es:

$$\nabla^2 f(x, y) = f(x + 1, y) + f(x - 1, y) - 4f(x, y) + f(x, y + 1) + f(x, y - 1)$$

El filtro Laplaciano por lo tanto detecta bordes en la imagen. El filtro responde solo a los cambios finos en la imagen, por ejemplo las regiones de la imagen donde el gradiente de la intensidad es significativo, por lo que también es muy sensible al ruido, por lo que antes de emplearse, se recomienda suavizar la imagen para reducir este efecto. El filtro Laplaciano puede ser visto como un caso especial de un filtro Unsharp Masking [5].

1.3 Modelo de degradación y restauración

Una imagen original $f(x, y)$ es afectada por un tipo de degradación (por ejemplo, debido a factores ambientales, distorsiones geométricas causados por lentes deformadas, o una cámara en movimiento, causan una imagen 'barrida' (blurred), borrosa o desenfocada), que puede ser modelado por una función $h(x, y)$, la imagen además puede ser contaminada con ruido aditivo $\eta(x, y)$. Bajo este esquema, la imagen degradada resultante $g(x, y)$ es

$$g(x, y) = H[f(x, y)] + \eta(x, y)$$

Dada $g(x, y)$ así como algún grado de información tanto del proceso de degradado H y el ruido aditivo η , el objetivo de los algoritmos de restauración es revertir el proceso de degradación, generando una imagen restaurada $\hat{f}(x, y)$, que debe ser interpretada como un estimado de la imagen original $f(x, y)$. En otras palabras, el objetivo de las técnicas de restauración es obtener una imagen que es lo más parecida posible a la imagen original.

El proceso de degradación/restauración se muestra en la figura 4

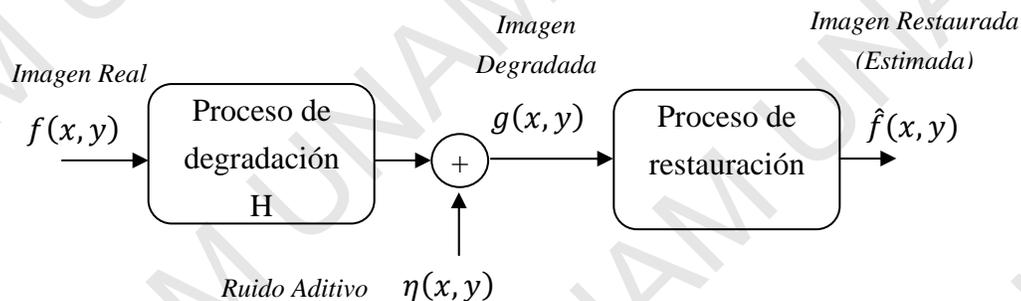


Figura 4. Proceso de degradación/restauración de imágenes digitales, planteado como un proceso lineal.

Si H es un proceso lineal y espacialmente invariante, se puede demostrar que la imagen degradada $g(x, y)$ se obtiene en el dominio espacial como:

$$g(x, y) = h(x, y) * f(x, y) + \eta(x, y)$$

Donde $*$ indica la operación convolución. Debido a que la degradación H es lineal e invariante espacialmente, y opera en forma de convolución con la imagen, el proceso de restauración a veces se le llama deconvolución [6]. Ya que la convolución entre dos

funciones en el dominio espacial corresponde a la multiplicación de las correspondientes transformadas de Fourier en el dominio frecuencial, la imagen degradada tiene la siguiente representación en el dominio frecuencial:

$$G(x, y) = H(x, y)F(x, y) + N(x, y)$$

Para obtener el estimado $\hat{f}(x, y)$ que varíe mínimamente con la entrada $f(x, y)$, se debe buscar un criterio óptimo (en el sentido de mínimos cuadrados) bien definido. Este criterio es el de minimizar el error medio cuadrático (conocido también como criterio de varianza mínima).

Filtro Wiener.

EL filtro Wiener [6] (llamado así por Norbert Wiener, quien propuso por primera vez el método en 1942) es uno de los primeros enfoques para restauración lineal de una imagen. El filtro Wiener busca un estimado que minimiza el error estadístico:

$$e^2 = E \{ (f - \hat{f})^2 \}$$

Donde $E\{\cdot\}$ es el operador valor esperado. La solución a éste problema en el dominio de la frecuencia es:

$$\hat{F}(u, v) = \left[\frac{1}{H(u, v)} \frac{|H(u, v)|^2}{|H(u, v)|^2 + S_\eta(u, v)/S_f(u, v)} \right] G(u, v)$$

En donde:

$G(u, v)$ = la imagen degradada

$H(u, v)$ = función de degradación

$H^*(u, v)$ = conjugado complejo de $H(u, v)$

$|H(u, v)|^2 = H^*(u, v)H(u, v)$

$S_\eta(u, v) = |N(u, v)|^2$ = potencia espectral del ruido

$S_f(u, v) = |F(u, v)|^2$ = potencia espectral de la imagen no degradada

La relación $S_\eta(u, v)/S_f(u, v)$ es llamada la relación Ruido/Señal, la cual es un escalar. Cuando se toma en cuenta ruido blanco aditivo, la potencia espectral del ruido $|N(u, v)|^2$ es constante. Sin embargo, la potencia espectral de potencia de la imagen no degradada casi nunca es conocida. Un enfoque frecuentemente usado cuando estas dos cantidades no se conocen o no pueden estimarse, es aproximar la expresión anterior como:

$$\hat{F}(u, v) = \left[\frac{1}{H(u, v)} \frac{|H(u, v)|^2}{|H(u, v)|^2 + K} \right] G(u, v)$$

Donde K (la relación Ruido/Señal), es una constante que se puede variar de forma experimental verificando el resultado de la restauración.

Por el sentido de su definición, se dice que el filtro Wiener es un filtro de restauración lineal óptimo.

1.4 Enfoques de segmentación.

1.4.1 Detección óptima, detector óptimo

¿Cómo se puede minimizar el número de píxeles erróneamente clasificados?

Se puede minimizar el número de píxeles erróneamente clasificados si se tiene algún conocimiento a priori sobre la distribución de los niveles de gris que componen tanto al objeto de interés y el fondo o aquello que no interesa [3]. De esta forma, al reducir el error de clasificar erróneamente los píxeles del objeto y de su entorno empleando un criterio de minimización, se obtiene un detector óptimo.

Los primeros enfoques de segmentación de imágenes digitales se basaron en los niveles de gris de los píxeles que forman la imagen. Estos niveles de gris son una traducción digital de un flujo energético recibido por el sensor para una determinada banda del espectro. Debido a esto, una segmentación basada exclusivamente en esta característica puede denominarse propiamente segmentación espectral. Aún cuando esta información es valiosa no siempre es capaz de discriminar entre clases, ya que en una escena puede haber varias clases con un comportamiento espectral similar. En este caso una opción ampliamente usada es la de incorporar a la segmentación el contexto espacial en que aparece cada píxel.

Tradicionalmente se han dividido los métodos de segmentación en supervisado y no supervisado de acuerdo a cómo son obtenidos los atributos de homogeneidad entre los píxeles. El método supervisado parte de un conocimiento previo de la imagen, de la cual se seleccionan muestras para cada una de las clases. Por otra parte el método no supervisado primero procede a una búsqueda automática de grupos de valores de píxel homogéneos dentro de la imagen.

De este modo el método supervisado pretende definir clases informacionales, mientras que el no supervisado tiende a identificar las clases espectrales presentes en la imagen. Ninguno de los dos métodos proporciona una solución inmediata a todos los problemas de segmentación. Por una parte el método supervisado podría forzar al algoritmo a discriminar categorías que no tengan un claro significado espectral, mientras que el método no supervisado puede proporcionar resultados de difícil interpretación, poco relacionados con las necesidades finales del usuario. [4]

Ahora bien, la clasificación de las técnicas de segmentación varía de una bibliografía a otra. Tomando como referencia [2], las técnicas frecuentemente empleadas se clasifican en dos amplias categorías: (1) Las técnicas de segmentación de regiones, en las que se buscan regiones que satisfacen un criterio de homogeneidad predefinido y, (2) técnicas de segmentación basadas en bordes, en las que se buscan bordes entre regiones con características diferentes. A continuación se describen algunas técnicas comunes empleadas en la segmentación de imágenes.

1.4.2 Umbralización

Un método común de segmentación por regiones es la umbralización, en esta técnica se selecciona un umbral T , se realiza una comparación de nivel de intensidad píxel a píxel con el umbral, y se divide en grupos de píxeles con valores de intensidad menores, y mayores o iguales al umbral.

La Umbralización Global se basa en la suposición de que la imagen tiene un histograma bimodal, es decir, los píxeles del objeto de interés y el fondo tienen niveles de gris fácilmente discernibles, por lo que el objeto puede ser extraído con la simple operación de comparar los valores de gris de los píxeles con el valor umbral T que separa ambos modos.

Otras técnicas para seleccionar el umbral global consisten en optimizar un parámetro, por ejemplo, minimizar la probabilidad de error de clasificar un píxel como perteneciente al objeto, cuando en realidad pertenece al fondo, o el caso contrario, clasificar un píxel como perteneciente al fondo cuando en realidad pertenece al objeto.

La umbralización global es computacionalmente simple y rápida, funciona en un nivel aceptable en imágenes con regiones de intensidad uniforme y un fondo contrastante, sin embargo tiene pobre desempeño en imágenes con poco contraste entre el objeto y el fondo o si el fondo tiene una intensidad variable en toda la imagen.

Este enfoque no toma en cuenta la información de la vecindad del píxel bajo prueba, lo que puede llevar a problemas de sobresegmentación, resultando en imágenes segmentadas con una alta incidencia de píxeles aislados, causado posiblemente, por la presencia de ruido en la imagen, por lo que se suele suavizar antes la imagen para reducir los efectos de píxeles aislados, pero con el problema subyacente de que los filtros suavizadores difuminan los bordes, provocando en la segmentación error en la delimitación del objeto.

Hasta aquí se ha considerado a la Umbralización solo con un umbral, el cual tiene un funcionamiento aceptable siempre y cuando la distribución del histograma sea bimodal, por lo que el umbral debe ser colocado entre ambos modos.

Sin embargo, hay una gran cantidad de imágenes que no tienen un comportamiento análogo, por lo que se tiene que recurrir a una umbralización tipo multinivel, donde la cantidad de umbrales dependerá del comportamiento del histograma. Este último caso acarrea un problema considerable para el usuario, ya que la selección de varios umbrales de forma manual se puede convertir en una tarea ardua y compleja.

1.4.3 Crecimiento de regiones

Mientras la umbralización actúa individualmente en cada pixel, el crecimiento de regiones lo hace en grupos de pixeles con intensidades similares. El crecimiento de regiones comienza con un pixel o un grupo de pixeles llamados semillas que pertenecen a la estructura de interés. Las semillas pueden ser elegidas por un usuario o con un método automático. En el siguiente paso se examinan los pixeles vecinos individualmente y se añaden a la región en crecimiento solo si son suficientemente similares, basándose en un criterio de similitud. El procedimiento continúa hasta que no hay más pixeles por añadir.

La ventaja de crecimiento por regiones es que es capaz de segmentar correctamente regiones que tienen las mismas propiedades y están separadas espacialmente, así como generar regiones conectadas.

El resultado depende fuertemente de la selección del criterio de similitud. Otro problema es que diferentes puntos de inicio podrían no crecer y terminar en regiones idénticas.

1.4.4 Agrupamiento por K-medias.

El agrupamiento por K-medias [7] es un método no supervisado de clasificación. Busca el agrupamiento natural en el conjunto de datos (pixeles) empleando una medida de similitud o de diferencia. Dos estrategias de implementación de K-medias son: por error cuadrático y por mezcla de modelos. La suma del cuadrado de la distancia euclidiana entre los elementos de un grupo y el centroide del grupo es llamada variación intra-grupo (intra-cluster). Se usa como criterio la minimización de la suma de las variaciones:

$$Q = \sum_{j=1}^K \sum_{i=1}^n \|v_i^j - \mu_j\|^2$$

Donde v_i^j es el elemento i de la clase j y μ_j el centroide de la clase j definido como la media de v_i perteneciente a la clase K_j .

