UNIVERSIDAD DE MÁLAGA

E.T.S. INGENIERÍA INFORMÁTICA
UNIVERSIDAD DE MÁLAGA

ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA INFORMÁTICA
INGENIERÍA DE LA SALUD

Análisis de Otolitos de peces empleando algoritmos de segmentación de imágenes Level-set

Analysis of fish Otoliths using Level-set image segmentation algorithms

Realizado por
Fernando Reina Jiménez

Tutorizado por
Enrique Nava Baro

Departamento
Departamento de ingeniería de comunicaciones

UNIVERSIDAD DE MÁLAGA

MÁLAGA, JUNIO DE 2020

Fecha defensa: 7 de julio de 2020

Resumen

Este Trabajo de Fin de Grado consiste en la detección de contornos de Otolitos de peces en imágenes obtenidas mediante lupa digital usando técnicas de contornos activos.

Estas técnicas se ocupan de la delineación semiautomática de formas en una imagen mediante la evolución de una curva guiada por fuerzas externas e influenciada por restricciones, tratando de minimizar energías externas e internas del contorno.

Para comenzar, se realiza una introducción de la parte biológica de los Otolitos y su finalidad, así como de la obtención de imágenes de estos y su segmentación.

Posteriormente, se explica la base teórica y matemática de los contornos activos y el conjunto de métodos fundamentales para el entendimiento e implementación del algoritmo utilizado en este proyecto.

Finalmente, se analiza la implementación del algoritmo en la herramienta Matlab y los resultados obtenidos de forma que se pueda evaluar si el algoritmo ofrece los resultados esperados, mediante un estudio de fiabilidad a partir de la curva ROC.

Palabras claves: Otolitos, segmentación de imágenes, contornos activos, Level Set, curva ROC.

Abstract

This Final Degree Project consists of detecting the contours of fish Otoliths in images obtained under a digital magnifying glass using active contours techniques.

These techniques deal with the semiautomatic delineation of shapes in an image by evolving a curve guided by external forces and influenced by constrains, the treatment of reducing external and internal contours forces.

To begin, an introduction is made to the biological part of the Otoliths and their purpose, as well as obtaining images of them and their segmentation.

Subsequently, the theoretical and mathematical basis of the active controllers and the set of fundamental methods for understanding and implementing the algorithm used in this project are explained.

Finally, the implementation of the algorithm in the Matlab tool and the results obtained are analyzed so that it can be evaluated whether the algorithm offers the expected results, through a verification study based on the ROC curve.

Keywords: Otoliths, image segmentation, active contours, Level Set, ROC curve.

INDICE GENERAL

1. INTRODUCCION 7
1.1 Motivación 7
1.2 Objetivos 7
1.3 Tecnologías utilizadas 8
2. OTOLITOS DE PECES 9
2.1 Definición 9
2.2 Estructura 10
2.3 Crecimiento 12
2.4 Función 13
2.5 Finalidad 14
2.6 Obtención de imágenes 15
3. SEGMENTACIÓN DE IMÁGENES 17
3.1 Introducción 17
3.2 Definición: Segmentación de imágenes 19
3.3 Métodos de segmentación 20
4. MÉTODO DE CONTORNOS ACTIVOS 25
4.1 Métodos Level Set 30
4.1.1 Distancia de regularización de la evolución del Level Set (DRLSE) 32
4.1.1.1 Formulación de energía con regularización de la distancia 34
4.1.1.2 Aplicación del método a la segmentación de imágenes 35
4.1.1.3 Formulación de la regularización de la distancia de Level Set basado en bordes de contornos activos 36
4.1.1.4 Implementación de banda estrecha 38
4.1.2 Otros métodos Level set 40
5. ANÁLISIS DEL MÉTODO IMPLEMENTADO Y RESULTADOS 45
5.1 CURVA ROC 57
5.2 Parámetro alpha 63
5.3 Resultados obtenidos 65
5.4 Conclusión 69
5.5 Líneas futuras 71
Bibliografía 73
Anexos 75
Anexo 1. Código en Matlab 75
Anexo 2. Imágenes gold truth 81
Anexo 3. Tablas necesarias para la representación de la curva ROC 85
Anexo 4. Valores de AUC 97

