

PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ
ESCUELA DE POSGRADO



**SEGMENTACIÓN DE IMÁGENES MÉDICAS MEDIANTE ALGORITMOS DE
COLONIA DE HORMIGAS**

Tesis para optar por el grado de Magíster en Informática que presenta:

CARLOS GABRIEL GAVIDIA CALDERÓN

Dirigido por:

CÉSAR ARMANDO BELTRÁN CASTAÑÓN

San Miguel, 2014

Resumen

El análisis de imágenes nos permite la extracción de información de éstas, y dentro de esta disciplina la segmentación permite la identificación de sus partes constituyentes. La segmentación de imágenes tiene aplicaciones en reconocimiento de patrones y sistemas de control de tráfico entre otros. Si llevamos la segmentación de imágenes al rubro de imágenes médicas, las aplicaciones van desde la detección de tumores y otras patologías hasta la medición de volúmenes en tejidos.

Existen diversas técnicas de segmentación de imágenes, y en este trabajo se plantea un procedimiento de segmentación de imágenes médicas basado en la metaheurística de Algoritmos de Colonia de Hormigas. Los algoritmos de esta metaheurística imitan el comportamiento de las hormigas durante su búsqueda de alimento, dado que siempre produce rutas óptimas entre la fuente de comida y el nido. Dicha conducta fue implementada mediante hormigas artificiales con el objeto de realizar tareas específicas de procesamiento de imágenes.

Este procedimiento fue aplicado a imágenes de Resonancias Magnéticas Cerebrales - buscando la extracción de los segmentos correspondientes a la Materia Gris, Materia Blanca y Líquido Cefalorraquídeo- y la segmentación obtenida fue de una calidad superior a la de los algoritmos actualmente existentes para esta tarea.

Este documento consta de 5 capítulos: El capítulo 1 busca definir el problema y el enfoque adoptado en este trabajo para darle solución. El capítulo 2 describe la disciplina de segmentación de imágenes y la metaheurística de Algoritmos de Colonia de Hormigas. El capítulo 3 describe los trabajos previos que busquen segmentar imágenes médicas mediante Algoritmos de Colonia de Hormigas. El capítulo 4 describe el procedimiento desarrollado, así como los resultados obtenidos en la aplicación del mismo. Finalmente, el capítulo 5 trata sobre las conclusiones y recomendaciones obtenidas como producto de este trabajo.

Índice

CAPÍTULO 1 GENERALIDADES.....	1
1.1 IDENTIFICACIÓN DEL PROBLEMA.....	2
1.2 OBJETIVO GENERAL.....	4
1.3 OBJETIVOS ESPECÍFICOS.....	4
1.4 RESULTADOS ESPERADOS.....	4
1.5 JUSTIFICACIÓN.....	4
1.6 LÍMITES DEL PROYECTO.....	5
1.7 APORTES DEL PROYECTO.....	6
CAPÍTULO 2 MARCO CONCEPTUAL.....	7
2.1 SEGMENTACIÓN DE IMÁGENES.....	8
2.1.1 <i>Técnicas basadas en umbrales</i>	8
2.1.1.1 Umbrales globales.....	8
2.1.1.2 Umbrales locales.....	11
2.1.2 <i>Técnicas basadas en detección de bordes</i>	12
2.1.3 <i>Técnicas basadas en regiones</i>	14
2.1.4 <i>Técnicas en transformación divisoria</i>	16
2.2 COLONIAS DE HORMIGAS ARTIFICIALES.....	17
2.2.1 <i>La metaheurística ACO</i>	20
2.2.1.1 Construcción de Soluciones.....	21
2.2.1.2 Aplicación de Búsqueda Local.....	21
2.2.1.3 Actualización de Feromona.....	22
2.2.2 <i>Algoritmos ACO</i>	22
2.2.2.1 Ant System (AS).....	22
2.2.2.2 Max-Min Ant System (MMAS).....	23
CAPÍTULO 3 REVISIÓN DEL ESTADO DEL ARTE.....	25
3.1 TRABAJOS PREVIOS EN SEGMENTACIÓN DE IMÁGENES MEDIANTE ALGORITMOS DE COLONIA DE HORMIGAS.....	26
CAPÍTULO 4 UN PROCEDIMIENTO PARA SEGMENTAR RESONANCIAS MAGNÉTICAS CEREBRALES BASADO EN COLONIAS DE HORMIGAS ARTIFICIALES.....	28
4.1 EXTRACCIÓN DE LA REGIÓN DE INTERÉS.....	29
4.1.1 <i>Algoritmo de Umbralización</i>	29
4.2 SEGMENTACIÓN DEL TELENCEFALO.....	33
4.2.1 <i>Algoritmo de Segmentación</i>	34
4.3 IMPLEMENTACIÓN Y PLATAFORMA DE EJECUCIÓN.....	38
4.4 EXPERIMENTOS Y RESULTADOS.....	38
4.4.1 <i>Diseño del experimento</i>	38
4.4.1.1 Carga Inicial.....	39
4.4.1.2 Umbralización.....	40
4.4.1.3 Segmentación.....	41
4.4.1.4 Análisis de Resultados.....	42
CAPÍTULO 5 CONCLUSIONES Y RECOMENDACIONES.....	45
5.1 CONCLUSIONES.....	46
5.2 RECOMENDACIONES.....	46

CAPÍTULO 6 ANEXOS.....I
CAPÍTULO 7 BIBLIOGRAFÍA.....III



Lista de imágenes

Fig. 1: Histograma, donde se aprecian los segmentos definidos por el umbral T.....	9
Fig. 2: Imagen original e imagen segmentada.....	10
Fig. 3: Área vs. Perímetro.....	10
Fig. 4: Máscaras del operador Sobel.....	13
Fig. 5: Proceso de obtención de bordes para una angiografía por resonancia magnética	13
Fig. 6: Algoritmo Hill Climbing de Bankman.....	16
Fig. 7: Hormigas en busca de alimento.....	18
Fig. 8: Imagen original arriba, telencéfalo extraído en la parte inferior.....	30
Fig. 9: Telencéfalo original arriba, telencéfalo segmentado en la parte inferior.....	35
Fig. 10: Diseño del experimento.....	39
Fig. 11: Resonancia magnética cerebral de BrainWeb.....	40
Fig. 12: Segmentos obtenidos por el Algoritmo propuesto.....	42

Lista de Tablas

Tab. 1: Segmentos producidos versus. Segmentos de referencia.....	43
Tab. 2: Resultados de las pruebas.....	44
Tab. 3: Probabilidad de mejor opción.....	I
Tab. 4: Ratio de evaporación.....	I
Tab. 5: Parámetro de medición de contigüidad.....	II
Tab. 6: Valor Máximo de Feromonas.....	II
Tab. 7: Importancia relativa de Heurística.....	II

Apéndices

Anexo I: Experimentos de calibración de parámetros para Algoritmo de Segmentación	I
--	---

Lista de Abreviaturas y Símbolos

ACO	<i>Ant Colony Optimization</i>
TSP	<i>Travelling Salesman Problem</i>
AS	<i>Ant System</i>
MMAS	<i>Max-Min Ant System</i>
JSI	<i>Jaccard Similarity Index</i>
CLF	<i>Líquido cefalorraquídeo</i>
MR	<i>Magnetic Resonance</i>



Dedicatoria

Este trabajo está dedicado a todos a los que tuve que postergar por dedicarme al Postgrado y a esta Tesis. Gracias por su comprensión y su paciencia.



Capítulo 1

Generalidades

En este capítulo se describe la necesidad de realizar Segmentación de Imágenes Médicas, además de la aproximación a dicho problema realizada como parte de la presente tesis. Asimismo, se detallan los objetivos de este trabajo y los resultados que se espera obtener.



1.1 Identificación del Problema

La disciplina de análisis de imágenes consiste en la extracción de información de representaciones gráficas. Los seres humanos - mediante el sentido de la visión - realizamos análisis de imágenes en tareas cotidianas como identificar objetos a distancia o leer un texto, acciones de análisis que podríamos calificar de orden cualitativo.

Además de las tareas de orden cualitativo, que la visión humana realiza eficientemente, existen tareas cuantitativas de análisis de imágenes. Por ejemplo, en [1] se menciona que existen técnicas de diagnóstico de rinitis atrófica en cerdos mediante el cálculo de áreas en imágenes de cortes transversales de la nariz de este animal. Es en estas tareas que la visión humana no se desempeña bien -prueba de ello son las ilusiones ópticas que hacen parecer grandes objetos que no lo son- por lo que surge la necesidad de utilizar computadoras para obtener esta información.

Volviendo al ejemplo de la rinitis atrófica, antes de realizar el cálculo de áreas es necesario depurar las imágenes obtenidas para remover imperfecciones y hacer el cálculo de áreas más preciso. Esta labor de pre-procesamiento en caso de ser realizada manualmente demanda considerable tiempo y esfuerzo, lo que por el contrario puede ser realizado de manera rápida y eficiente por una computadora y un buen algoritmo. Este es otro aspecto donde el uso de computadores resulta beneficioso para el análisis de imágenes.

El proceso de análisis de imágenes implica someter a la imagen a una serie de etapas consecutivas y lógicas para obtener la información deseada, siendo una de esas etapas la segmentación. El proceso de segmentación consiste en dividir la imagen en regiones, donde cada región se corresponde -por ejemplo- con objetos distintos o con partes distintas de un mismo objeto. Esta etapa es crítica debido a que representa un salto semántico de unidades computacionales -como los píxeles- hacia elementos más próximos a la realidad como objetos y sus partes constitutivas. Una segmentación exitosa es necesaria para que el resto de etapas del análisis de la imagen sean más simples [1].