El algoritmo para segmentación de una imagen sigue los siguientes pasos:

1. Proporcionar el número de clases K y los centroides μ_j
2. Asignar cada pixel al grupo cuyo centroide es más cercano
3. Después de que todos los pixeles fueron asignados recalcular los centroides con los nuevos grupos.
4. Repetir los pasos 2 y 3 hasta que no haya una diferencia significativa en los centroides.

Una sección del código en Matlab para implementar segmentación con k-medias se obtuvo de la referencia [7].

1.4.5 Clasificador Bayesiano.

Un enfoque de clasificación de patrones empleada para segmentación es el probabilístico [6]. La clasificación se basa en teoría de probabilidad y con el principio de escoger la opción más probable o con el menor riesgo de clasificar un patrón incorrectamente.

La probabilidad de que un vector de atributos \mathbf{x} pertenezca a la clase ω_k es $P(\omega_k|\mathbf{x})$ y se hace referencia a esta probabilidad como la probabilidad a posteriori, una vez que se conoce un conjunto de datos de referencia correspondiente a cada clase, llamado conjunto de entrenamiento denotado por $p(\mathbf{x}|\omega_k)$ y corresponde a la función de densidad de probabilidad en el espacio de atributos, de la clase ω_k . La relación entre estas dos probabilidades se establece con la regla de Bayes:

$$P(\omega_k|\mathbf{x}) = \frac{p(\mathbf{x}|\omega_k) P(\omega_k)}{p(\mathbf{x})}$$

De acuerdo a esto, un patrón \mathbf{x} se asigna a la clase ω_i si se cumple la función de decisión:

$$P(\omega_i|\mathbf{x})P(\omega_i) > P(\omega_j|\mathbf{x})P(\omega_j)$$

Las distribuciones Gaussianas usualmente son buenas aproximaciones para modelar la forma de las clases en un espacio de atributos adecuado, en el sentido de que los vectores de atributos de cada clase generan clases mutuamente excluyentes. En algunos casos, los vectores que provienen de diferente clase muestran un grado de traslape en el espacio de atributos. Por tal motivo, no siempre se puede garantizar que la clasificación estará libre de errores empleando distribuciones Gaussianas.

De esta forma las distribuciones $P(\omega_k|\mathbf{x})$ se estiman con la función de densidad Gaussiana. Para una variable (vector) \mathbf{x} n-dimensional de atributos, digamos para la j-ésima clase patrón, la distribución es:

$$p(\mathbf{x}|\omega_j) = \frac{1}{(2\pi)^{n/2} |C_j|^{1/2}} e^{-\frac{1}{2}(\mathbf{x}-\mu_j)^T C_j^{-1}(\mathbf{x}-\mu_j)}$$

Donde μ_j y C_j son correspondientemente la media de dimensión n y la matriz de covarianza de dimensión $n \times n$. El término $|C_j|$ corresponde al determinante de C_j .

Las probabilidades a priori $P(\omega_k)$, que son las probabilidades de ocurrencia de los datos de la k-ésima clase, pueden ser estimadas a partir del conjunto de datos disponible como la fracción de datos de la k-ésima clase correctamente anotados, entre el número de datos totales, en este caso, el número de píxeles de la k-ésima clase entre el número de

píxeles totales de la imagen. Cuando no se pueden estimar las probabilidades a priori, éstas se asumen iguales.

La estructura del clasificador de Bayes empleando funciones de decisión para k clases se muestra en la figura 5.

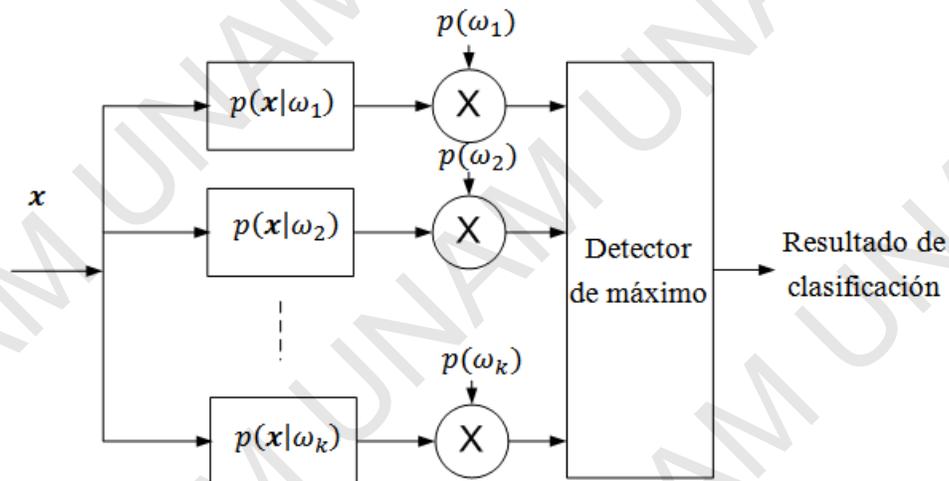


Figura 5. Clasificador de Bayes empleando funciones de decisión (clasificación MAP).

2. HIPÓTESIS.

Dada una imagen degradada por procesos de ruido aditivo y una degradación (pérdida de nitidez por desenfoque) lineal, es posible hallar un filtro lineal óptimo, que mejore un proceso de segmentación óptimo. Éste filtro, es el filtro Wiener, siempre y cuando se tenga algún grado de información tanto del ruido como de la distorsión.

Los filtros suavizadores (filtros pasobajas) atenúan el ruido y los bordes, ocasionando que en el proceso de segmentación posterior clasifique erróneamente los pixeles del fondo como del objeto o viceversa en regiones con un gradiente de intensidad amplio.

Por su parte, los filtros del tipo Unsharp Masking por sí solos, pueden incrementar el ruido, debido a pixeles aislados; empleando antes un suavizado de la imagen y un filtro Unsharp Masking posterior reduciría el realce del ruido pero atenuaría en cierto grado los bordes finos de la imagen, reduciendo nitidez, causando de nuevo errores en la segmentación. Para el uso de filtros Unsharp Masking, se necesita una versión borrosa de la imagen que se quiere mejorar. Cuando la imagen que se dispone es ya borrosa, una versión más borrosa para usarla con el filtro, no mejorará su nitidez.

Teniendo cierto conocimiento del modelo del ruido aditivo y del proceso lineal de reducción de nitidez que afectan a la imagen, se puede obtener una imagen (estimada) no degradada por medio del filtro Wiener.

Debido a las propiedades lineales del filtro Wiener y su obtención bajo el criterio óptimo de minimización del error cuadrático medio, entre la imagen estimada con la original, se puede mejorar un proceso de segmentación que optimice algún criterio.

3. OBJETIVO.

El objetivo de este trabajo es el siguiente: dada una imagen con cierto nivel de degradación, comprobar experimentalmente que, el proceso de segmentación de la imagen, tiene un mejor desempeño mejorando la calidad de la imagen con un filtro Wiener, a diferencia del uso de filtros paso bajas o de realce de bordes (Unsharp Masking).

4. METODOLOGÍA PROPUESTA

Es necesario generar algunas imágenes con algún nivel de degradación, por ejemplo ruido aditivo y reducción de nitidez, de tal forma que se pueda hacer una comparación entre la efectividad de los enfoques de restauración de la imagen, empleados como etapa de preprocesamiento para la segmentación posterior, por lo tanto, el procedimiento será el siguiente.

1. Segmentar la imagen original.
2. Agregar degradación:
 - a) Ruido Gaussiano,
 - b) Pérdida de nitidez (blurring),
 - c) Combinación de los dos procesos.

Para el caso (a):

- Emplear un filtro paso bajas *para reducir ruido* y segmentar la imagen.
- Emplear un filtro Wiener *para reducir ruido* y segmentar la imagen.

Para el caso (b):

- Emplear un filtro Unsharp Masking *para mejorar nitidez* y segmentar la imagen.
- Emplear un filtro Wiener *para mejorar nitidez* y segmentar la imagen.

Para el caso c):

- Emplear un filtro paso bajas *para reducir ruido* y un filtro Unsharp Masking *para mejorar nitidez*. Segmentar la imagen.
- Emplear un filtro Wiener *para reducir ruido y mejorar nitidez*. Segmentar la imagen.

La imagen original tiene un histograma que a primera vista parece bimodal, como se muestra en la figura 6, por lo que un método de segmentación basado en histograma como la umbralización no sería adecuado.

El método de segmentación empleado es el algoritmo de K medias, ya que es un método óptimo que sirve como exploración para encontrar un número K de clusters adecuado para lograr una separación aceptable del Mesencéfalo de su entorno. Con el propósito de comparar el desempeño del método de segmentación seleccionado, se realizará también una segmentación con un clasificador Bayesiano, para el cual se seleccionan cuatro regiones importantes: Mesencéfalo, Fondo, Lóbulos del cerebro y Hueso.

La región que interesa segmentar (el mesencéfalo, en forma de mariposa, en la zona central de la imagen) contiene pixeles cuya intensidad es similar a otras estructuras que no pertenecen a esta región. Por lo que el resultado de la segmentación puede incluir regiones desconectadas asignadas a la misma clase del Mesencéfalo y puede ser necesario un procesamiento posterior, el cual se describe más adelante, para extraer solamente el Mesencéfalo. En los resultados, la sección del borde del objeto de interés se rodeará con una línea de color blanco (intensidad 255).

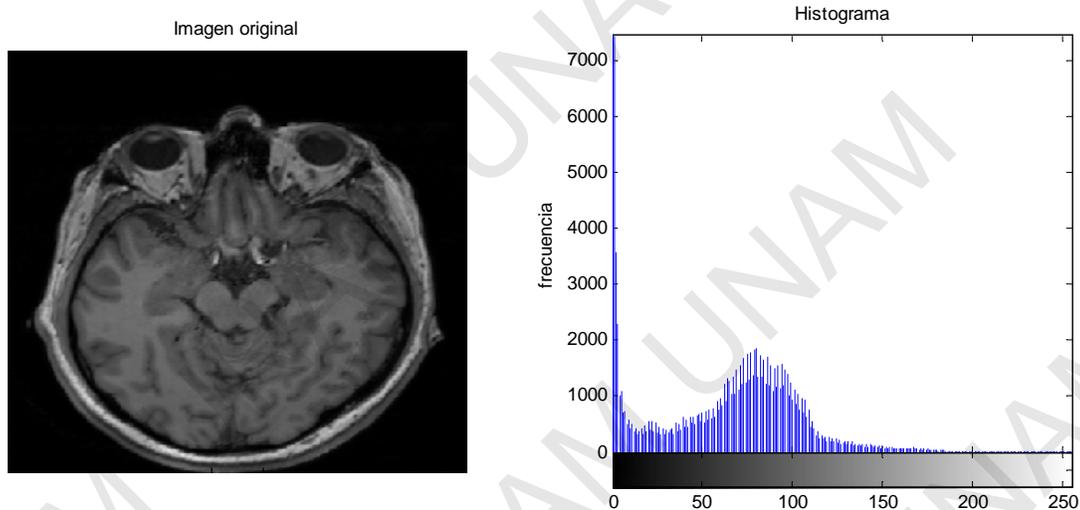


Figura 6. Imagen original y su histograma.

5. DESARROLLO.

5.1 Proceso de Degradación Restauración

El filtro paso bajas empleado en los experimentos de este trabajo es un filtro Gaussiano. En el Listado 1 se muestra la implementación en MatLab del filtro Gaussiano aplicado a una imagen a la cual se le ha agregado ruido; en la figura 7 se muestra el resultado.

```

imD = im2double(im); % imagen original
% aplicando ruido Gaussiano a 'im'
noise_mean = 0; noise_var = 0.005;
im_noisy = imnoise(imD, 'gaussian', noise_mean, noise_var);
est_nsr = noise_var / var(imD(:));
figure(8), imshow(im_noisy), title('Imagen con ruido')

% restauracion de im_noisy con filtro paso bajas
sigma = 2;
l = ceil(sigma*3)*2 + 1;
pb = fspecial('gaussian', [l l], sigma); % genera kernel Gaussiano
im_pbf = imfilter(im_noisy, pb); % aplica filtro Gaussiano
figure(10), imshow(im_pbf), title('Restauración contra Ruido, \newline
filtro PB');

```

Listado 1. Implementación del filtro Gaussiano (paso bajas) a la imagen con ruido aditivo.