INDICE DE FIGURAS

Figura 1. Esquema del oído interno. Ubicación de los otolitos en canales semicirculares. (Secor, Deany, & Laban, 1991).....9
Figura 2. Diferenciación de las bandas opacas y translucidas (Luque & Ramírez, 1996) 10
Figura 3. Otolito Sagitta (Cubillos, Aguayo, Neira, Sanhueza, & Castillo-Jordán, 2009) 11
Figura 4. Etapas del procesamiento digital de imágenes (Palomino & Concha, 2009).....18
Figura 5. Ejemplo de un algoritmo de Watershed (Palomino & Pro concepcion, 2010).....21
Figura 6. Imagen y su histograma (Palomino & Concha, 2009) 22
Figura 7. Umbralización (Palomino & Concha, 2009) 22
Figura 8.Segmentación Split and merge (División de región, s.f.).....24
Figura 9. Valores de ϕ fuera, en el límite y dentro de la región de interés. 31
Figura 10. Ejemplos de evolución de la técnica de Level set a diferentes topologías (Wu, 2019) 32
Figura 11. Todas las posiciones posibles de la curva según el modelo Chan-Vese (Mitiche & Ben Ayed, 2010) 43
Figura 12. Segmentación con DRLSE del Otolito PIL-MLG#16. Efecto del parámetro timestep con valores -2, 1, 4, respectivamente. 45
Figura 13. Segmentación con DRLSE del Otolito PIL-MLG#16. Efecto del parámetro Lambda con valores 1, 5, 10 y 50, respectivamente. 46
Figura 14. Segmentación con DRLSE del Otolito PIL-MLG#16. Efecto del parámetro alpha con valores 1, 5 y 10, respectivamente.....47
Figura 15. Segmentación con DRLSE del Otolito PIL-MLG#16. Efecto del parámetro épsilon con valores -2, 1 y 5, respectivamente.....48
Figura 16. Segmentación con DRLSE del Otolito PIL-MLG#16. Efecto del parámetro sigma con valores 0.5, 1.5 y 4, respectivamente. 49
Figura 17. Segmentación con DRLSE del Otolito PIL-MLG#16. Efecto del parámetro hsize con valores 5, 15 y 20, respectivamente. 50
Figura 18. Región definida por el Level set cero a) Un rectángulo b) Dos rectángulos fusionados 51
Figura 19. Región definida por el Level set cero a) Un rectángulo b) Dos rectángulos.....51
Figura 20. Evolución final del Level set a) Un rectángulo b) Dos rectángulos.....52
Figura 21. Evolución final del Level set a) Un rectángulo b) Dos rectángulos.....52
Figura 22. Evolución con alpha = 7 del Otolito PIL-ETP#36, donde el número de falsos negativos es demasiado grande 53
Figura 23. Segmentación con DRLSE del Otolito PIL-TBK#1. Progresión de la curva según el parámetro alpha 55
Figura 24. Imagen gold truth y contorno obtenido de la imagen con contorno real.....56
Figura 25. Índice de los canales RGB 57
Figura 26. Diferenciación de regiones (TP, TN, FP y FN).....59

Figura 27. Comparación de contornos según el valor de alpha.....60
Figura 28. Representación curva ROC.....60
Figura 29. Media del MCC de los Otolitos dependiendo del parámetro alpha.....65
Figura 30. Contorno obtenido con alpha=4 67
Figura 31. Comparación del contorno de la imagen gold truth con el contorno obtenido de la segmentación con valor alpha=4.....68

INDICE DE TABLAS

Tabla 1. Media los valores de sensibilidad y 1-especificidad en cada iteración 63
Tabla 2. Media de MCC dependiente del parámetro alpha.....64

1. INTRODUCCION

1.1 Motivación

En la actualidad, los Otolitos se han convertido, para una gran cantidad de investigadores, en una pieza clave en el estudio del reclutamiento y la dinámica de poblaciones, permitiendo estimar el grado de crecimiento, la mortalidad y demás factores que se desarrollarán más adelante.