Capítulo 1. Generalidades

La segmentación cobra especial importancia en el ámbito de imágenes médicas, donde es común el uso de computadoras y técnicas de segmentación automáticas para delinear estructuras anatómicas, dado que la realización de estos procedimientos de manera manual es tediosa y demanda tiempo considerable [9]. Estas técnicas tienen que lidiar con el hecho que la segmentación de imágenes es un procedimiento computacionalmente costoso, por lo que debe tenerse en consideración tiempos de respuesta y su optimización al momento del diseño de un procedimiento de esta naturaleza [10].

Dada su importancia, varios procedimientos han sido definidos para afrontar esa tarea, en gran medida debido a que las características y naturaleza de la imagen a segmentar influyen en la selección del algoritmo. Las técnicas de segmentación pueden agruparse en técnicas basadas en umbrales, técnicas basadas en detección de bordes, técnicas basadas en regiones y técnicas de transformación divisoria. Asimismo, el desempeño de estas técnicas puede ser optimizado mediante el uso de herramientas avanzadas como algoritmos evolutivos, redes neuronales y lógica difusa [2]. Sin embargo, aún no existe un procedimiento generalmente aceptado que produzca segmentaciones de calidad para múltiples dominios de aplicación [8].

En este trabajo, se plantea el uso de un método no-tradicional para la segmentación de imágenes médicas - haciendo énfasis en resonancias magnéticas cerebrales- basado en colonias de hormigas artificiales. Las colonias de hormigas naturales muestran un comportamiento complejo en contraste que el comportamiento simple que muestra cada hormiga como individuo, y esto es especialmente visible en el procedimiento de búsqueda de comida: Las hormigas al recorrer el terreno en busca de comida van dejando rastros de feromona, que sirven a su vez de guía al resto de integrantes de la colonia en su búsqueda de alimento. Tanto Marco Dorigo [5] como Chialvo y Millonas [6] definieron nuevos paradigmas computacionales estableciendo una analogía con ese comportamiento.

El método desarrollado plantea un procedimiento de segmentación de imágenes de resonancias magnéticas cerebrales para obtener los segmentos correspondientes a

Capítulo 1. Generalidades

Materia Gris, Materia Blanca y Líquido Cefalorraquídeo. El método propuesto consta de dos etapas: primero se realiza la obtención del objeto de interés de la imagen a procesar para luego proceder a la definición de segmentos en este objeto. En cada una de estas etapas se utiliza un Algoritmo de Colonia de Hormigas especializado, utilizando el planteado por Malisia [18][19] para la extracción del objeto y el descrito por Ouadfel[16] para la definición de segmentos.

1.2 Objetivo General

Desarrollar un procedimiento de segmentación de imágenes médicas mediante algoritmos basados en colonias de hormigas artificiales.

1.3 Objetivos Específicos

1. Determinar un conjunto de imágenes junto a un objetivo de segmentación, asegurando que existan mecanismos de medición de la calidad de la segmentación a realizar.
2. Implementar el algoritmo de segmentación de imágenes basado en colonias de hormigas artificiales.
3. Evaluar el desempeño del algoritmo a nivel de calidad de segmentación y tiempo de ejecución.

1.4 Resultados Esperados

1. Conjunto de imágenes médicas donde el procedimiento de segmentación será aplicado.
2. Un Software de Segmentación de Imágenes que internamente utilice Algoritmos de Colonia de Hormigas para ser aplicado sobre el Set de Imágenes del Resultado Esperado 1.
3. Una métrica de evaluación de la calidad de la segmentación, que permita establecer a su vez la calidad del procedimiento de segmentación propuesto.

1.5 Justificación

Se puede decir que la segmentación de imágenes es una de las etapas más importantes del proceso de análisis de imágenes. Asimismo, la gran mayoría de aplicaciones sobre

Capítulo 1. Generalidades

imágenes requieren de segmentación dentro de su proceso, ya sea en etapas tempranas -a nivel de pre-procesamiento- o en etapas posteriores[2]. Raut et al. [2] hace un listado extenso de aplicaciones que caen dentro de esa categoría, entre las que podemos mencionar: reconocimiento de objetos, reconocimiento de patrones, sistemas de control de tráfico y localización de objetos en imágenes satelitales.

La segmentación de imágenes se ha tornado en una herramienta importante para el diagnóstico de enfermedades [10]. Existen múltiples modalidades de imágenes médicas -resonancias magnéticas, tomografías y mamografías por mencionar algunas- y se suele usar computadoras para su análisis cuando se tiene un gran número de imágenes o estas son de gran tamaño. Los algoritmos de segmentación actualmente son aplicados para medir volúmenes de tejidos, para detectar tumores y patologías y para el estudio de estructuras anatómicas [2].

Los algoritmos ACO han sido aplicados con éxito a una gran diversidad de problemas, mostrando resultados similares a los mejores algoritmos diseñados para afrontar dichos problemas o en ciertos casos siendo la mejor aproximación para el mismo [25]. Existen actualmente algoritmos ACO para problemas de ordenamiento secuencial, problemas de clasificación, problemas de rutas de vehículos e incluso aplicaciones de análisis de imágenes como las mostradas en el Capítulo 3, lo que nos llevó a seleccionar a la metaheurística como el enfoque a adoptar.

1.6 Límites del Proyecto

Existen múltiples objetivos de segmentación en imágenes de resonancias magnéticas cerebrales: Podemos mencionar la extracción de estructuras específicas como tumores o lesiones de esclerosis múltiple. En el presente estudio, el objetivo de segmentación se limita a la identificar dentro de la imagen las regiones correspondientes a Materia Blanca, Materia Gris, y Líquido Cefalorraquídeo.

Para lograr este objetivo el estudio plantea la implementación de un procedimiento de segmentación de imágenes, que a su vez hace uso del algoritmo de Malisia [18] [19]

Capítulo 1. Generalidades

para lo referente a umbralización y al trabajo de Ouadfel[16] para la segmentación propiamente dicha.

De manera análoga a lo desarrollado por Cao [3][4], el procedimiento de segmentación será aplicado a imágenes de la base de datos de Resonancias Magnéticas Cerebrales proveída por el *Brain Imaging Centre* del *Montreal Neurological Institute* de *McGill University* [7]. Los segmentos obtenidos por el algoritmo serán contrastados con la información de segmentación que está contenida en la misma base de datos utilizando al índice de Jaccard (JSI) como indicador de similitud, debido a que esta métrica ya ha sido utilizada en múltiples aplicaciones de segmentación de imágenes [3][4] [22].

1.7 Aportes del Proyecto

En el procedimiento planteado hacemos énfasis en la importancia de las tareas de pre-procesamiento para aumentar el tiempo de respuesta y la calidad de la solución. El uso del algoritmo de umbralización para la extracción del telencéfalo se vio traducido en una reducción significativa del tiempo de ejecución del algoritmo, así como la aplicación de morfología matemática tuvo impacto en la calidad de la segmentación obtenida.

Otro aporte a rescatar es el nivel de similitud obtenido por el procedimiento planteado. Los experimentos muestran que se ha llegado a valores de Índice de Similitud de Jaccard (JSI) de hasta 0.94 para ciertos segmentos, lo que contrasta con los niveles de JSI de 0.9 obtenidos por procedimientos análogos sobre el mismo conjunto de imágenes médicas.

Finalmente, como parte de la implementación del procedimiento de segmentación fue necesario antes implementar los Algoritmos de Colonia de Hormigas utilizados así como funciones para manipulación de imágenes, dado que a la fecha de la investigación no existían librerías que ofrecieran la funcionalidad necesaria para este proyecto. Todo el código fuente construido como parte de este proyecto -hecho en Java- ha sido puesto en Internet para que pueda servir de soporte a futuras investigaciones a realizar en esta área.

Capítulo 2

Marco Conceptual

En este capítulo exploramos la disciplina de Segmentación de Imágenes describiendo algunas de las principales técnicas existentes. Asimismo, profundizamos en los conceptos principales de la Meta-Heurística de Algoritmos de Colonia de Hormigas y describimos los algoritmos más representativos dentro de esta técnica.



2.1 Segmentación de Imágenes

El proceso de segmentación tiene como objetivo establecer regiones en una imagen, donde cada región es homogénea en relación a una característica determinada. En el ámbito del procesamiento de imágenes médicas es una herramienta de importancia, teniendo aplicaciones que incluyen simulaciones de cirugía, medición de volumen de tumores, clasificación de células sanguíneas, estudios de desarrollo cerebral, detección de micro-calcificaciones en mamografías y detección de tumores. Si bien existen una gran cantidad de técnicas de segmentación disponibles a la fecha, no existe aún un procedimiento estándar que se pueda utilizar en todas las aplicaciones de procesamiento de imágenes y producir resultados satisfactorios [8].

La clasificación de las técnicas de segmentación es diversa, sin embargo para este capítulo se usará la tipología utilizada por Bankman [8] que a su vez coincide con la manejada por Glasbey[1]:

2.1.1 Técnicas basadas en umbrales

Este conjunto de técnicas establecen umbrales de modo que la imagen a segmentar pueda ser dividida en grupos de píxeles, donde un grupo de píxeles tenga asociados valores inferiores al umbral mientras otro grupo tenga valores superiores o iguales a este umbral. En [8], estas técnicas son a su vez clasificadas en dos grupos:

2.1.1.1 Umbrales globales

Estas técnicas se basan en la premisa que la imagen a analizar tiene un histograma bimodal, por ende, es posible diferenciar al objeto del fondo mediante una operación simple, que compara los valores de cada píxel de la imagen respecto a un valor umbral T .