En el listado se muestra la aplicación del filtrado Unsharp Masking a la imagen original y en la figura 8 se muestra el resultado.

```
% filtro unsharp masking
UM = fspecial('unsharp',0); %valor alfa = 0
imum = imfilter(imD,UM,'circular','conv'); % imD es la imagen original
figure(17); imshow(imum),title('Filtro UM');
```

Listado 2. Implementación del Filtro Unsharp Masking a la imagen original.

Como se aprecia, el filtro Unsharp Masking tiene un buen desempeño con imágenes que tienen una nitidez aceptable o con un efecto de desenfoque apenas notorio como la anterior. El propósito fundamental del filtro es resaltar bordes finos.

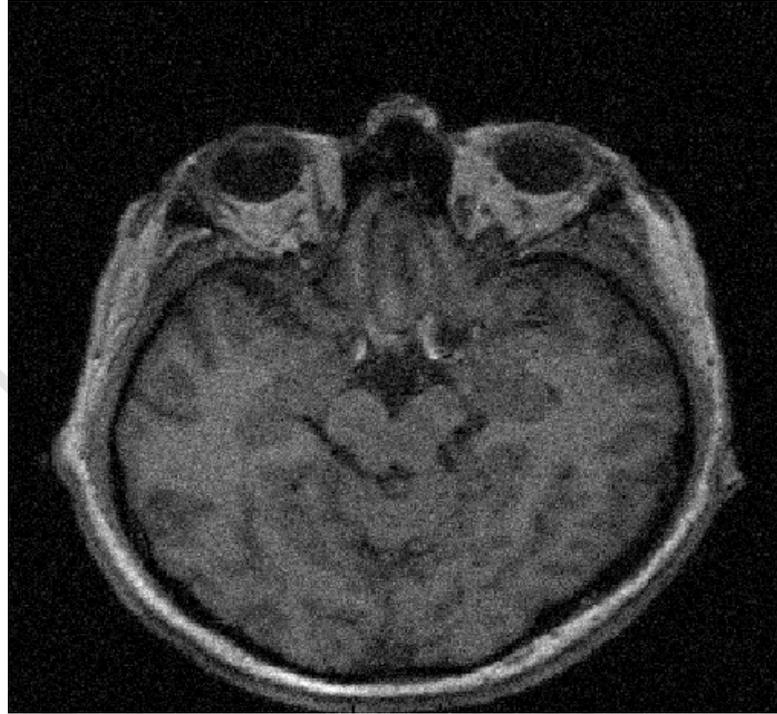
Para una imagen real con degradación de desenfoque real y acentuada, ésta no se puede corregir con un filtro Unsharp Masking, ya que el principio del filtro es emplear una 'máscara borrosa' de la imagen disponible; esto se puede comprobar con el ejemplo mostrado en el Listado 2 y la figura 9, donde se aplica de manera sintética el efecto de desenfoque y se trata de mejorar con el filtro Unsharp Masking.

```
% Aplicando blurring a 'im'
PSF = fspecial('disk',5);
im_blur = imfilter(im2double(imD),PSF,'circular','conv');
figure(11); imshow(im_blur); title('Imagen desenfocada ');

% restauracion de im_blur con filtro Unsharp masking
UM = fspecial('unsharp');
im_um = imfilter(im_blur,UM,'circular','conv');
figure(13); imshow(im_um),title('Restauración contra desenfoque,
\newlinefiltro UM');
```

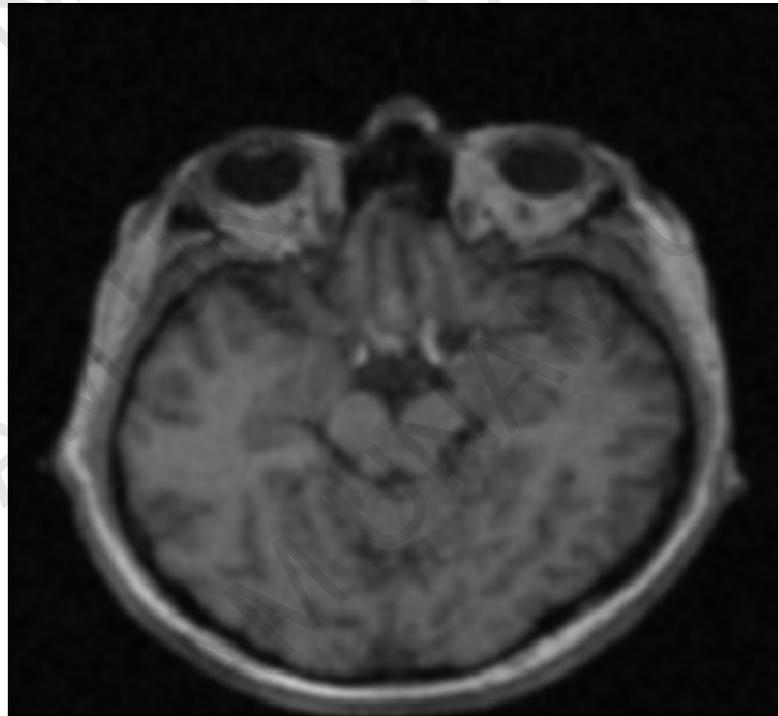
Listado 3. Imagen sintética desenfocada y mejoramiento con filtro Unsharp Masking.

Imagen con ruido



a)

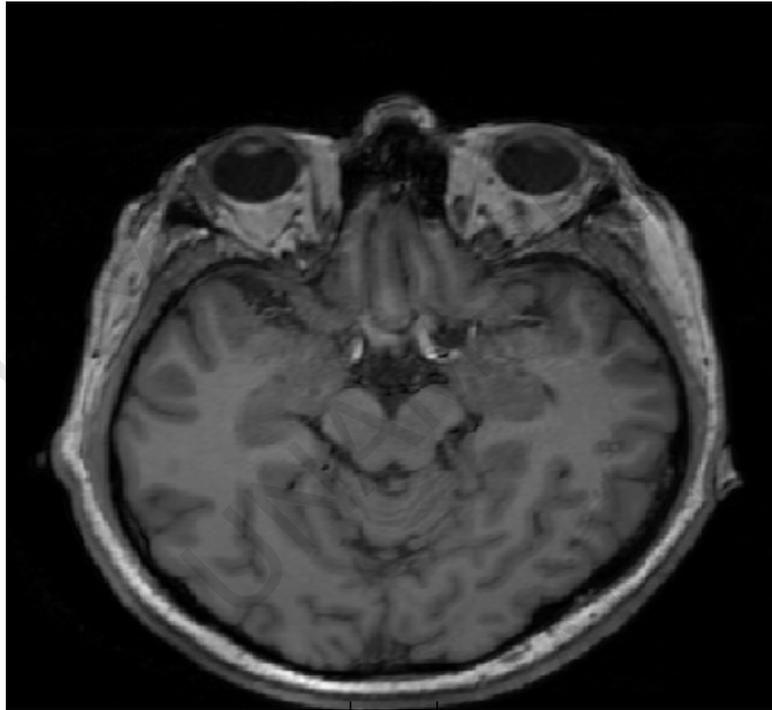
Filtrado de Ruido,
filtro Gaussiano



b)

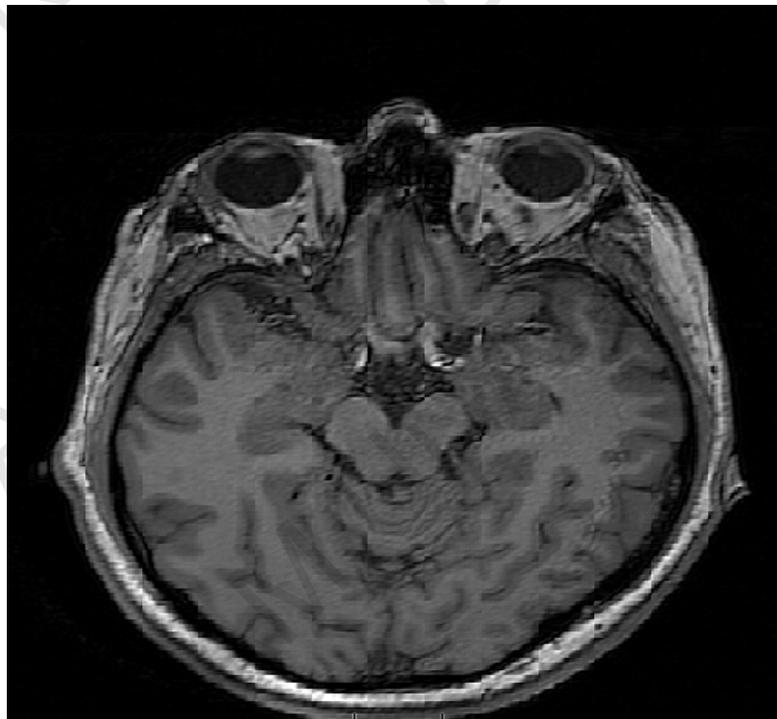
Figura 7. Reducción de ruido con filtro paso bajas (Gaussiano).
a) Imagen con ruido aditivo, b) Resultado de aplicar el filtro.

Imagen Original



a)

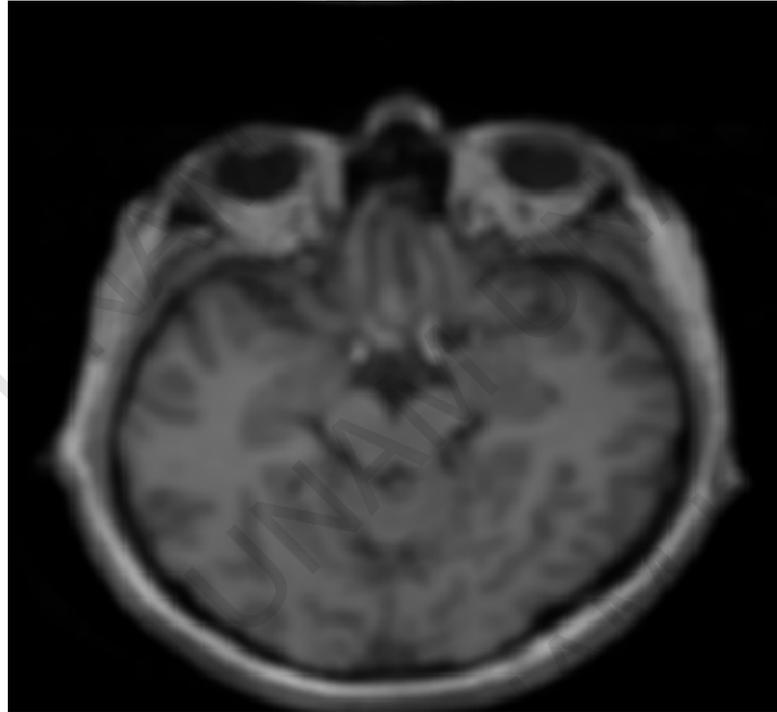
Resultado, Filtro UM



b)

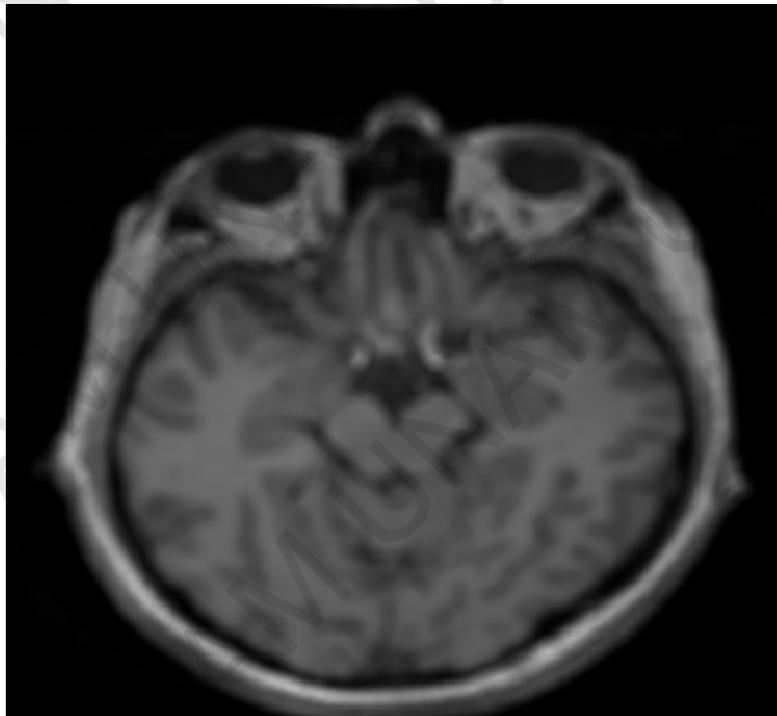
Figura 8. Mejoramiento de nitidez con filtro Unsharp Masking.
a) Imagen Original, b) Imagen filtrada.