Muchos de estos investigadores, tienen que seleccionar la región de interés (contorno real) de los Otolitos de manera manual, lo que puede dar lugar a errores en la selección, ya que, en algunas ocasiones, debido a la claridad de la imagen, de contrastes, etc…, el profesional puede cometer inexactitudes y provocar que el dibujo no sea exacto y no se adapte bien a los bordes de los Otolitos.

Con el método de contornos activos, se puede evitar estos errores, o al menos, disminuirlos en gran cantidad. El profesional o investigador, obtendrá de manera automática el contorno deseado, facilitando de manera considerable su trabajo y pudiendo ayudar al diagnóstico de este.

1.2 Objetivos

Como se ha visto en el punto anterior, el principal objetivo es encontrar de manera automática el contorno deseado en imágenes realizadas con lupa digital, mediante el método de contornos activos.

En este proyecto, se utiliza un algoritmo basado en contornos activos, el cual, se emplea para obtener de manera exacta el contorno de la forma deseada. Para ello, se cuenta con una gran cantidad de imágenes obtenidas por lupa digital, a las cuales, se les ha logrado conseguir la región de interés, la cual, se utiliza como imagen de referencia.

Para llevar a cabo el algoritmo, se realizará un estudio de este, para visualizar como le afectan los parámetros que se definen según la base matemática de estos métodos de contornos activos y como se implementa en la herramienta Matlab.

Por último, se procederá a una comparación de los resultados obtenidos, a partir del algoritmo implementado y la imagen de referencia (contorno real), mediante la curva ROC.

1.3 Tecnologías utilizadas

Este proyecto se ha desarrollado mayoritariamente con el software Matlab. Este, es un sistema de cómputo numérico que ofrece un entorno de desarrollo integrado con un lenguaje de programación propio (M). Entre sus prestaciones básicas se hallan la manipulación de matrices, la representación de datos y funciones, la implementación de algoritmos, etc…. (Mathworks, 1984-2020)

Se ha elegido este software, ya que proporciona una gran capacidad de procesamiento, análisis y visualización de imágenes, así como para el desarrollo de algoritmos gracias a la herramienta Image Processing Toolbox incluida en Matlab.

2. OTOLITOS DE PECES

2.1 Definición

En los peces teleósteos el aparato vestibular u oído interno es un órgano que forma parte del sistema sensorial relacionado con las funciones de equilibrio. Estructuralmente, el oído interno está formado por tres canales semicirculares, dentro de los cuales se ubican los otolitos. (Vanina & Vaz-dos-santos, 2015)