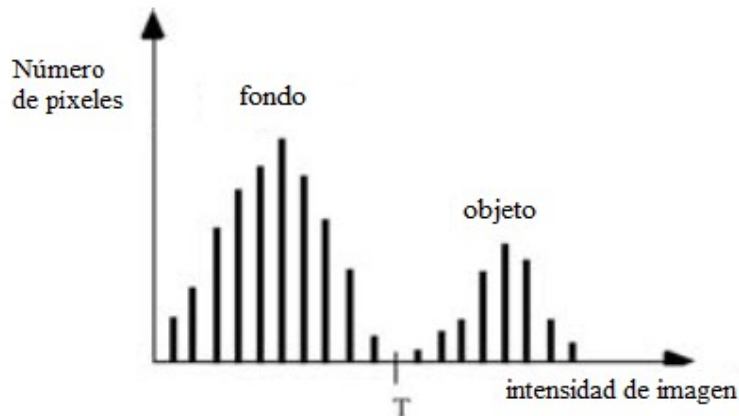


Fig. 1: Histograma, donde se aprecian los segmentos definidos por el umbral T .
Fuente: Handbook of medical image processing and analysis[8]

En la Figura 1. se observa que los píxeles del objeto y del fondo en la imagen tienen los niveles de gris agrupados en dos modas, donde la separación entre las modas viene a estar definida por el umbral T . Así, la imagen luego de la segmentación dada por el umbral viene a estar determinada por la siguiente expresión:

$$g(x, y) = \begin{cases} 1 & \text{si } (x, y) > T \\ 0 & \text{si } (x, y) \leq T \end{cases}$$

El resultado de la aplicación del umbral es una imagen binaria, donde los píxeles con un valor de intensidad 1 se corresponden al objeto mientras que los píxeles con valor de intensidad 0 son los asociados al fondo. La Figura 2. muestra el resultado de este proceso.

Se dice que se ha obtenido una segmentación adecuada cuando el área o el perímetro de los objetos tiene sensibilidad mínima hacia pequeñas variaciones del umbral seleccionado. Tanto el área $A(T)$ como el perímetro $P(T)$ del objeto obtenido como producto de la segmentación son dependientes del valor del umbral T , y estas variables tienen un comportamiento similar al mostrado en la Figura 3.




Fig. 2: Imagen original e imagen segmentada
Fuente: Handbook of medical image processing and analysis[8]




Fig. 3: Área vs. Perímetro
Fuente: Handbook of medical image processing and analysis [8]

Así, un buen valor del umbral a seleccionar debe minimizar $dA(T)/d(T)$ o $dP(P)/d(T)$. En caso la imagen tenga más de dos tipos de regiones, es posible segmentarla aplicando varios umbrales individuales o utilizando alguna técnica multi-umbral. Mientras más regiones se tenga, la identificación de las modas se dificulta con lo que también se complica el proceso de identificación de umbrales.

El uso de umbrales globales es de implementación simple y rápida, y se ha demostrado su eficiencia al procesar imágenes que contienen objetos con valores de intensidad uniforme con un fondo de alto contraste. Por el contrario, la técnica falla al haber un contraste bajo entre objeto y fondo, en caso la imagen tenga mucho ruido o si la intensidad del fondo varía significativamente a lo largo de la imagen [8].

2.1.1.2 Umbrales locales

Existen aplicaciones en las que no se puede obtener un único umbral para un histograma o también se puede dar el caso en el que el utilizar un solo umbral no nos brinde una segmentación de calidad. Para este tipo de situaciones, una posible alternativa es la utilización de umbrales locales, también llamados adaptativos[8].

Una primera aproximación es dividir la imágenes en sub-imágenes y calcular umbrales para cada sub-imagen. Para esto, la imagen es dividida en sub-imágenes superpuestas rectangulares, de modo que cada sub-imagen tenga píxeles tanto del objeto como del fondo. Luego, se obtienen histogramas para cada sub-imagen. Otro enfoque es examinar las intensidades de imagen en la vecindad de cada píxel. En ese caso, el umbral puede obtenerse como la media de la distribución de intensidad local u otra estadística (la media más la desviación estándar, la media entre el máximo y el mínimo, etc).

Se puede decir que el uso de umbrales locales es más costoso computacionalmente que usar umbrales globales, sin embargo es bastante útil para la segmentación de objetos con fondo variable y para la extracción de regiones pequeñas y dispersas [8].

2.1.2 Técnicas basadas en detección de bordes

Un borde en una imagen está definido por la gradiente de la intensidad de los píxeles, siendo la gradiente una aproximación de la derivada de primer orden de la función de la imagen. Así, la magnitud de la gradiente para una imagen $f(x, y)$ está dada por (1):

$$|G| = \sqrt{G_x^2 + G_y^2} = \sqrt{\left[\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2\right]} \quad (1)$$

Y la dirección de la gradiente se define por (2):

$$D = \tan^{-1}\left(\frac{G_y}{G_x}\right) \quad (2)$$

Donde G_x es la gradiente en la dirección x y G_y es la gradiente en la dirección y . En caso de representar la magnitud como una imagen, los niveles de gris serían proporcionales con la magnitud de los cambios de intensidad, mientras que en la imagen asociada a la dirección los niveles de gris representarían la dirección del máximo valor de gradiente en la imagen original.

Los operadores gradiente para imágenes digitales implican el cálculo de convoluciones, que son sumas ponderadas de los valores de intensidad en la vecindad de los píxeles. Los pesos para la ponderación se representan en un arreglo numérico -llamado máscara, ventana o kernel- que tiene la forma de la vecindad involucrada en el cálculo. Por ejemplo, el operador Sobel de detección de bordes tiene dos máscaras 3x3, las cuales se pueden ver en la Figura 4.

La primera máscara obtiene G_x , la segunda G_y y la magnitud de la gradiente se obtiene combinando ambos valores con la expresión correspondiente. Es común también que se utilicen umbrales en los valores de gradiente calculados para determinar si un borde ha sido encontrado. Por ejemplo, en la Figura 5 se muestra el proceso de obtención de bordes para una angiografía por resonancia magnética.

$$\begin{array}{cccccc}
 -1 & -2 & -1 & -1 & 0 & 1 \\
 0 & 0 & 0 & -2 & 0 & 2 \\
 1 & 2 & 1 & -1 & 0 & 1
 \end{array}$$

Fig. 4: Máscaras del operador Sobel
 Fuente: Handbook of medical image processing and analysis [8]




Fig. 5: Proceso de obtención de bordes para una angiografía por resonancia magnética
 Fuente: Handbook of medical image processing and analysis[8]

La figura A muestra a la imagen original, la figura B se corresponde con la imagen asociada a la magnitud de la gradiente obtenida con el operador Sobel y en las figuras

C y D se muestra el resultado de la aplicación del umbral, con valores de 300 y 600 respectivamente.

Las técnicas basadas en detección de bordes son de rápida ejecución y no requieren información *a priori* de la imagen, sin embargo los bordes por lo general no rodean al objeto a segmentar por completo. Esto hace necesario procesamientos posteriores para depurar los bordes obtenidos, que pueden ser computacionalmente costosos y de poca confiabilidad.

Dado que los picos de la derivada de primer orden se corresponden con valores cero en la derivada de segundo orden, es posible utilizar el Operador Laplaciano -una aproximación a la derivada de segundo orden- para detectar bordes en una imagen. Este operador está definido por la expresión (3):

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2}. \quad (3)$$

El Operador Laplaciano para imágenes digitales se aproxima mediante máscaras de convolución. Luego de aplicar la máscara, los bordes serían los píxeles donde el valor del Laplaciano se traslada hacia cero. Cabe resaltar que los métodos de detección de bordes basados en gradientes o en el operador Laplaciano son muy sensibles al ruido, por lo que es común reducir el efecto del ruido aplicando procedimientos de alisado antes de la detección de bordes. [8]

2.1.3 Técnicas basadas en regiones

La técnica de crecimiento de regiones tiene como punto de partida un píxel -o un grupo de píxeles- que pertenecen a la estructura de interés, donde estos píxeles pueden seleccionarse de manera manual o por un procedimiento automático. Luego, los píxeles en la vecindad son analizados uno a uno y agregados a la región en crecimiento en caso cumplan el criterio de homogeneidad. Este procedimiento continúa hasta abarcar la totalidad de píxeles de la imagen, donde al final del mismo el objeto queda representado por los píxeles aceptados durante el proceso de crecimiento.

El criterio de homogeneidad -también llamado prueba de uniformidad- puede ser la diferencia entre el valor de intensidad del píxel y la media del valor de intensidad dentro de la región. En caso esta diferencia sea menor que un valor predefinido (podríamos decir, dos desviaciones estándar del valor de intensidad dentro de la región) el píxel es incluido en la región, caso contrario pasa a ser un píxel limítrofe. El resultado de esta técnica es altamente dependiente del criterio de homogeneidad seleccionado, así como de los píxeles iniciales.

Un enfoque alternativo es comenzar con una segmentación inicial, y dividir las regiones que no satisfagan el criterio de uniformidad. En general, las técnicas basadas en regiones tienen la ventaja de generar regiones conectadas.

Podemos mencionar al algoritmo *Hill Climbing* de Bankman como una técnica de segmentación basada en regiones, utilizado para detectar microcalcificaciones en mamografías. La técnica aprovecha el hecho que dada una imagen $f(x, y)$, el borde de la microcalcificación a segmentar es un contorno cerrado alrededor del píxel (x_0, y_0) que posee la máxima intensidad local. Para cada píxel, se define un valor de pendiente de acuerdo a (4):

$$s(x, y) = \frac{f(x_0, y_0) - f(x, y)}{d(x_0, y_0, x, y)}, \quad (4)$$

Donde d es la distancia euclidiana entre el máximo local y el píxel (x, y) . En el primera etapa del algoritmo se ubican 16 puntos pertenecientes al borde alrededor del píxel (x_0, y_0) que viene a ser el máximo local. Luego, utilizamos estos puntos del borde como semillas para generar la región teniendo en cuenta restricciones de espacio e intensidad. En la Figura 6. siguiente se puede observar al algoritmo en acción [8]




Fig. 6: Algoritmo Hill Climbing de Bankman
Fuente: *Handbook of medical image processing and analysis* [8]

2.1.4 Técnicas en transformación divisoria

Estas técnicas hacen uso de morfología de imágenes. Se requiere inicialmente la selección de un punto semilla dentro de cada objeto de la imagen -considerando al fondo como un objeto- que podría ser obtenido mediante algún procedimiento automático. Una vez que cada objeto posea un punto semilla, su región asociada se va generando mediante transformaciones divisorias.