Imagen desenfocada



a)

Restauración contra desenfoque,
filtro UM



b)

Figura 9. Para una imagen con desenfoque real, un filtro Unsharp Masking no mejora la imagen. A) Imagen 'desenfocada'; b) Resultado del filtro Unsharp Masking.

El Listado 4 muestra el proceso para realizar la degradación de la imagen por desenfoque, ruido aditivo y ambos, así como la restauración empleando el filtro Wiener. En las figuras 10 a 12 se muestra el resultado de los procesos de degradación y restauración.

```

clear all
im = imread('mr.png'); im = rgb2gray(im);
figure(1), imshow(im,[]); title('Imagen Original');
imD = im2double(im);

%aplicando ruido Gaussiano a la imagen
noise_mean = 0; noise_var = 0.005;
im_noisy = imnoise(imD, 'gaussian',noise_mean, noise_var);
est_nsr = noise_var / var(imD(:));
figure(8), imshow(im_noisy), title('Imagen con ruido')

% restauracion de im_noisy con filtro wiener
[wnr1, noise] = wiener2(im_noisy,[5 5],est_nsr);
figure(9); imshow(wnr1); title('Restauración contra Ruido, \newline
filtro Wiener');

% Aplicando blurring a la imagen
PSF = fspecial('disk',5); % H: operador de distorsión real
im_blur = imfilter(im2double(imD),PSF,'circular','conv');
figure(11); imshow(im_blur); title('Imagen desenfocada');

% restauracion de im_blur con filtro wiener y PSF real
PSF = fspecial('disk',5);
wnr2 = im2uint8(deconvwnr(im2double(im_blur),PSF,0));
figure(12);imshow(wnr2,[]); title('Restauración contra desenfoque,
\newline filtro Wiener');

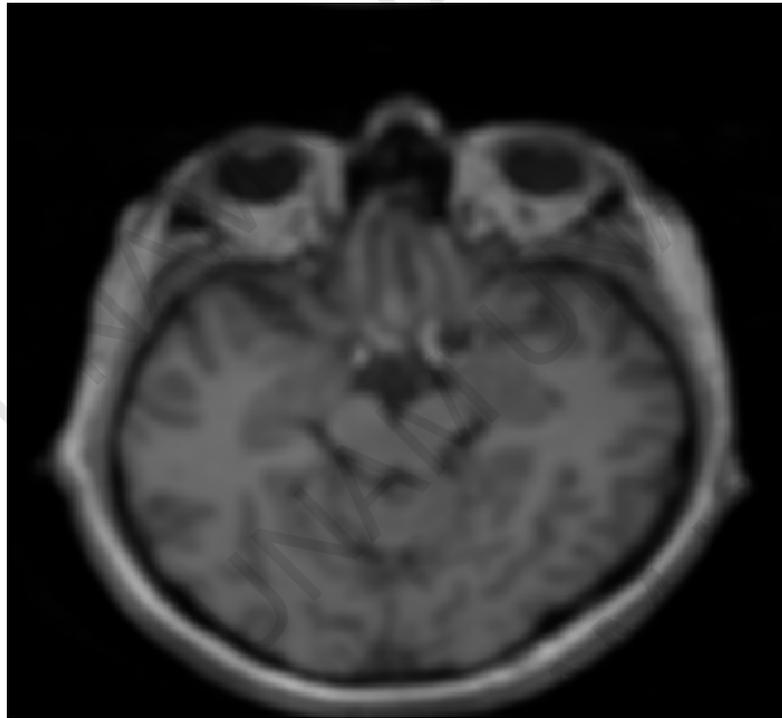
%Aplicando blurring y ruido Gaussiano a la imagen
im_bn = imfilter(im_noisy, PSF,'circular','conv');
figure(14); imshow(im_bn); title('Imagen borrosa y con ruido');

% restauracion de im_bn con filtro wiener
wnr3 = deconvwnr(im_bn, PSF, 0.0014); % relación NSR experimental
figure(15);imshow(wnr3); title('Restauracion contra ruido y desenfoque,
filtro Wiener');

```

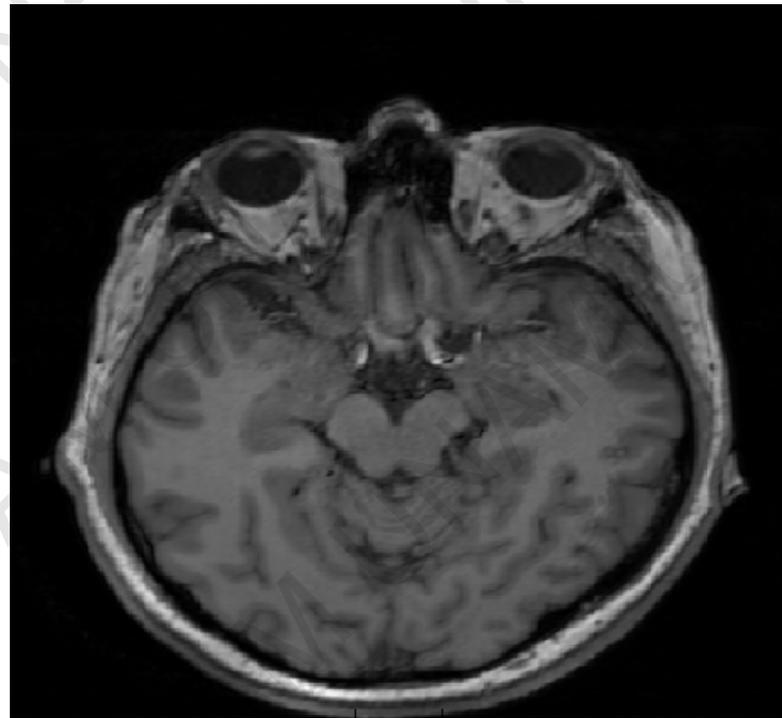
Listado 4. Degradación (desenfoque, ruido aditivo, ambos) y restauración de la imagen empleando filtros Wiener.

Imagen desenfocada



a)

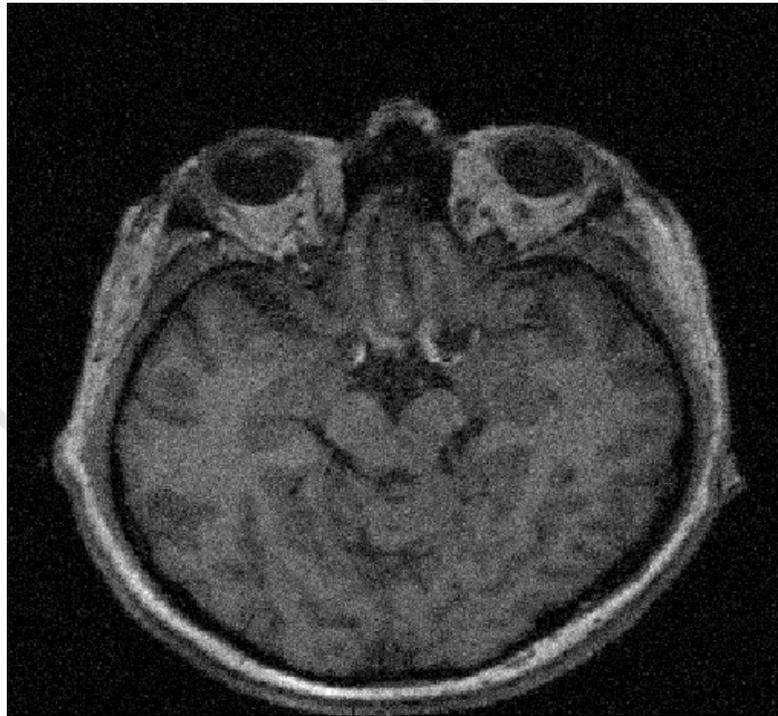
Restauración contra desenfoque,
filtro Wiener



b)

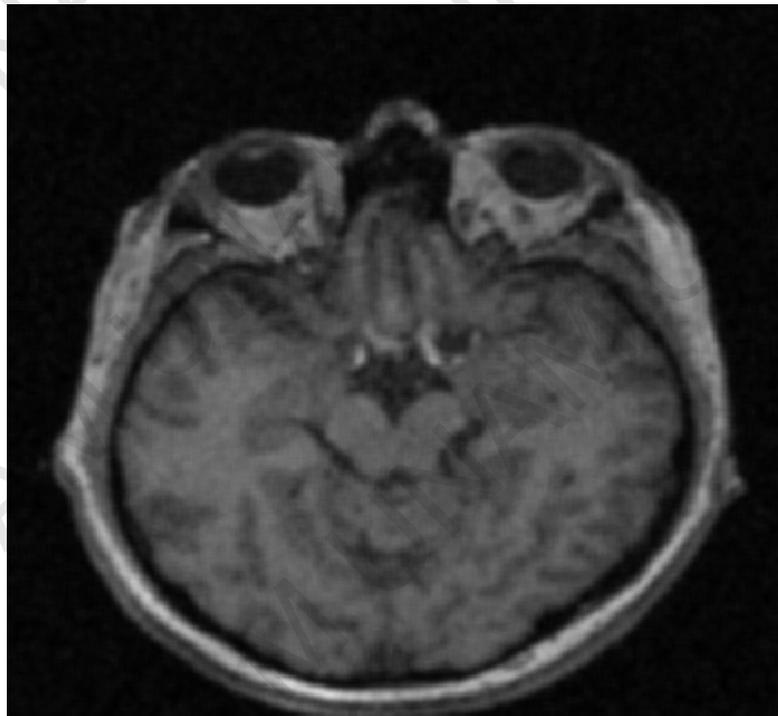
Figura 10. a) Imagen degradada por desenfoque (blurring),
b) Imagen restaurada con filtro Wiener.