Para comprender este procedimiento, podríamos imaginarnos que la imagen es una superficie donde los píxeles brillantes representan cimas y los píxeles oscuros valles. Luego, se realizan perforaciones en los valles y se sumerge la superficie en agua, de modo que el agua se filtre a través de las perforaciones y los valles se inundan. Sin embargo, no está permitido que el agua proveniente de perforaciones distintas se mezcle por lo que hay que construir barreras en los puntos de contacto. Estas barreras, que son límites de los depósitos de agua, también son los límites de los objetos presentes en la imagen [8].

2.2 Colonias de Hormigas Artificiales

En 1992 Marco Dorigo propone *Ant System*[12], un procedimiento de resolución de problemas de optimización combinatoria emulando el comportamiento de búsqueda de alimento de una colonia de hormigas. El algoritmo propuesto es inicialmente validado en el problema del vendedor viajero (TSP - *Travelling Salesman Problem*) y se basa en la capacidad de las hormigas de seguir la ruta más corta entre su nido y la fuente de alimento en base a rastros de feromona.

Durante su recorrido, las hormigas depositan sobre su ruta rastros de feromona y a su vez tienden a seguir rutas donde el rastro de feromona sea intenso. El algoritmo propuesto por Dorigo -junto a otros algoritmos derivados- toma ventaja del hecho que las hormigas que tomen la ruta más corta depositarán más feromona sobre su camino dado que pueden ir y regresar de la comida al nido de manera más rápida. Al tener la ruta más corta un rastro de feromona más intenso, el resto de hormigas de la colonia seguirá esta ruta intensificando aún más el nivel de feromona, como puede apreciarse en la Figura 7 tomada de [11].

En la adaptación realizada por Dorigo en su algoritmo, se tiene una población de hormigas artificiales que recorren el grafo del TSP, donde la probabilidad que una hormiga tome la arista (camino) que conectada a dos nodos (ciudades) depende del nivel de feromona asociada a la arista, que a su vez es una función del número de hormigas que han recorrido dicha arista anteriormente. Esta retro-alimentación es la que le permite al algoritmo la resolución de múltiples problemas de optimización combinatoria.

Chialvo y Millonas [13] han desarrollado un modelo matemático de la inteligencia colectiva que emerge de una colonia de hormigas que buscan alimento mediante rastros de feromona. En [13] establecen una analogía entre la red de comunicaciones de la colonia con las conexiones entre neuronas en el cerebro: ambos sistemas comprenden un conjunto de nodos conectados, el estado de los nodos cambia en el

Capítulo 2. Marco Conceptual

tiempo y se dan procesos de aprendizaje entendidos como cambios de intensidad en las conexiones entre nodos.




Fig. 7: Hormigas en busca de alimento
Fuente: Swarm intelligence [11]

Este modelo establece que el movimiento de las hormigas está normado por dos parámetros: La intensidad de feromona y la influencia de la feromona en las hormigas de acuerdo a (5):

$$W(\sigma) = \left(1 + \frac{\sigma}{1 + \delta\sigma}\right)^\beta \quad (5)$$

De acuerdo a esa expresión, la probabilidad de que una hormiga se traslade hacia la ciudad r que tiene una intensidad de feromonas σ depende también de β , que está encargado de controlar la influencia del nivel del feromona en la decisión de la hormiga: Para valores bajos de β la concentración de feromonas no tiene mayor relevancia mientras que para valores altos es todo lo contrario [13].

Chiavo y Millonas [13] también establecen la necesidad de calibrar los parámetros con cuidado dado que, por ejemplo, valores de β elevados pueden llevar a soluciones sub-óptimas dado un comportamiento conformista de las hormigas. Por otro lado, valores de β demasiado bajos podrían evitar que las hormigas converjan hacia una solución óptima.

Las colonias de hormigas reales han logrado resultados importantes en diversos problemas de optimización, desde problemas de agrupamiento hasta obtención de rutas más cortas. Debe notarse que en ninguna de estas instancias de problema la solución pasa por una evaluación global de la situación: Las hormigas sólo son conscientes de su entorno inmediato. Los algoritmos de optimización por lo general requieren de la evaluación de la calidad de la solución, que implica comparar la calidad de las soluciones candidatas con un valor estándar entendido como un objetivo a alcanzar; sin embargo en las hormigas reales esto no es posible dado que las hormigas no son conscientes del desempeño de la colonia.

En general, podemos concluir que el procedimiento que comunicación mediante feromonas implica que la solución óptima resultará más atractiva, lo que se traducirá en una acumulación de feromona que hará que la población converja hacia esta solución. Todo esto a nivel local.

2.2.1 La metaheurística ACO

La aplicación de Colonias de Hormigas artificiales para la resolución de problemas de optimización combinatoria ha sido formalizada por Marco Dorigo en una metaheurística, que constituye un conjunto de conceptos algorítmicos que pueden ser usados por métodos heurísticos para un grupo diverso de problemas.

Esta metaheurística -denominada *Ant Colony Optimization* o ACO por sus siglas - establece que los modelos para problemas de optimización combinatoria deben tener los siguientes componentes:

- Un espacio de búsqueda S , definido sobre un conjunto finito y discreto de variables de decisión X_i . Una variable X_i toma valores en un dominio D_i .
- Un conjunto Ω de restricciones entre estas variables.
- Una función objetivo $f; S \rightarrow \mathbb{R}^+$, a ser minimizada. Una solución factible $s \in S$ es aquella que satisface todas las restricciones definidas en Ω , mientras que una solución s^* se define como óptimo global sólo si $f(s^*) \leq f(s)$, para todo s en S .

Además de un modelo para problemas de optimización combinatoria, es necesario definir un modelo de feromonas. Cada componente de una solución c_{ij} -es decir, cada posible asignación de valores v_i^j a variables X_i - tiene asignado un valor de feromonas τ_{ij} .

Durante la ejecución de Algoritmos ACO las hormigas construyen la solución al recorrer un grafo de construcción $G_C(V, E)$, conformado por el grupo de vértices V y el grupo de aristas E . Este grafo se puede obtener del conjunto de componentes de soluciones C , ya sea que estos representen los vértices o las aristas. Las hormigas artificiales se trasladan entre los vértices del grafo a través de las aristas construyendo soluciones parciales de manera incremental y además depositando feromona $\Delta\tau$ en los componentes, ya sean estos vértices o aristas. Esta cantidad $\Delta\tau$ es proporcional a la calidad de la solución generada, y las hormigas de la colonia utilizan la información de feromona como referencia en el proceso de exploración del espacio de búsqueda.

Capítulo 2. Marco Conceptual

Con estas consideraciones, los algoritmos dentro de la metaheurística ACO tendrían la siguiente estructura:

```

Iniciar parámetros
Iniciar rastros de feromona
Mientras no sea la condición de término hacer
    ContruirSoluciones
    AplicarBusquedaLocal
    ActualizarFeromona
FinMientras
  
```

El algoritmo implica un proceso de configuración inicial, que luego itera sobre tres fases:

2.2.1.1 Construcción de Soluciones

Un grupo de m hormigas artificiales construye soluciones utilizando elementos del conjunto de componentes de soluciones $C = \{c_{ij}\}$. Las soluciones comienzan como una solución parcial vacía, y en cada paso de construcción la solución parcial s^p es extendida con un componente de solución del conjunto $N(s^p)$, que viene a ser el grupo de componentes que pueden agregarse a la solución parcial sin violar las restricciones definidas en Ω . Durante el proceso de construcción, las hormigas recorren el grafo de construcción G_c .

La elección del siguiente componente desde $N(s^p)$ es realizada mediante un mecanismo estocástico, que depende del nivel de feromona asociado a cada componente de solución. Cada algoritmo ACO debe definir la regla de selección exacta.

2.2.1.2 Aplicación de Búsqueda Local

Una vez que las soluciones han sido construidas y antes de realizar el proceso de actualización de feromonas, podría realizarse un proceso de mejoramiento de las soluciones generadas por las hormigas mediante búsqueda local. Esta fase depende en gran medida de la naturaleza del problema y es opcional aunque bastante común.

Capítulo 2. Marco Conceptual

2.2.1.3 Actualización de Feromona

Esta fase busca incrementar los valores de feromona asociados a soluciones de mayor calidad, y disminuir los valores de los componentes de soluciones de menor calidad. Este procedimiento por lo general implica disminuir todos los valores de feromonas a través de un proceso de evaporación y luego incrementar los niveles de feromona de los componentes de las mejores soluciones.[17]

2.2.2 Algoritmos ACO

Existen múltiples algoritmos dentro de la metaheurística, sin embargo pasaremos a detallar sólo *Ant System* -que fue el algoritmo original en el contexto del Problema del Vendedor Viajero (TSP, por sus siglas en inglés)- y *Max-Min Ant System*, que es en el que se basa el procedimiento de segmentación utilizado en este trabajo.

2.2.2.1 Ant System (AS)

Ant System fue el primer algoritmo ACO propuesto, y se caracteriza por actualizar los valores de feromona de las soluciones de la totalidad de hormigas m presentes en la colonia al final de cada iteración. La cantidad de feromona τ_{ij} asociada a cada arista que vincula las ciudades i y j viene a estar definida por (6):

$$\tau_{ij} \leftarrow (1 - \rho) \cdot \tau_{ij} + \sum_{k=1}^m \Delta\tau_{ij}^k \quad (6)$$

Donde ρ es el ratio de evaporación, m es el número de hormigas y $\Delta\tau_{ij}^k$ es la cantidad de feromona a depositar en la arista (i, j) por la hormiga k . Este valor está definido por (7):

$$\Delta\tau_{ij}^k = \begin{cases} Q/L_k & \text{Si la hormiga } k \text{ utiliza la arista } (i, j) \text{ en su solución,} \\ 0 & \text{En cualquier otro caso,} \end{cases}$$

Donde Q es una constante y L_k es la longitud de la ruta construida por la hormiga k .

Capítulo 2. Marco Conceptual

Durante la construcción de la solución, las hormigas seleccionan la siguiente ciudad a visitar mediante un mecanismo estocástico. Al estar la hormiga k en la ciudad i y tener la solución parcial s^p , la probabilidad de trasladarse a la ciudad j está dada por (8):

$$p_{ij}^k = \begin{cases} \frac{\tau_{ij}^\alpha \cdot \eta_{ij}^\beta}{\sum_{c_{il} \in \mathbf{N}(s^p)} \tau_{il}^\alpha \cdot \eta_{il}^\beta} & \text{si } c_{ij} \in \mathbf{N}(s^p), \\ 0 & \text{en otros casos,} \end{cases}$$

Donde $\mathbf{N}(s^p)$ es el conjunto de componentes factibles, que vendrían a ser aristas (i, l) donde l es una ciudad que no ha sido visitada aún por la hormiga k . Los parámetros α y β controlan la importancia relativa de la feromona contra la información heurística η_{ij} , que viene a ser (9):

$$\eta_{ij} = \frac{1}{d_{ij}} \quad (9)$$

Donde d_{ij} es la distancia entre las ciudades i y j . [12]

2.2.2.2 Max-Min Ant System (MMAS)

Este algoritmo representa una mejora al algoritmo *Ant System* original. Entre sus características más importantes tenemos que sólo la hormiga de mejor desempeño puede realizar depósitos de feromona sobre los elementos de su solución, y que el valor de rastro de feromona asociado a una arista tiene límites inferiores y superiores, de acuerdo a :

$$\tau_{ij} \leftarrow \left[(1 - \rho) \cdot \tau_{ij} + \Delta \tau_{ij}^{\text{best}} \right]_{\tau_{\min}}^{\tau_{\max}}$$

Donde τ_{\max} representa la cota superior y τ_{\min} la cota inferior al nivel de feromona de una arista. Además, el operador $[\]$ se define como:

$$[x]_b^a = \begin{cases} a & \text{si } x > a, \\ b & \text{si } x < b, \\ x & \text{en otros casos;} \end{cases}$$

Y $\Delta\tau_{ij}^{\text{best}}$ es:

$$\Delta\tau_{ij}^{\text{best}} = \begin{cases} 1/L_{\text{best}} & \text{si } (i, j) \text{ pertenece a la mejor solución,} \\ 0 & \text{en otros casos;} \end{cases}$$

Donde L_{best} es la longitud de la ruta generada por la mejor hormiga de la colonia, ya sea de la iteración actual o la mejor solución global encontrada. En lo referente a las cotas, estas son generalmente obtenidas de manera empírica y ajustadas para problemas en específico.[21]

Capítulo 3

Revisión del Estado del Arte

En este capítulo se revisan los desarrollos recientes orientados a realizar Segmentación de Imágenes mediante Algoritmos de Colonia de Hormigas. Se describe el enfoque utilizado, las imágenes seleccionadas para segmentación y los resultados obtenidos.



3.1 Trabajos previos en Segmentación de Imágenes mediante Algoritmos de Colonia de Hormigas

Han [14] propone un algoritmo de segmentación de imágenes basado en algoritmos de colonia de hormigas usando un enfoque de *Clustering* Difuso. Luego de hacer una propuesta inicial de algoritmo concluye que el enfoque utilizado es demasiado caro en términos computacionales -una segmentación llega a tomar 10 minutos- por lo que rehace su propuesta con el fin de reducir cálculos. Los experimentos se orientan a detección de bordes, y al ser comparado con algoritmos clásicos como Sobel, Canny y *Watershed* en imágenes complejas el algoritmo muestra una mejor calidad de segmentación y un tiempo de respuesta manejable de 26 segundos.

Ouadfel [15] plantea un algoritmo híbrido utilizando *Ant Colony System* y Campos Aleatorios de Markov (MRF, por sus siglas en inglés) para segmentar imágenes. Se realizan experimentos sobre resonancias magnéticas de cerebros, y se realizan comparaciones de desempeño y calidad con Algoritmos Genéticos y Algoritmos de Recocido Simulado, tomando como referencia la segmentación ofrecida por la Base de Datos utilizada. Se concluyó que el algoritmo se desempeña de manera similar a sus análogos en el experimento.

En otro trabajo, Ouadfel[16] propone la utilización de *Max-Min Ant System* -otro algoritmo ACO- para la segmentación de imágenes. Se plantea el problema de segmentación como un problema de *Clustering*, y se realizan ajustes al algoritmo original -un procedimiento de búsqueda local y la regla pseudo aleatoria de *Ant Colony System*- para que mejorar su desempeño. Se realizan experimentos en imágenes simuladas y reales, y se realizan comparaciones con el Algoritmo *K-Means*, resultando que el algoritmo propuesto tiene más resistencia al ruido que su competidor.

Tanto en [18] como en [19], Malisia adapta el Algoritmo *Ant System* para la segmentación binaria de imágenes, es decir, establecer dos categorías en las imágenes a segmentar, pudiendo ser estas objeto y fondo. Compara los resultados de su propuesta con los algoritmos de Otsu, Kittler y Kapur obteniendo resultados superiores en lo referente a calidad de segmentación.

Capítulo 3. Revisión del Estado del Arte

Cao en [3] y [4] toma como referencia el modelo de Chialvo y Millonas[6] de hormigas artificiales para proponer un algoritmo de segmentación de imágenes, que valida contra con una base de datos de Resonancias Magnéticas Cerebrales. La base de datos utilizada consigna también segmentaciones de referencia, lo que le permite validar numéricamente la superioridad de su algoritmo respecto a *Fuzzy C-means*.



Capítulo 4

Un procedimiento para segmentar resonancias magnéticas cerebrales basado en Colonias de Hormigas Artificiales

El objetivo del procedimiento a desarrollar es obtener la Materia Gris, Materia Blanca y Líquido cefalorraquídeo de imágenes correspondientes a Resonancias Magnéticas Cerebrales: Para esto, se planea utilizar el algoritmo de Segmentación basado en Colonias de Hormigas Artificiales planteado por Ouadfel en [16]. Sin embargo, la experimentación inicial indicó que el algoritmo toma tiempo considerable en llegar al resultado, por lo que se hacía necesario un procedimiento de depuración previo antes de la ejecución del algoritmo de segmentación.

Con este fin, el procedimiento se ha dividido en dos etapas de manera análoga a lo trabajado por Yoon en [22]. La primera etapa implica la extracción del telencéfalo de las imágenes de entrada mediante un algoritmo de umbralización -también basado en Colonias de Hormigas Artificiales- propuesto por Malisia en [18][19], mientras que en la segunda etapa segmentamos el tejido interno del cerebro con el algoritmo de Ouadfel, solamente en la región de interés determinada por el algoritmo de umbralización lo que se espera produzca una reducción del tiempo de procesamiento.

*Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales
basado en Colonias de Hormigas Artificiales*

4.1 Extracción de la región de interés

Dado que el procedimiento de segmentación propiamente dicho es computacionalmente intenso, la primera parte del procedimiento propuesto consiste en aislar la región del telencéfalo y excluir del análisis el hueso, músculo y tejidos que no son trascendentes en el proceso de segmentación.

Este procedimiento a su vez cuenta de tres etapas diferenciadas: La primera es excluir inicialmente los píxeles del fondo con un proceso de umbralización sencillo. Una vez que los píxeles del fondo han sido excluidos, se aplica el algoritmo de umbralización basado en Colonia de Hormigas para separar el telencéfalo del resto de tejidos. Finalmente, el resultado de esta segmentación es depurado mediante la técnica de apertura de morfología matemática. El resultado de este proceso puede apreciarse en la Figura 8.


4.1.1 Algoritmo de Umbralización

Se usará el algoritmo presente en el trabajo de Malisia en [18] y [19], donde utilizan Colonias de Hormigas Artificiales para la segmentación binaria de imágenes tomando como referencia a *Ant System*.

Dado un conjunto S de n píxeles, cada píxel $s \in S$ está definido por su ubicación (i, j) y su valor de escala de grises y_s , mediante el algoritmo buscamos que las hormigas artificiales construyan rutas de píxeles g_k de longitud n , donde la media de nivel de escala de grises de un ruta de píxeles g_k esta dada por:

$$\mu_g^k = 1/n * \sum_{s \in g_k} y_s$$

*Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales
basado en Colonias de Hormigas Artificiales*



*Fig. 8: Imagen original arriba, telencéfalo extraído en la parte inferior
Fuente: Elaboración propia*

El objetivo del algoritmo es generar una dimensión adicional para cada píxel de la imagen que viene a ser la cantidad de feromona asociada a cada píxel, de modo que sirva de entrada a un algoritmo de agrupamiento que sea el que defina las dos particiones de la imagen: objeto y fondo. El proceso en su conjunto puede definirse de la siguiente manera:

*Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales
basado en Colonias de Hormigas Artificiales*

Iniciar matriz de rastros de feromonas

Mientras no se ha llegado al máximo de iteraciones **hacer**

Para cada hormiga k

Construir una ruta de píxeles mediante la regla de transición

FinPara

Actualizar los valores de rastro de feromona para todas las rutas de píxeles.

Evaporar la feromona asociada a todos los píxeles

FinMientras

Normalizar matriz de feromona

Ejecutar algoritmo de agrupamiento usando como atributos el valor de feromona y el valor de escala de grises

Pasaremos a definir con mayor detalle el desarrollo del algoritmo:

Regla de Transición

Al iniciar el algoritmo asignamos una hormiga de la colonia a cada píxel de la imagen a segmentar. Dentro de cada iteración, cada hormiga se traslada hacia un píxel dentro de su vecindad realizando esta tarea hasta que la ruta de píxeles generada alcance una longitud definida. La vecindad de un píxel viene a estar dada por un máximo de 8 píxeles adyacentes.