Imagen con ruido



a)

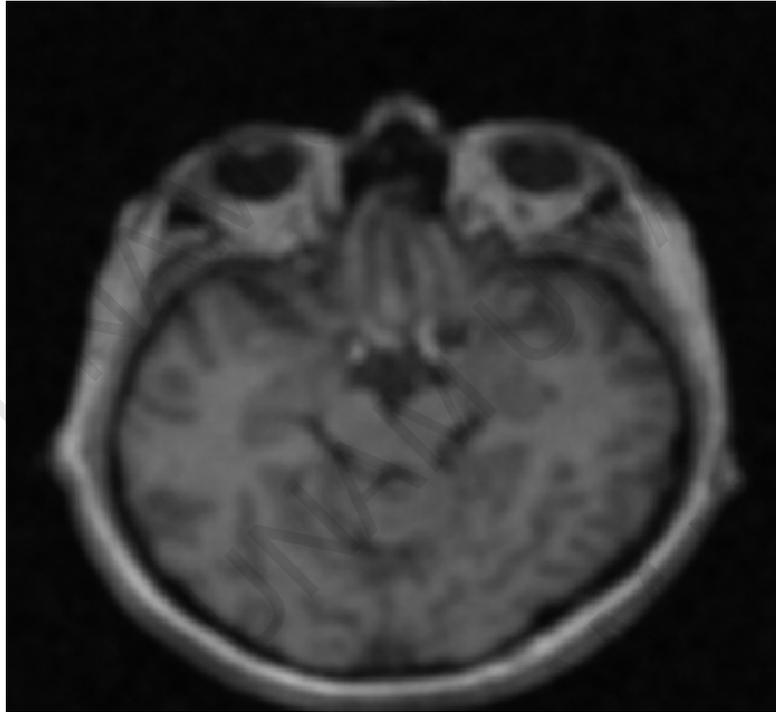
Restauración contra Ruido,
filtro Wiener



b)

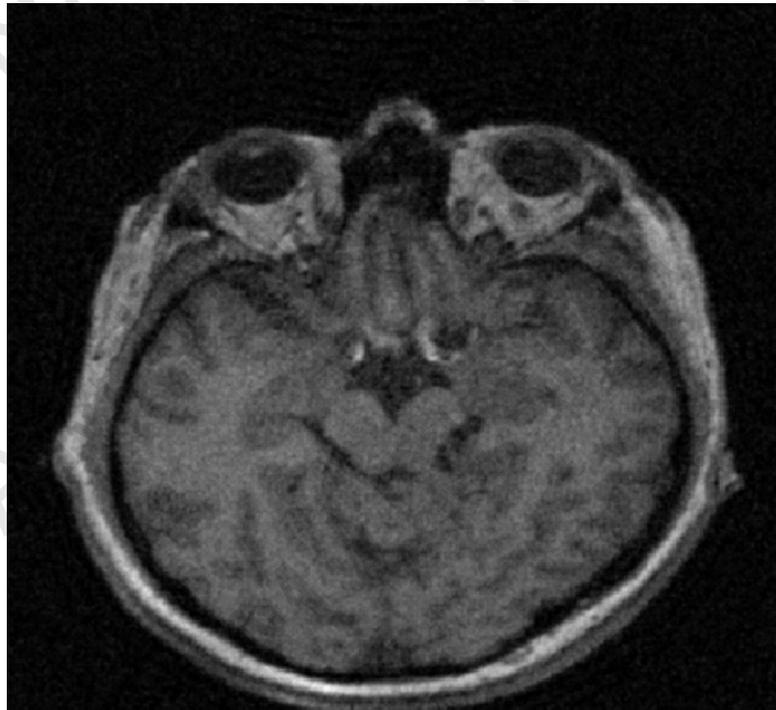
Figura 11. a) Imagen degradada por ruido aditivo,
b) Imagen restaurada con filtro Wiener.

Imagen borrosa y con ruido



a)

Restauración contra ruido y desenfoque, filtro Wiener



b)

Figura 12. a) Imagen degradada por ruido aditivo y desenfoque, b) Imagen restaurada con filtro Wiener, donde la relación NSR se obtuvo experimentalmente.

5.2 Segmentación con el algoritmo de k-medias.

La segmentación realizada con el algoritmo K-medias se realizó con un número de clusters $K = 3, 4, 5$ y 6 , como dato de entrada. La figura 13 muestra el resultado de estas realizaciones. Con la selección de 5 clusters se nota una separación del Mesencéfalo de su entorno, por lo que se selecciona un número de cluster igual a 5 para las experimentaciones posteriores.

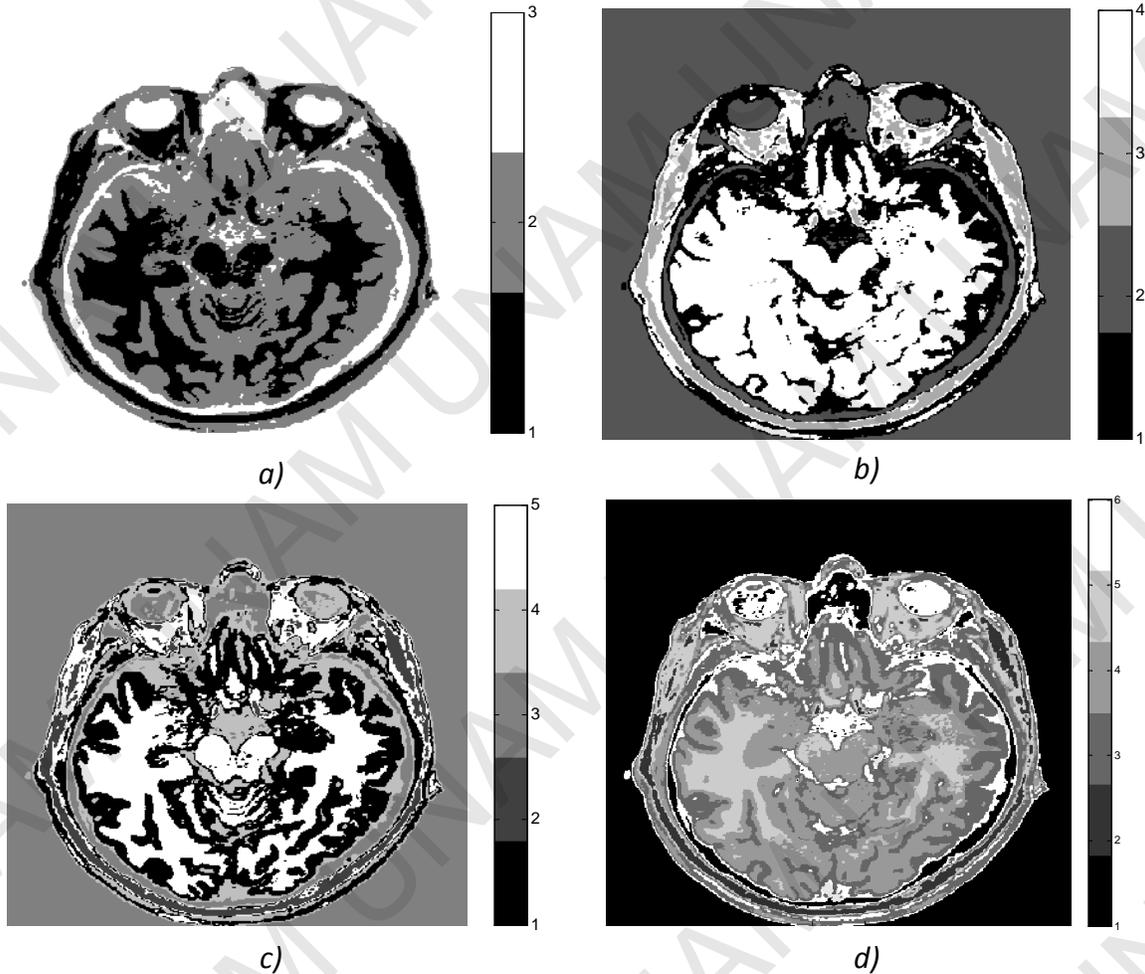


Figura 13. Resultado de segmentación con K-medias para un número de cluster: a) $K=3$, b) $K=4$, c) $K=5$, d) $K=6$. Se selecciona $K=5$ para los experimentos posteriores.

5.3 Post procesamiento: Filtros morfológicos. Indexación.

Adicionalmente, para extraer sólo el Mesencéfalo y descartar otras secciones pertenecientes al mismo cluster, se realiza un filtrado posterior con filtros morfológicos de Apertura-Cierre y además Indexación [6]. El proceso es el siguiente:

- Extracción del cluster del Mesencéfalo seleccionando un píxel perteneciente al mismo.
- Eliminación de objetos menores a una cantidad determinada de píxeles (Opening).
- Indexación de los objetos restantes. El píxel seleccionado en el paso (a) se emplea de nuevo para extraer el índice del área que lo contiene (Mesencéfalo).

- d) Elimina de la máscara los demás objetos, asignando nivel de gris '0'; en la región restante, se llenan los espacios 'vacíos' (Closing).
- e) Extracción del contorno del área restante, establecer en la imagen de entrada un valor máximo en la intensidad para marcar el contorno resultado de la segmentación.

En las figuras 14 y 15 se muestran las etapas de post procesamiento indicadas.



Figura 14. Proceso para extraer de forma Interactiva sólo el Mesencéfalo.
a) Selección de la máscara, b) Apertura (Opening), c) Indexación, d) Cierre (Closing).

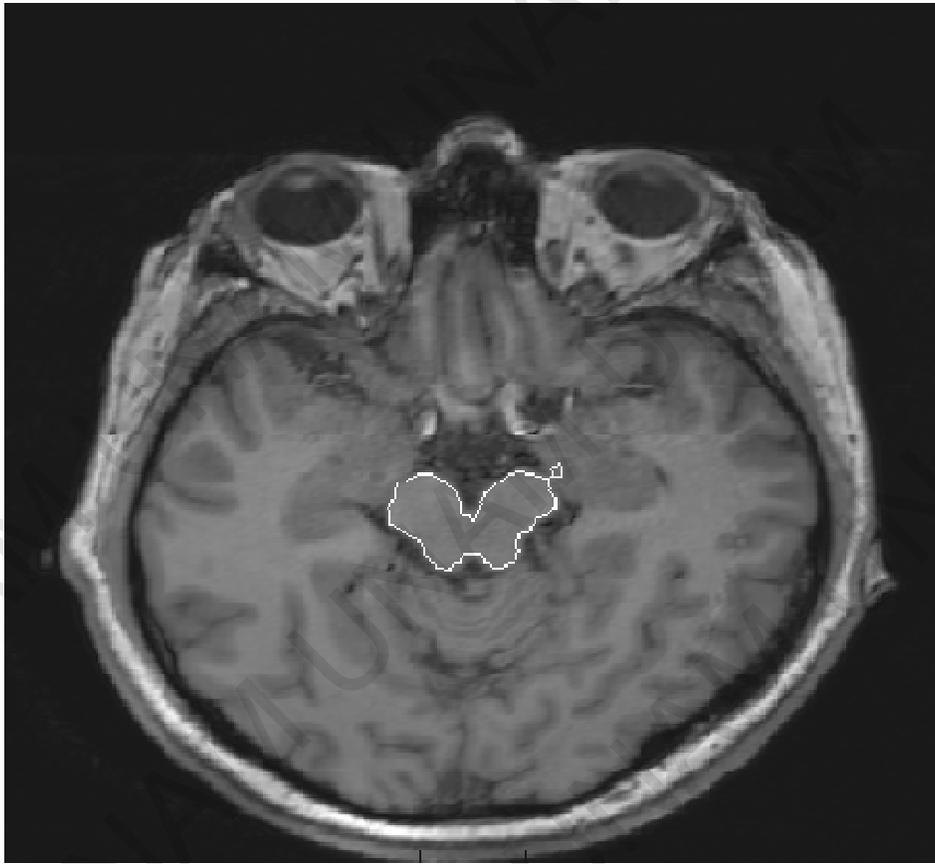


Figura 15. Resultado Final de la segmentación (e). Imagen original segmentada.

5.4 Segmentación con clasificador Bayesiano.

Adicionalmente a la segmentación por K-medias, se realizan experimentos empleando un clasificador Bayesiano, para lo cual se toman muestras de regiones representativas que se pueden separar. En este caso la sección de las muestras conlleva información espacial ya que además del nivel de intensidad de gris de los píxeles, se agrega como atributo su ubicación espacial. La imagen de entrenamiento y de prueba es la misma; empleando un mayor número de imágenes se reduciría estadísticamente el error de clasificación en una imagen de prueba.

Las regiones seleccionadas en la imagen son las siguientes:

- 1) Mesencéfalo
- 2) Fondo de la imagen
- 3) Lóbulos
- 4) Hueso (cráneo) en dos partes: Izquierdo y Derecho en la imagen.

En la figura 16, se muestran: (a) las regiones seleccionadas en el entrenamiento, (b) el resultado de la segmentación en las cuatro regiones y, (c) etapa de post segmentación extrayendo de forma similar a la ya descrita, la región del Mesencéfalo, rellenando huecos y extrayendo el contorno.



Figura 16. Segmentación empleando un clasificador Bayesiano. a) Selección de las regiones en la imagen de entrenamiento, b) Resultado de segmentación. c) Post procesamiento y obtención del contorno.

En la segmentación por clasificador Bayesiano se emplea una imagen sin ruido ni distorsión para anotar 'correctamente' los datos y usarlos como entrenamiento. Las imágenes de prueba serán las imágenes degradadas y recuperadas por los filtros implementados.

Se realiza a continuación, la segmentación con las imágenes que son degradadas por ruido, desenfoque y ambos procesos de degradación, como se indica en la metodología propuesta.

6. RESULTADOS

En la tabla I se muestra un resumen de las imágenes empleadas como entrada para los dos métodos de segmentación.

Tabla I. Experimentos realizados y resultados.

Imagen de entrada	Segmentación por K medias	Segmentación Clasificador Bayesiano.
Imagen con ruido aditivo	Figura 17	Figura 26
Imagen con ruido aditivo Filtrada con Filtro Wiener	Figura 18	Figura 27
Imagen con ruido aditivo Filtrada con Filtro Unsharp Masking	Figura 19	Figura 28
Imagen con degradación por desenfoque	Figura 20	Figura 29
Imagen con degradación por desenfoque Filtrada con Filtro Wiener	Figura 21	Figura 30
Imagen con degradación por desenfoque Filtrada con Filtro Unsharp Masking	Figura 22	Figura 31
Imagen con ruido aditivo y desenfoque	Figura 23	Figura 32
Imagen con ruido aditivo y desenfoque filtrada con Filtro Wiener	Figura 24	Figura 33
Imagen con ruido aditivo y desenfoque filtrada con Filtro Unsharp Masking	Figura 25	Figura 34

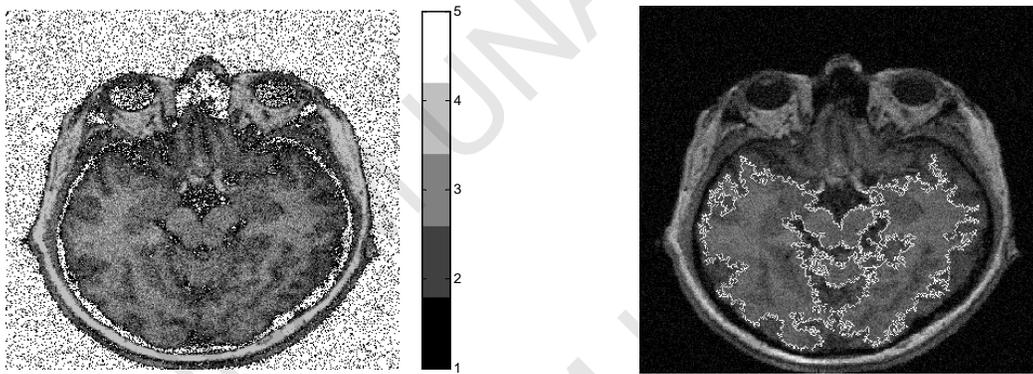


Figura 17. Segmentación (*k*-medias, $k=5$), Imagen con ruido.

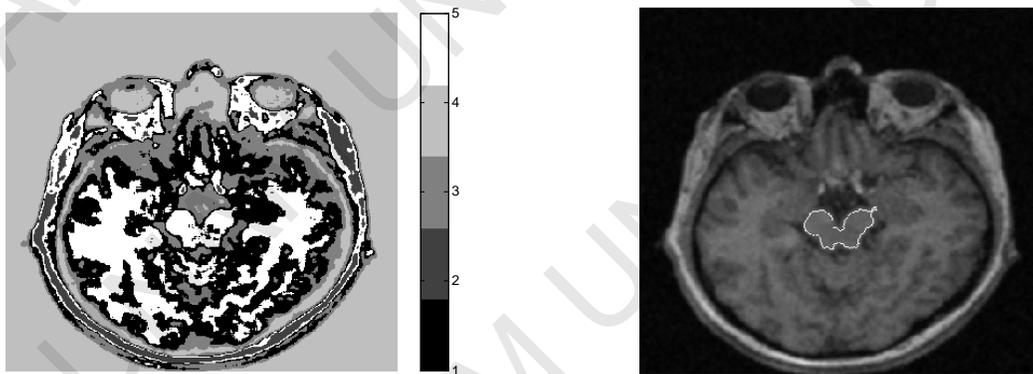


Figura 18. Segmentación (*k*-medias, $k=5$), Imagen con ruido, filtrada usando filtro Wiener.

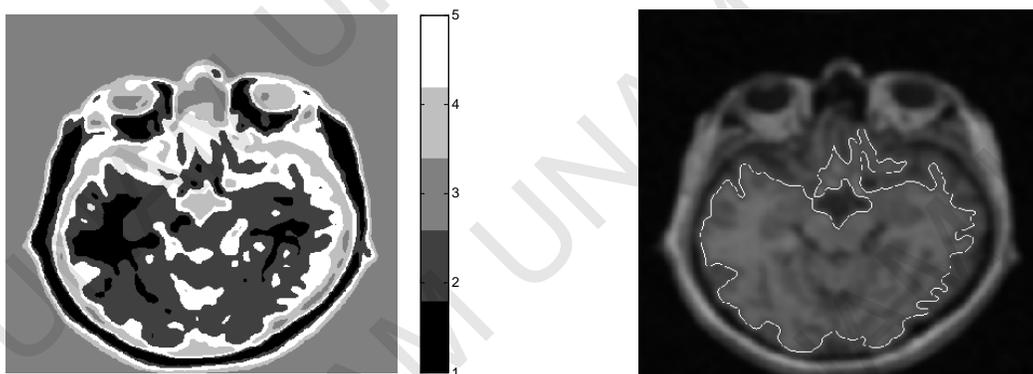


Figura 19. Segmentación (*k*-medias, $k=5$), Imagen con ruido, filtrada usando filtro Gaussiano.

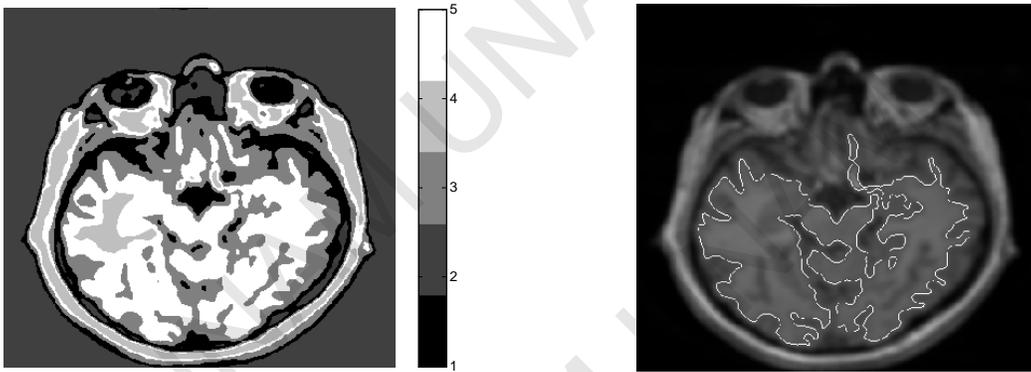


Figura 20. Segmentación (k -medias, $k=5$), Imagen con desenfoque.

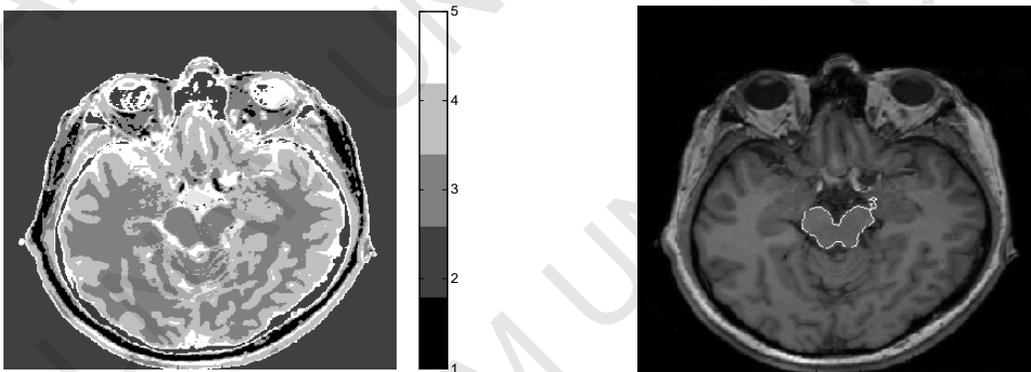


Figura 21. Segmentación (k -medias, $k=5$), Imagen con desenfoque, filtrada con filtro Wiener.

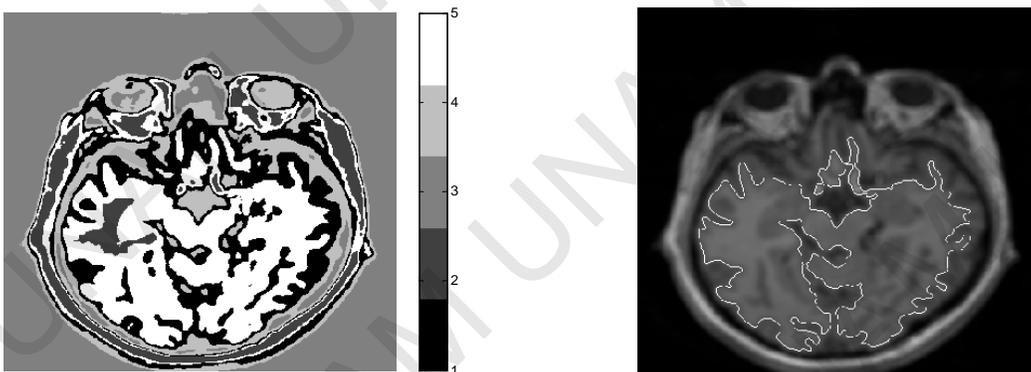


Figura 22. Segmentación (k -medias, $k=5$), Imagen con desenfoque, filtrada con filtro UM.

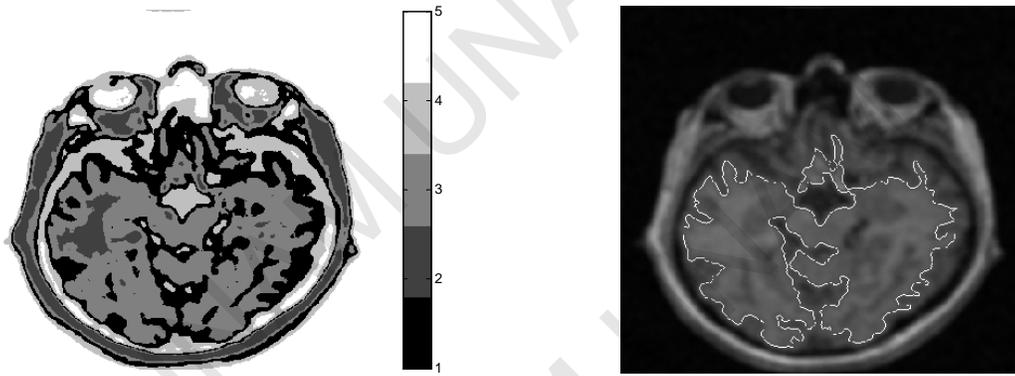


Figura 23. Segmentación (*k*-medias, $k=5$), Imagen con desenfoque y ruido.

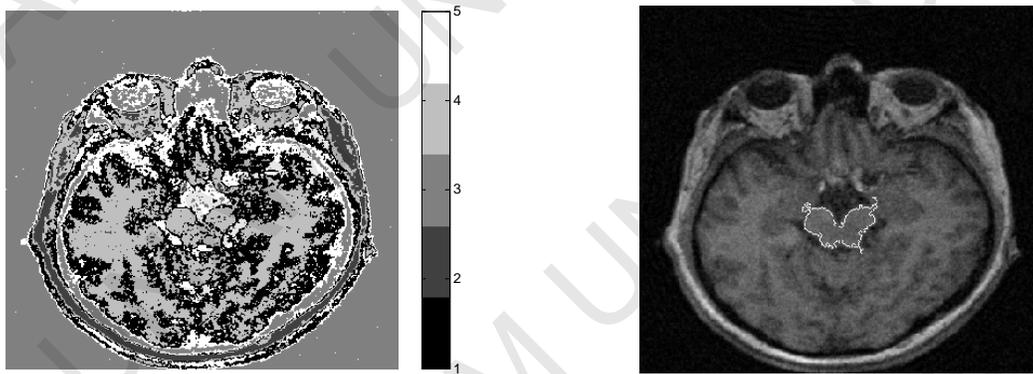


Figura 24. Segmentación (*k*-medias, $k=5$), Imagen con desenfoque y ruido, filtrada con filtro Wiener.