La probabilidad de selección del siguiente píxel en la ruta es realizada mediante el mismo procedimiento de *Ant System* descrito en el Capítulo 2 de acuerdo a la expresión (10):

$$p_{ij}^k = \frac{[\tau_{ij}]^\alpha [\eta_{ij}]^\beta}{\sum_{l \in N_i^k} [\tau_{il}]^\alpha [\eta_{il}]^\beta} \quad \text{if } j \in N_i^k \quad (10)$$

Donde:

- τ_{ij} es el contenido de feromona del píxel de coordenadas i, j
- N_i^k está definido por los píxeles colindantes al píxel i en el que se encuentra la hormiga k

Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales basado en Colonias de Hormigas Artificiales

- η_{ij} es la información heurística asociada al trasladarse al píxel j viniendo del píxel i . Viene a estar definida como la inversa del valor absoluto de la diferencia entre el valor de escala de grises del píxel j y el valor medio de la escala de grises de la ruta de píxeles actual.
- α es un parámetro que define la importancia relativa de la feromona
- β es un parámetro que define la importancia relativa de la información heurística

Actualización de Rastros de Feromona

Luego que todas las hormigas han construido una ruta de píxeles, los rastros de feromona son actualizados. Para esto, se determina el costo asociado a la ruta de píxeles y se calcula la cantidad de feromona a depositar en los píxeles que constituyen la ruta actual. La cantidad de feromona asociada a cada píxel de la ruta quedaría determinada por la expresión (11):

$$\tau_i^{new} = W\tau_i^{current} + \Delta\tau_i^k \quad (11)$$

De la misma manera que en [18] y [19], se utiliza el parámetro adicional W en la regla de actualización. Este parámetro toma valores entre 0 y 1, y tiene por objeto reducir la contribución de la feromona pre-existente y darle mayor énfasis a la feromona adicional.

En el algoritmo la feromona es depositada directamente en los píxeles -análogos a los vértices- y no en las artistas, escenario que es también contemplado en la metaheurística ACO. Luego de realizado el depósito de feromona, se realiza el proceso de evaporación de feromona en todos los píxeles de la imagen de acuerdo a la expresión (12) similar a la de *Ant System*:

$$\tau_{ij} = (1 - p)\tau_{ij} \quad 0 < p \leq 1. \quad (12)$$

*Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales
basado en Colonias de Hormigas Artificiales*

Donde ρ define la persistencia de los rastros de feromona y toma valores entre 0 y 1. A mayores valores de ρ mayor es la velocidad con la que la información obtenida en iteraciones previas es descartada.

Calidad de la Solución

El algoritmo busca encontrar regiones de la imagen con valores bajos de escala de grises. Bajo esta premisa, el costo asociado a la ruta de píxeles generada por la hormiga k viene a ser el valor medio de la escala de grises para esta ruta, μ_g^k . Una vez definido el costo, la cantidad de feromona adicional vendría a ser la definida por (13):

$$\Delta \tau_i^k = \frac{1}{A + B\mu_g^k} \quad (13)$$

Se observa que la cantidad adicional de feromona es inversamente proporcional al costo de la ruta de píxeles. Los parámetros A y B fueron introducidos en [18] y [19] para darle estabilidad a la función, debido a que su ausencia hacía la función muy sensible con valores bajos de escala de grises.

Clasificación de Píxeles

La matriz de feromonas obtenida es normalizada linealmente. Luego, se genera un set de datos con una instancia por cada píxel de la imagen original, donde para cada instancia se definen dos atributos: Cantidad de feromona normalizada, y el valor de escala de grises de la imagen original. Este set de datos es agrupado mediante *K-means*, habiéndole proveído previamente del número de clústers a considerar, que para un proceso de umbralización viene a tomar el valor de dos (fondo y objeto).

4.2 Segmentación del telencéfalo

El algoritmo de umbralización filtrará de la imagen original el fondo, dejando sólo la región concerniente al telencéfalo. Es sobre esta región de la imagen que aplicaremos

Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales basado en Colonias de Hormigas Artificiales

el algoritmo de segmentación de Ouadfel [16] con el fin de obtener la Materia Gris, Materia Blanca y Líquido Cefalorraquídeo de la imagen original.

Así, la imagen del telencéfalo servirá de entrada al algoritmo de segmentación, que asignará a cada píxel de esta imagen un clúster correspondiente de 3 clústeres posibles (Materia Gris, Materia Blanca y Líquido Cefalorraquídeo). En la Figura 9 se puede apreciar el resultado de este proceso.


4.2.1 Algoritmo de Segmentación

El modelo de problema para el Algoritmo de Segmentación cambia drásticamente respecto al del Algoritmo de Umbralización, aún al tratarse ambos de algoritmos ACO y lidiar ambos con procesamiento de imágenes.

En el Algoritmo de Segmentación, una imagen se considera como un conjunto S de n píxeles, donde cada píxel está definido por su ubicación en la imagen (i, j) y su valor de escala de grises y_s . El algoritmo busca definir una partición de S en K clústeres $\{c_1, c_2, c_3, \dots, c_k\}$, de modo que cada clúster c_k tenga n_k píxeles y cada píxel s pertenezca sólo a un clúster.

El algoritmo de agrupamiento está basado a su vez en el algoritmo ACO *Max-Min Ant System*, y a través de las iteraciones tratará de obtener la partición óptima. El algoritmo puede describirse de la siguiente manera:

*Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales
basado en Colonias de Hormigas Artificiales*



*Fig. 9: Telencéfalo original arriba, telencéfalo segmentado en la parte inferior
Fuente: Elaboración propia*

*Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales
basado en Colonias de Hormigas Artificiales*

Iniciar matriz de rastros de feromonas con su valor máximo
Mientras no se ha llegado al máximo de iteraciones **hacer**

Para cada hormiga k

Construir una posible solución mediante la regla de transición

FinPara

Actualizar los valores de rastro de feromona para todas las rutas de píxeles.

Evaporar la feromona asociada a la partición de la mejor hormiga

FinMientras

Devolver la mejor partición encontrada

Pasaremos a definir con mayor detalle el desarrollo del algoritmo:

Regla de Transición

Una hormiga puede asignar el píxel s hacia al clúster candidato c mediante la siguiente regla :

$$c = \begin{cases} \operatorname{argmax} \tau(s,c) \cdot (\eta(s,c))^\beta & \text{if } q \leq q_0 \\ C & \text{otherwise} \end{cases}$$

Donde:

- $\tau(s,c)$ es el contenido de feromona presente en la asociación del píxel s al clúster c .
- $\eta(s,c)$ es la información heurística.
- β es un parámetro que define la importancia relativa de la información heurística
- q es un valor aleatorio entre 0 y 1.
- q_0 es un parámetro que controla la explotación del historial de búsqueda -representado por los rastros de feromona- contra la exploración del espacio de búsqueda.

C es una variable aleatoria a seleccionar de acuerdo a la siguiente distribución de probabilidades:

Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales basado en Colonias de Hormigas Artificiales

$$p(s,c) = \frac{\tau(s,c) \cdot (\eta(s,c))^\beta}{\sum_u \tau(s,u) \cdot (\eta(s,u))^\beta}$$

Donde:

- u es un posible clúster dentro del grupo de clústeres $\{c_1, c_2, c_3, \dots, c_k\}$.
- $p(s, c)$ es la probabilidad de que la hormiga seleccione asignar el píxel s hacia el clúster c .

Se observa que la asignación depende tanto de la cantidad de feromona τ como del valor de la función heurística η , que en este contexto viene a representar que tan atractiva resulta la asignación manteniendo regularidad espacial. El algoritmo define entonces la función heurística de la siguiente manera:

$$\eta(s,c) = d_e(s,c) + \alpha \cdot d_c(s,c)$$

Dónde:

- d_e es la distancia euclidiana entre el valor de escala de grises del píxel y el promedio del clúster candidato.
- d_c es una medida de contigüidad, tomada respecto a los 8 píxeles colindantes.
- α es un parámetro que toma valores entre 0 y 1.

Actualización de Rastros de Feromona

Luego que todas las hormigas de la colonia han construido una posible partición, se realiza el procedimiento de actualización de los rastros de feromona sólo en la hormiga de mejor desempeño en la iteración actual. Los rastros de feromona asociados a la correspondencia entre píxeles y clústeres (p,s) se actualizan de acuerdo a la expresión:

Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales basado en Colonias de Hormigas Artificiales

$$\tau(s, c) = \rho\tau(s, c) + \frac{1}{Q_{best}}$$

Donde:

- ρ es la persistencia del rastro de feromona, y toma valores entre 0 y 1.
- Q_{best} es la calidad de la mejor partición generada durante la iteración actual.

Calidad de la Solución

El algoritmo busca generar clústeres compactos, separados entre sí tomando en cuenta que los píxeles colindantes deben pertenecer al mismo clúster. Con estos criterios, se define la calidad de partición Q con la expresión:

$$Q = \sum_{i=1}^k \sum_{s \in c_i} \frac{1}{n_i} \cdot \eta(s, c_i)$$

4.3 Implementación y plataforma de ejecución

Para la implementación del algoritmo se utilizó el lenguaje Java utilizando el kit de desarrollo de Oracle en su versión 1.7. La implementación de los algoritmos se hizo mediante librerías propias de la plataforma, a excepción del procedimiento de agrupación *K-means* para lo que se utilizó la implementación proveída por Weka [20] en su versión 3.6. La ejecución se realizó sobre una portátil con procesador Intel Core i7 2.20 Ghz con sistema operativo Microsoft Windows 8 Professional.