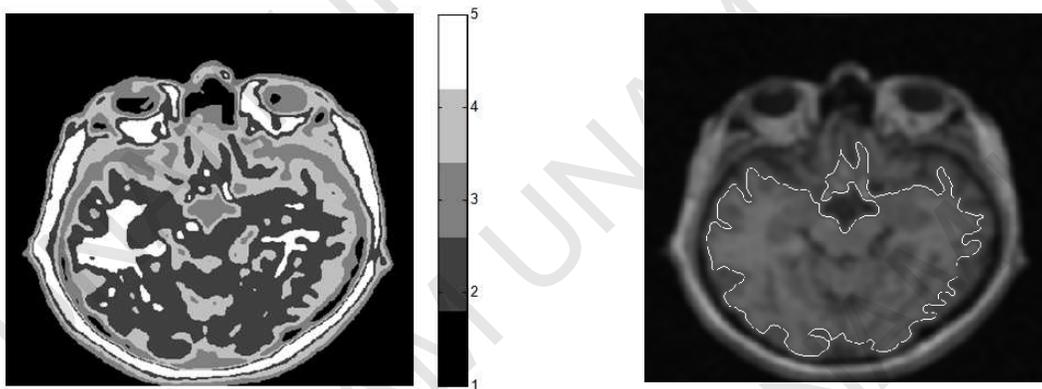


Figura 25. Segmentación (*k*-medias, $k=5$), Imagen con desenfoque y ruido, filtrada con filtro Gaussiano y UM.

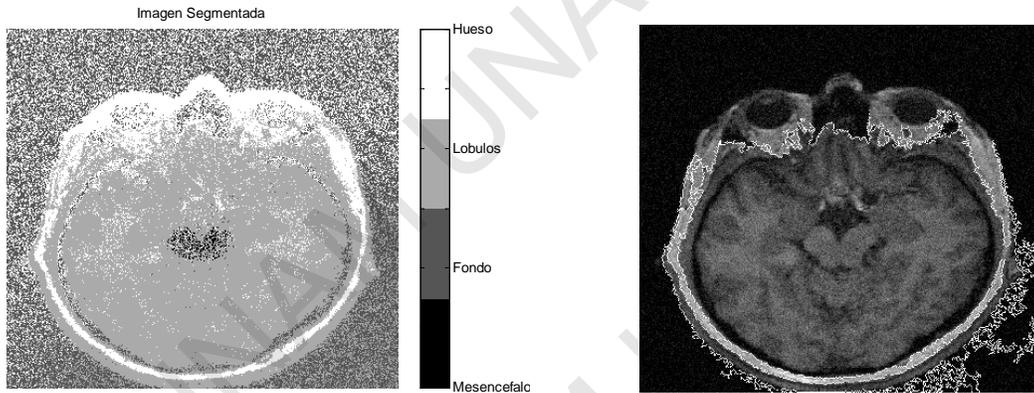


Figura 26. Segmentación Bayes. Imagen con ruido

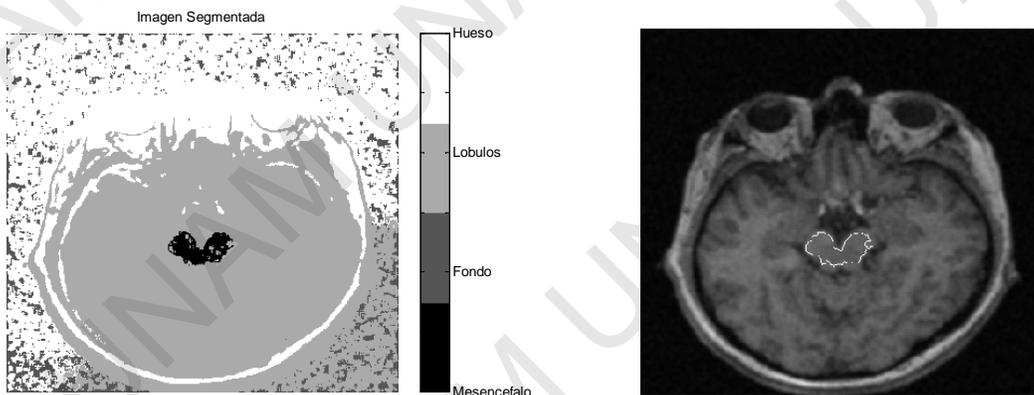


Figura 27. Segmentación Bayes. Imagen con ruido, filtrada con filtro Wiener.

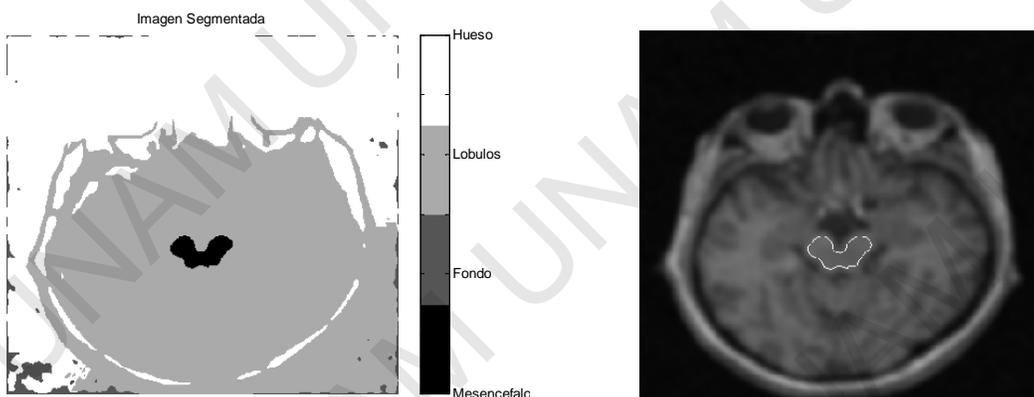


Figura 28. Segmentación Bayes. Imagen con ruido, filtrada con filtro Gaussiano.

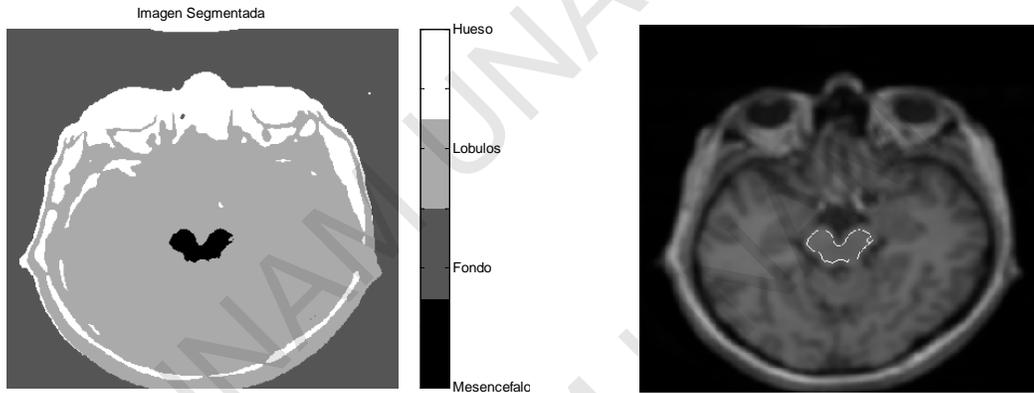


Figura 29. Segmentación Bayes. Imagen con desenfoque.

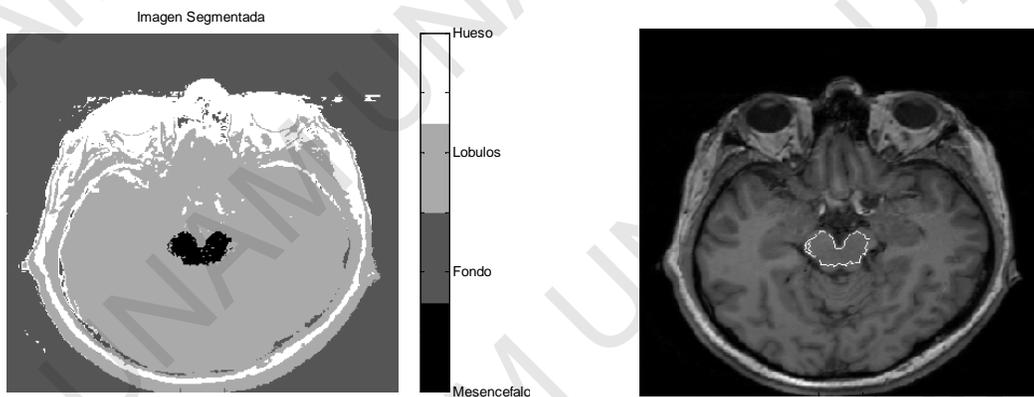


Figura 30. Segmentación Bayes. Imagen con desenfoque, filtrada con filtro Wiener.

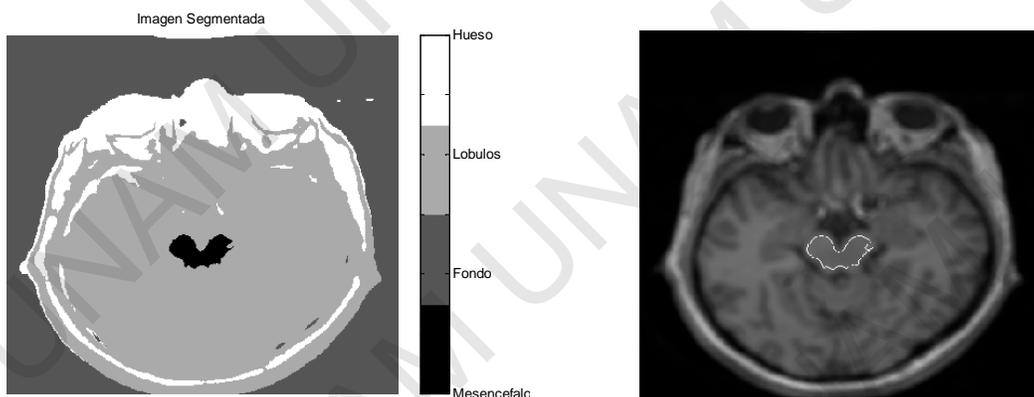


Figura 31. Segmentación Bayes. Imagen con desenfoque, filtrada con filtro UM.

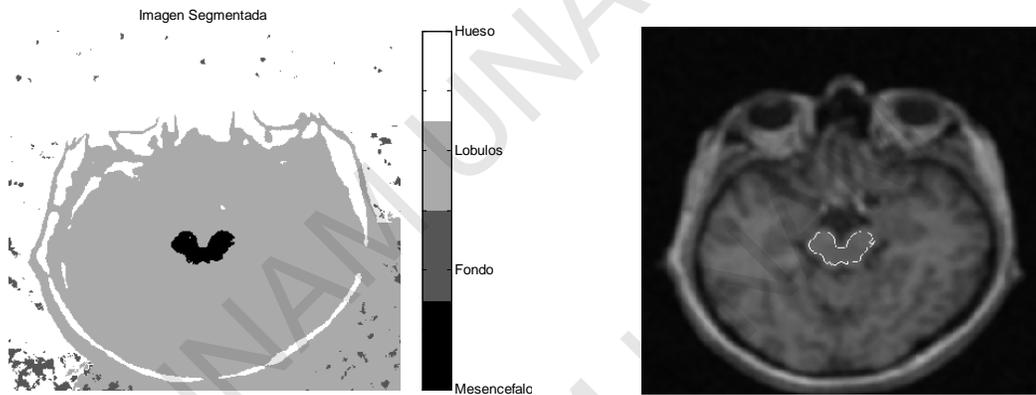


Figura 32. Segmentación Bayes. Imagen con ruido y desenfoque.

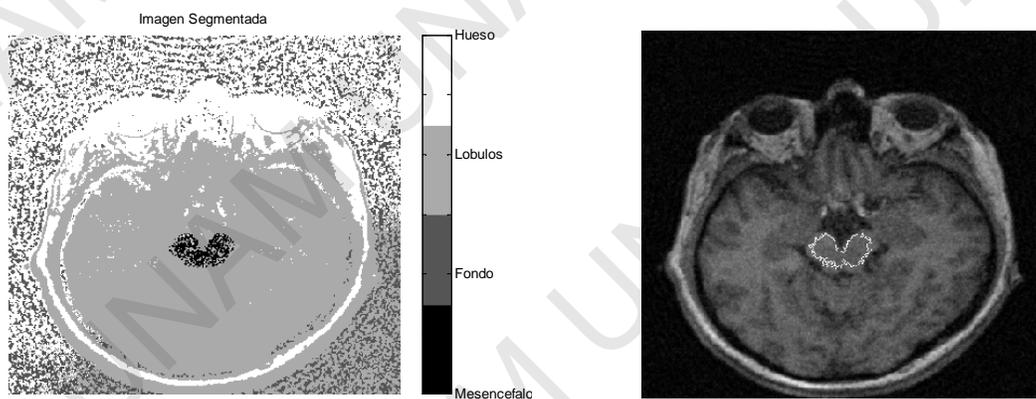


Figura 33. Segmentación Bayes. Imagen con ruido y desenfoque, filtrada con filtro Wiener.

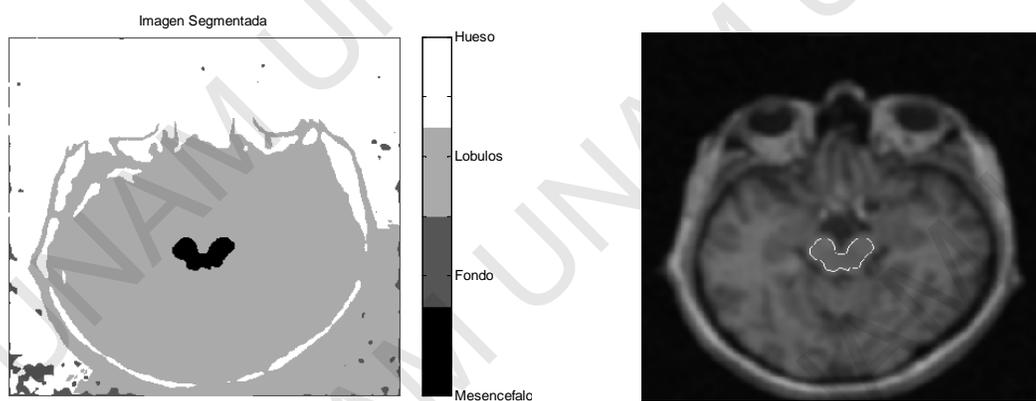


Figura 34. Segmentación Bayes. Imagen con ruido y desenfoque, filtrada con filtro UM.

7. EVALUACIÓN

Algoritmo de k-medias.

Imagen con ruido.

- Segmentando la imagen, el resultado es que la zona de interés se obtiene junto con partes de su entorno como una región conectada, por lo que la segmentación no es buena.
- Filtrando esta imagen con un filtro Wiener, se mejora la separación de las regiones y se obtiene una buena segmentación, comparada con la imagen sin ruido.
- Filtrando la imagen con un filtro Gaussiano, se suaviza la imagen, provocando que las zonas sean homogéneas y por lo tanto incluye en una misma región el área de interés y su entorno, por lo que se tiene una mala segmentación.

Imagen con desenfoque.

- Ya que el desenfoque tiene el efecto de difuminar bordes y homogeneizar las regiones, es similar a aplicar un filtro Gaussiano, por lo que la segmentación no es buena, ya que de nuevo la región de interés está conectada con su entorno.
- Filtrando la imagen con un filtro Wiener, se mejora de forma significativa la nitidez, recuperando en apariencia la imagen original, por lo que se obtiene una buena segmentación.
- Filtrando la imagen con un filtro Unsharp Masking para mejorar la nitidez no tiene buenos resultados. Como se mencionó antes, este tipo de filtro se basa en emplear una máscara borrosa de la imagen original, para mejorar la nitidez, pero cuando la imagen no contiene un grado de nitidez o calidad aceptable, el filtro Unsharp Masking no mejora la calidad de la imagen. Por lo tanto la segmentación no es buena.

Imagen con desenfoque y ruido.

- En este caso el efecto más notorio es el desenfoque, el resultado de la segmentación confirma esta percepción, es decir, no se tiene una buena segmentación ya que se incluyen áreas del entorno al área de interés.
- El filtro Wiener aplicada a la imagen mejora la segmentación, aunque la calidad de la imagen podrá variar dependiendo de la percepción, ya que el filtro se adecuó experimentalmente variando la relación Ruido/Señal.
- De nuevo, usando un filtro Unsharp Masking a una imagen desenfocada, no mejora su nitidez, por lo que la segmentación es mala.

Clasificador Bayesiano.

Imagen con ruido.

- Aunque algunos píxeles de la región de interés son clasificados correctamente, no hay una región bien definida. En el procesamiento posterior, la selección del punto perteneciente a la región de interés se realizó de igual forma que las anteriores, es decir, de forma interactiva sin ser exactos. Esto provoca que, tanto por la eliminación de las regiones menores a una cantidad preestablecida de píxeles, como por el relleno de los espacios vacíos del cluster al que pertenece el punto elegido, la región restante no corresponda a la deseada. Por lo que se obtiene una mala segmentación.
- Filtrando la imagen con un filtro Wiener, se logra homogeneizar en cierta medida las regiones, produciendo en la segmentación una región de interés más grande que la anterior. A pesar de esto, la segmentación pierde algunas zonas en los bordes de la región.
- Filtrando la imagen con un filtro Gaussiano, se obtienen en la segmentación unos bordes más suaves correspondientes a la forma de el área de interés, pero debido a la eliminación de las altas frecuencias, el borde no llega a ajustarse por completo al percibido. Una mejora para este resultado se podría obtener aplicando un filtro Wiener contra desenfoque.

Imagen con desenfoque.

- Se tiene un desempeño similar al obtenido cuando se filtra la imagen con un filtro Gaussiano, perdiendo algunos bordes, similar a la imagen sin degradación.
- Filtrando la imagen con un filtro Wiener se tiene un desempeño similar a la imagen sin degradación, aunque se pierden algunas zonas en los bordes.
- Filtrando la imagen con un filtro Unsharp Masking, de nuevo el resultado es similar a los anteriores a la imagen sin degradación, ya que el filtro tiene poca o nula incidencia en la mejora de la nitidez.

Imagen con desenfoque y ruido

- Ya que el efecto de desenfoque es el que domina, se tiene una segmentación similar a la imagen degradada sólo por desenfoque, también perdiendo algunas zonas en los bordes.
- Filtrando la imagen con un filtro Wiener se logra en gran medida reducir el desenfoque aunque las zonas pierden un poco de homogeneidad, lo cual provoca que los bordes no sean suaves. Cabe mencionar que la percepción del ruido restante se prefirió al de homogeneidad de las zonas en la experimentación para decidir la calidad de la imagen variando la relación Ruido/Señal como parámetro del filtro Wiener.
- Como se ha visto, el filtro Unsharp Masking no mejora una imagen con una degradación acentuada de distorsión. Sin embargo la segmentación es aceptable, comparada con la imagen sin degradación, debido a la homogeneidad de las zonas y al método de segmentación empleado.

8. CONCLUSIONES.

En la segmentación por K medias, para establecer un número de cluster adecuado que separe el Mesencéfalo de su entorno, se empleó la imagen original, (de la cual se tiene una percepción de calidad aceptable), y se efectuaron diversas realizaciones para cuatro diferentes valores de cluster K.

Para los valores $K=3$ y $K=5$, se aprecia que el Mesencéfalo se separa de su entorno y en ambos se tiene un buen desempeño. Sin embargo, se seleccionó $K=5$, ya que las regiones percibidas como anatómicamente diferentes se separan, por ejemplo, el cerebro y cráneo pertenecen a dos zonas diferentes, a diferencia de la experimentación con $K=3$ que las agrupa como una sola.

Este valor de k funciona bien para la imagen disponible, donde las regiones son más o menos homogéneas y se nota la separación del Mesencéfalo del fondo. En imágenes con ruido, se deberá filtrar para reducirlo y mejorar el desempeño de la segmentación.

Ya sea con el algoritmo de k-medias o con el detector bayesiano, la segmentación funciona con información previa proporcionada, ya sea por el número de clusters que se ingresa basado en experimentos previos, o por los conjuntos de datos de entrenamiento, correspondientemente.

Retomando la definición de un detector óptimo, ambos métodos pertenecen a esta categoría, ya que en ambos se cuenta con información previa sobre la distribución de los datos, una de forma heurística y otra de forma estadística. Además de que en ambos métodos se busca optimizar una función objetivo.

El filtro Wiener considera la degradación como un efecto lineal. Una degradación por desenfoque, por ejemplo por un filtro de media o Gaussiano aplicado sobre toda la imagen, se pueden considerar como degradaciones lineales, ya que fue posible restaurar la imagen conociendo el modelo de degradación que lo causó.

Por otra parte, el filtrado del ruido con el filtro Wiener especificando una relación Ruido/Señal constante para toda la imagen, tiene buenos resultados, aunque puede variar según la percepción de la calidad al ajustar esta relación como parámetro del filtro.

La segmentación de las imágenes restauradas, tiene buenos resultados con ambos métodos después de aplicar el filtro Wiener, a diferencia de los filtros paso bajas y Unsharp Masking. El clasificador Bayesiano tiene resultados similares con las imágenes restauradas con todos los filtros, principalmente porque además del nivel de gris como atributo, se incluyó información espacial de los pixeles.

En el filtro Wiener, la restauración de la imagen contra ruido y desenfoque se adapta en las zonas donde varía la relación Ruido/señal, pero se mantiene la misma estructura (llamada filtro inverso) para la degradación por desenfoque.

Respondiendo a la pregunta: Desde el punto de vista de la teoría de la detección, ¿aplicar un filtro lineal ya sea pasobajas para suavizar el ruido o del tipo unsharp masking para realzar los bordes de la estructura, debe mejorar el desempeño de un detector óptimo?

R: La detección positiva o negativa, y el rechazo positivo o negativo de un patrón, que es resultado de un proceso de filtrado paso bajas, no tendrá buen resultado para todas las frecuencias espaciales contenidas en una imagen ya que se aplica el mismo filtro para toda la imagen.

En el caso del filtro Unsharp Masking, se realizaron experimentos considerando que la imagen carece de nitidez y se desea mejorarla con un filtro de este tipo. A partir de esto y teniendo en cuenta que el filtro UM requiere una versión borrosa de la imagen, el resultado es también una imagen borrosa, por lo que la detección o rechazo de un patrón no tendrá buenos resultados.

Y respecto a la segunda Pregunta:

¿Existe un filtro lineal óptimo que optimice el proceso de detección en imágenes con ruido? ¿Cuál es?

R: Como se estableció en la Hipótesis, el filtro lineal que mejora el proceso de detección en imágenes con ruido es el filtro Wiener, ya que toma en cuenta la zona en donde se aplica el filtro (ya que su ámbito de operación es en la frecuencia espacial). Cuando no se conoce el ruido, se puede estimar o experimentar con el parámetro Ruido/Señal, y se puede notar una mejoría importante en la reducción del ruido; incluso si se conoce exactamente el ruido, es posible que permanezca alguna cantidad de ruido y no se recupere totalmente la imagen original. A pesar de esto se obtienen mejores resultados que con los filtros paso bajas y Unsharp Masking, y en consecuencia, mejores resultados en la segmentación.

9. BIBLIOGRAFÍA.

1. Solomon C, Breckon T. *Fundamentals of Digital Image Processing. A Practical Approach with Examples in Matlab*. John Wiley & Sons, Ltd, 2011.
2. Bankman IN (Editor). *Handbook of Medical Image Processing and Analysis*, 2nd Edition, Academic Press, USA, 2008.
3. Petrou M, Bosdogianni P. *Image Processing, the Fundamentals*. John Wiley & Sons, Ltd, 1999.
4. Barilla Perez ME, Franco Bello JA. *Fusión de datos y segmentación de imágenes de percepción remota*. Tesis, UNAM, Facultad de Ingeniería 2001.
5. Burger W, Burge MJ. *Principles of digital image processing Processing. Fundamental techniques*. Springer-Verlag London Ltd 2009.
6. Gonzalez RC., Woods RE, Eddins SL. *Digital Image Processing using Matlab*, 2nd Ed.
7. Omer Demirkaya et al. *Image Processing with MATLAB. Applications in Medicine and Biology*. CRC Press Taylor & Francis Group 2009.