4.4 Experimentos y resultados

4.4.1 Diseño del experimento

El objetivo del experimento es someter a una resonancia magnética cerebral al procedimiento de segmentación propuesto, obtener los segmentos correspondientes a la Materia Gris, Materia Blanca y Líquido Cefalorraquídeo y determinar la calidad de la segmentación propuesta, de manera análoga a lo planteado por Cao en [3]. Este procedimiento está descrito en la Figura 10.

Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales basado en Colonias de Hormigas Artificiales

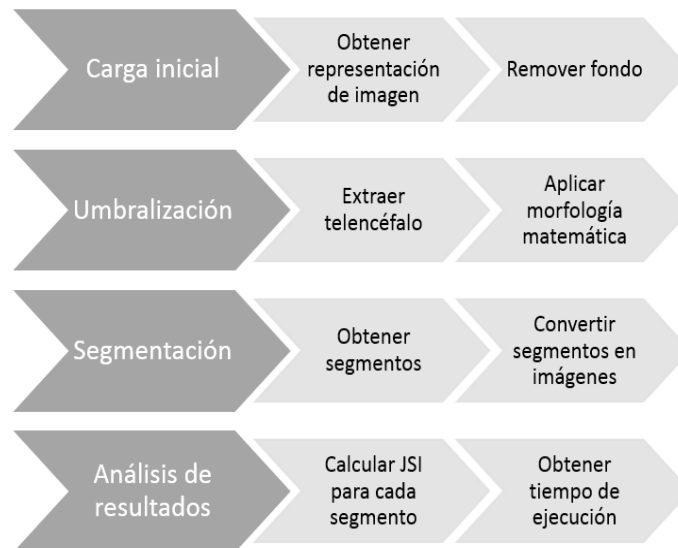


Fig. 10: Diseño del experimento

Fuente: Elaboración propia

4.4.1.1 Carga Inicial

El experimento comienza con tareas de pre-procesamiento que han sido incorporadas al Software desarrollado. Se necesita una representación adecuada de la imagen para que pueda ser recibida por el Algoritmo -una matriz numérica que almacene los valores de escala de grises- lo que es realizado en esta fase. Asimismo, el fondo negro de la imagen es removido mediante umbralización dado que no tiene valor invertir tiempo de procesamiento en esa sección de la imagen.

Las imágenes de entrada fueron obtenidas de la base de datos *BrainWeb*[7] de *Brain Imaging Centre, Montreal Neurological Institute, McGill University*. La base de datos provee a su vez resultados estándar de segmentación, que nos servirán como imágenes de referencia para analizar la calidad del algoritmo propuesto de manera cuantitativa. Una imagen como la Figura 11. es la que usamos como valor de entrada para el algoritmo:

Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales basado en Colonias de Hormigas Artificiales




Fig. 11: Resonancia magnética cerebral de BrainWeb
Fuente: BrainWeb [7]

4.4.1.2 Umbralización

El procedimiento de carga inicial servirá de entrada al Algoritmo de Umbralización, cuya labor será separar el telencéfalo -la región de interés- de las secciones correspondientes al cráneo y otros tejidos. La configuración del algoritmo de umbralización fue la siguiente:

- Longitud de ruta de píxeles = 15
- Número de iteraciones = 5
- Parámetro A de Cálculo de Costo = 500
- Parámetro B de Cálculo de Costo = 10
- Parámetro W para actualización de feromonas = 0.6
- Importancia relativa de Feromonas = 1
- Importancia relativa de Información Heurística = 5
- Ratio de evaporación = 0.5
- Número de clústeres = 2

Varios de estos valores han sido tomados de las recomendaciones de [18] y [19] y otros han sido ajustados durante la ejecución de los experimentos. Luego, el resultado del proceso de umbralización es mejorado mediante morfología matemática antes de pasar a la siguiente fase.

Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales basado en Colonias de Hormigas Artificiales


4.4.1.3 Segmentación

El telencéfalo obtenido por el proceso de umbralización sirve de entrada al procedimiento de segmentación, que es el que finalmente obtiene los segmentos correspondientes a la Materia Gris, Materia Blanca y Líquido Cefalorraquídeo. El algoritmo fue ejecutado con la siguiente configuración:

- Número de iteraciones = 5
- Importancia relativa de Feromonas = 1
- Importancia relativa de Información Heurística = -2
- Ratio de evaporación = 0.7
- Número de clústeres = 3
- Probabilidad de mejor elección = 0.9
- Parámetro de medición de contigüidad = 0.5
- Valor máximo de feromona = 0.033
- Valor mínimo de feromona = 0.007
- Número de hormigas = 10

Varios de estos valores han sido tomados de las recomendaciones de [16] y otros han sido ajustados durante la ejecución de experimentos cuyos resultados están contenidos en el Anexo I. Una vez determinados los segmentos es necesario generar las imágenes correspondientes a cada segmento, lo que produjo las imágenes mostradas en la Figura 12.

*Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales
basado en Colonias de Hormigas Artificiales*




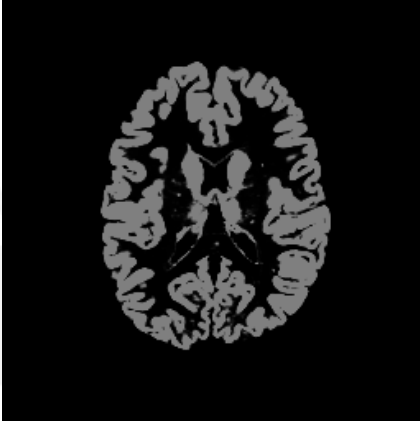
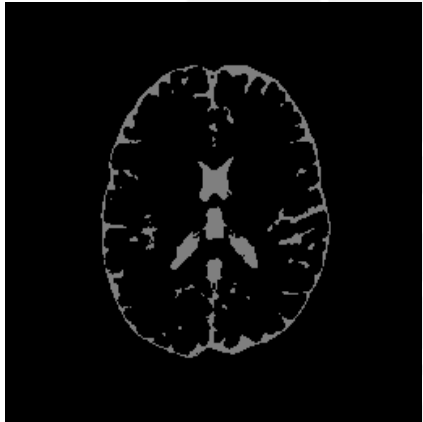
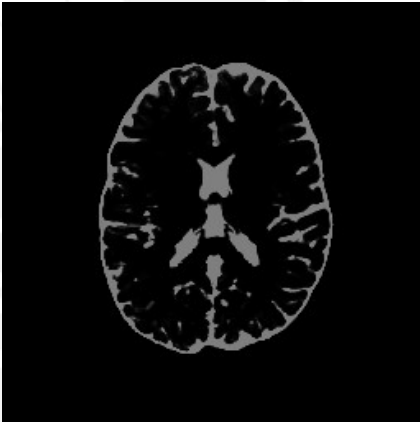
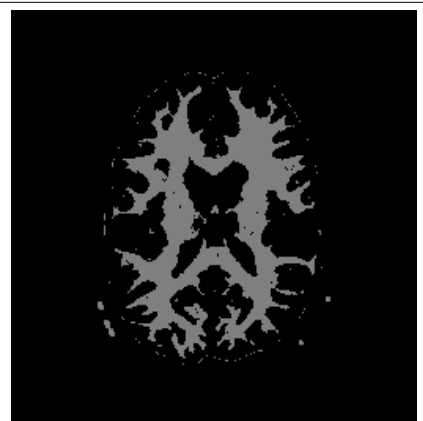
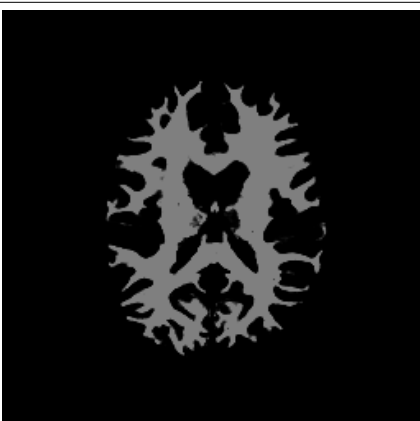
*Fig. 12: Segmentos obtenidos por el Algoritmo propuesto
Fuente: Elaboración propia*

4.4.1.4 Análisis de Resultados

Son dos las principales métricas que el experimento busca obtener. La primera es el tiempo de segmentación, que es medido por el Software construido desde el inicio del proceso hasta que los segmentos son producidos. Para la configuración descrita, se obtuvo un tiempo de segmentación de aproximadamente 300 segundos.

Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales basado en Colonias de Hormigas Artificiales

La segunda métrica a obtener es la calidad de la segmentación producida. Para evaluar el desempeño del algoritmo compararemos los segmentos producidos por el algoritmo contra los segmentos de referencia contenidos en la base de datos, como lo muestra la Tabla 1.

Segmento producido	Segmento de referencia
	
	
	

Tab. 1: Segmentos producidos versus. Segmentos de referencia
Fuente: Creación propia

*Capítulo 4. Un procedimiento para segmentar resonancias magnéticas cerebrales
basado en Colonias de Hormigas Artificiales*

Para cada producto de segmentación se utilizó el índice de similitud de Jaccard (JSI, por sus siglas en inglés) -usado también en [3]- para evaluar los resultados. El índice de similitud de Jaccard es un método estadístico para comparar similitud y diversidad entre conjuntos de datos, y se define como el tamaño de la intersección dividido entre el tamaño de la unión de los conjuntos de datos como en (14):

$$J(S_1, S_2) = \frac{|S_1 \cap S_2|}{|S_1 \cup S_2|} \quad (14)$$

Donde S_1 es un píxel del resultado de segmentación de algún algoritmo de prueba y S_2 es un píxel de la imagen de referencia de la Base de Datos. Valores del índice cercanos a 1 aseguran que la segmentación se aproxima más al estándar de referencia. Los experimentos arrojan los resultados de la Tabla 2:

Segmento	JSI
Líquido cefalorraquídeo	0.87
Materia Gris	0.93
Materia Blanca	0.93

Tab. 2: Resultados de las pruebas
Fuente: Creación propia

Se observan niveles de similitud cercanos a 0.9 en los tres segmentos, notándose un menor desempeño para el segmento correspondiente al líquido cefalorraquídeo. Los resultados de segmentación son los de la Tabla 2.

Capítulo 5

Conclusiones y Recomendaciones

En este capítulo se describen los principales hallazgos realizados como producto de la presente investigación, y mencionamos algunas recomendaciones para posibles investigaciones futuras.



5.1 Conclusiones

La segmentación de imágenes es un problema complejo. El presente trabajo buscó combinar dos algoritmos de colonia de hormigas de distintos ámbitos para segmentar resonancias electromagnéticas cerebrales, y ver la factibilidad y calidad de su aplicación. Se siguieron las premisas básicas de los algoritmos originales, que incluían asignar hormigas a píxeles y construir rutas con valores de escala de grises bajos así como el depósito de feromonas dependiendo de la calidad de la ruta obtenida en el algoritmo de Malisia; y la utilización de *Max-Min Ant System* para obtener particiones óptimas tomando en cuenta la vecindad de los píxeles en el algoritmo de Ouadfel .

El procedimiento de segmentación propuesto fue implementado en Java y el código fue liberado y puesto a disposición de la comunidad de desarrolladores. La utilización de un lenguaje con soporte al Paradigma Orientado a Objetos fue beneficiosa al ofrecer múltiples opciones de re-utilización. Los mecanismos de herencia y polimorfismo ofrecidos por Java facilitaron la implementación de la funcionalidad común entre los diversos algoritmos ACO utilizados sin necesidad de duplicidad de código.

Los resultado experimentales muestran similitudes altas para ciertos segmentos -en valores de JSI de 0.93- mientras para otros la calidad de la segmentación si bien es inferior se mantiene en niveles aceptables. Asimismo, incluso en los mejores segmentos el porcentaje de falsos negativos es alto lo que implica que varios píxeles esta siendo omitidos durante el proceso de segmentación. La calidad de los segmentos obtenidos es buena y es comparable con los algoritmos principales que sobre el mismo set de datos llegan a valores de JSI de 0.9.

5.2 Recomendaciones

Deberían explorarse otros dominios de imágenes que ofrezcan mejores condiciones para el desempeño del algoritmo propuesto, así como evaluar diversos niveles de ruido. Asimismo, debería hacerse un mayor análisis para verificar el impacto de los parámetros en la calidad de la segmentación.

Capítulo 5. Conclusiones y Recomendaciones

También, el número de clústeres/segmentos en el algoritmo actual son ingresados de forma manual. Deberían explorarse mecanismos que permitan la obtención automática y óptima de este parámetro. Asimismo, pueden realizar tareas de pre-procesamiento adicionales sobre la imagen de entrada que faciliten el proceso de segmentación.

Finalmente, no se ha explorado mucho la configuración de *K-means* para mejorar la segmentación. Podrían evaluarse parámetros que mejoren su comportamiento, o incluso evaluar la utilización de otro método de agrupamiento.



Capítulo 6

Anexos

Anexo I: Experimentos de calibración de parámetros para Algoritmo de Segmentación

Para este fin, se tomó como referencia una configuración de parámetros estándar y se procedió a modificar sólo el valor de un parámetro para evaluar su impacto en la calidad de segmentación y en el tiempo de respuesta.

Valor	Tiempo (s)	Materia Blanca JCI	Materia Gris JCI	CLF JCI	Calidad de Partición
0.9	301	0.93	0.91	0.83	11.68
0.8	280	0.91	0.90	0.80	13.27
0.7	252	0.90	0.88	0.77	15.33
0.6	218	0.88	0.86	0.73	17.66
0.5	201	0.86	0.84	0.68	20.14

Tab. 3: Probabilidad de mejor opción
Fuente: Creación propia

Valor	Tiempo (s)	Materia Blanca JCI	Materia Gris JCI	CLF JCI	Calidad de Partición
0.9	199	0.86	0.84	0.68	20.14
0.8	201	0.88	0.86	0.72	17.62
0.7	200	0.89	0.87	0.76	15.39
0.6	189	0.89	0.88	0.77	15.66
0.5	192	0.88	0.87	0.75	16.2

Tab. 4: Ratio de evaporación
Fuente: Creación propia

Valor	Tiempo (s)	Materia Blanca JCI	Materia Gris JCI	CLF JCI	Calidad de Partición
0.9	190	0.88	0.87	0.75	16.44
0.8	198	0.89	0.87	0.75	15.45
0.7	192	0.89	0.87	0.75	15.10
0.6	199	0.89	0.87	0.76	14.09
0.5	193	0.89	0.87	0.75	13.89

Tab. 5: Parámetro de medición de contigüidad
Fuente: Creación propia

Valor	Tiempo (s)	Materia Blanca JCI	Materia Gris JCI	CLF JCI	Calidad de Partición
0.03	193	0.89	0.87	0.77	13.6
0.28	192	0.89	0.86	0.74	13.8
0.023	197	0.89	0.87	0.76	13.8
0.018	200	0.89	0.85	0.75	13.8
0.013	197	0.89	0.87	0.76	13.7

Tab. 6: Valor Máximo de Feromonas
Fuente: Creación propia

Valor	Tiempo (s)	Materia Blanca JCI	Materia Gris JCI	CLF JCI	Calidad de Partición
-0.5	210	0.63	0.50	0.32	33.9
-1.0	202	0.89	0.85	0.76	13.7
-1.5	190	0.91	0.91	0.83	10.46
-2.0	193	0.92	0.92	0.85	9.36
-2.5	188	0.82	0.93	0.86	9.08

Tab. 7: Importancia relativa de Heurística
Fuente: Creación propia

Capítulo 7

Bibliografía

Esta sección contiene el material referido en el presente trabajo. El formato de cita utilizado es MLA.

1. Glasbey, Chris A, and Graham W Horgan. *Image analysis for the biological sciences*. Chichester: Wiley, 1995.
2. Raut, S.; Raghuvanshi, M.; Dharaskar, R.; Raut, A. "Image Segmentation—A State-Of-Art Survey for Prediction." *Advanced Computer Control, 2009. ICACC'09. International Conference on* 22 Jan. 2009: 420-424.
3. Huang, Peng, Huizhi Cao, and Shuqian Luo. "An artificial ant colonies approach to medical image segmentation." *Computer Methods and Programs in Biomedicine* 92.3 (2008): 267-273.
4. Cao, Huizhi, Peng Huang, and Shuqian Luo. "A novel image segmentation algorithm based on artificial ant colonies." *Medical Imaging and Informatics* (2008): 63-71.
5. Dorigo, Marco, Gianni Di Caro, and Luca M Gambardella. "Ant algorithms for discrete optimization." *Artificial life* 5.2 (1999): 137-172.
6. Chialvo, Dante R, and Mark M Millonas. "How swarms build cognitive maps." *The biology and technology of intelligent autonomous agents* (1995): 439-450.
7. BrainWeb: Simulated Brain Database." Enero 2014
<<http://www.bic.mni.mcgill.ca/brainweb/>>
8. Bankman, Isaac. *Handbook of medical image processing and analysis*. Isaac Bankman. Access Online via Elsevier, 2008.
9. Pratz, Guillem, and Lei Xing. "GPU computing in medical physics: A review." *Medical physics* 38 (2011): 2685.
10. Pham, Dzung L, Chenyang Xu, and Jerry L Prince. "Current methods in medical image segmentation 1." *Annual review of biomedical engineering* 2.1 (2000): 315-337.
11. Kennedy, James F, James Kennedy, and Russel C Eberhart. *Swarm intelligence*. Morgan Kaufmann, 2001.
12. Dorigo, Marco, Vittorio Maniezzo, and Alberto Colomi. "Ant system: optimization by a colony of cooperating agents." *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on* 26.1 (1996): 29-41.
13. Chialvo, Dante R, and Mark M Millonas. "How swarms build cognitive maps." *The biology and technology of intelligent autonomous agents* (1995): 439-450.
14. Han, Yanfang, and Pengfei Shi. "An improved ant colony algorithm for fuzzy clustering in image segmentation." *Neurocomputing* 70.4 (2007): 665-671.
15. Ouadfel, Salima, and Mohamed Batouche. "Ant colony system with local search for Markov random field image segmentation." *Image Processing, 2003. ICIP 2003. Proceedings. 2003 International Conference on* 14 Sep. 2003: I-133-6 vol. 1.

16. Ouadfel, Salima, and Mohamed Batouche. "Unsupervised image segmentation using a colony of cooperating ants." *Biologically Motivated Computer Vision* 1 Jan. 2002: 109-116.
17. Dorigo, M.; Birattari, M.; Stutzle, T., "Ant colony optimization," *Computational Intelligence Magazine, IEEE*, vol.1, no.4, pp.28,39, Nov. 2006
18. Malisia, Alice R, and Hamid R Tizhoosh. "Applying ant colony optimization to binary thresholding." *Image Processing, 2006 IEEE International Conference on* 8 Oct. 2006: 2409-2412.
19. Malisia, Alice R, and Hamid R Tizhoosh. "Image thresholding using ant colony optimization." *Computer and Robot Vision, 2006. The 3rd Canadian Conference on* 7 Jun. 2006: 26-26.
20. Mark Hall, Eibe Frank, Geoffrey Holmes, Bernhard Pfahringer, Peter Reutemann, Ian H. Witten (2009); *The WEKA Data Mining Software: An Update; SIGKDD Explorations, Volume 11, Issue 1.*
21. Stutzle, Thomas, and Holger Hoos. "MAX-MIN ant system and local search for the traveling salesman problem." *Evolutionary Computation, 1997., IEEE International Conference on* 13 Apr. 1997: 309-314.
22. Yoon, Ock-Kyung et al. "MR brain image segmentation using fuzzy clustering." *Fuzzy Systems Conference Proceedings, 1999. FUZZ-IEEE'99. 1999 IEEE International* 22 Aug. 1999: 853-857.