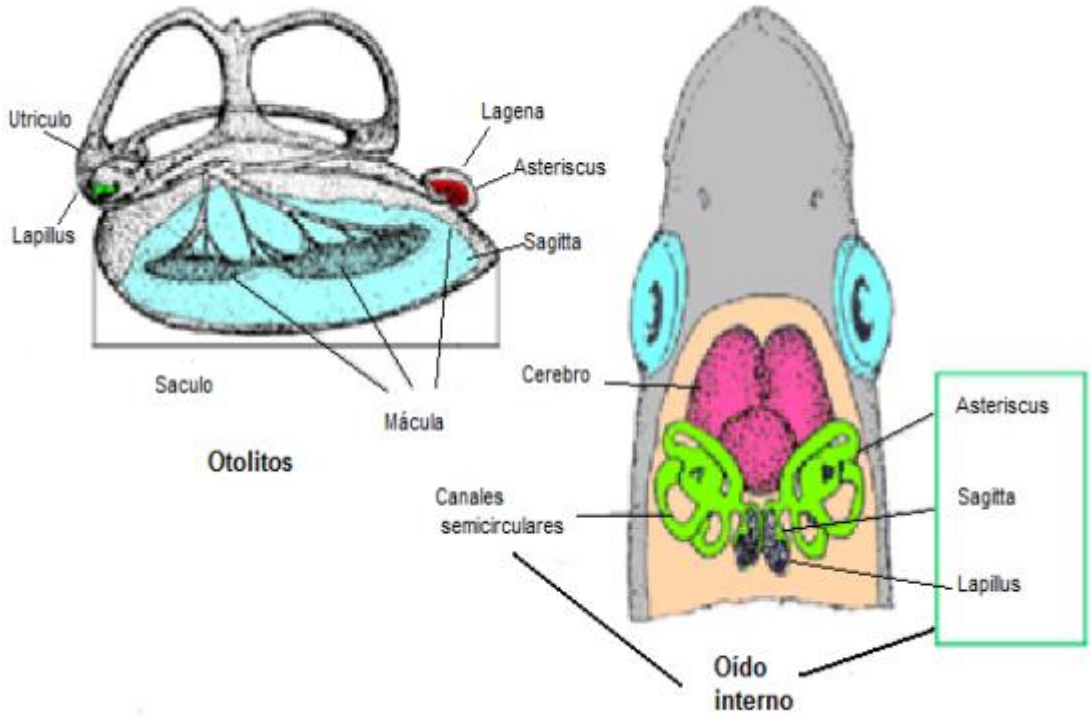

Figura 1. Esquema del oído interno. Ubicación de los otolitos en canales semicirculares. (Secor, Deany, & Laban, 1991)

Los otolitos son unas estructuras de carbonato cálcico suspendidos en una matriz proteica. Estos, poseen una morfología compleja específica de cada especie.

Existen tres pares de otolitos denominados comúnmente como Lapillus, Sagitta y Asteriscus. Estos, se encuentran, respectivamente, en el interior de unos vestíbulos otolíticos, en el aparato vestibular, denominados Utrículo, Sáculo y Lagena.

2.2 Estructura

Como se ha introducido en el apartado anterior, los otolitos son unas estructuras de carbonato de calcio en forma de piezas solidas constituidas por cristales de aragonita o vaterita dispuestos sobre una matriz formada por una proteína fibrosa llamada otolina.

La mineralización y crecimiento de los otolitos es periódica en forma de anillos concéntricos, constituidas por bandas translúcidas (hialinas), alternadas con bandas opacas o discontinuas. El otolito crece a partir de un núcleo central de materia orgánica denominado primordium. Este, carece de anillos y los cristales crecen desde él hacia el exterior del otolito en equilibrio isotópico con el agua del mar. (Luque & Ramírez, 1996)

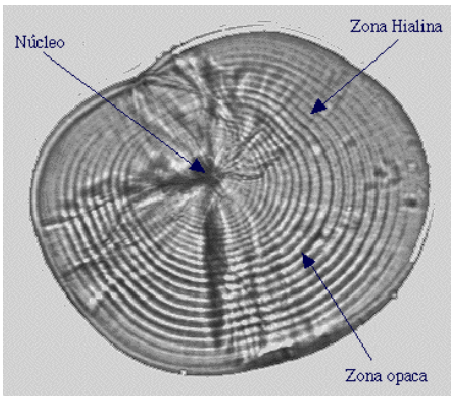

Figura 2. Diferenciación de las bandas opacas y translucidas (Luque & Ramírez, 1996)

El primer anillo, crece en un determinado tiempo comprendido entre la eclosión del huevo y el comienzo de la alimentación de la larva, dependiendo de la especie.

Acompañando al calcio, que forman los otolitos, existen otros elementos como son el estroncio, magnesio, cobre, sodio, potasio, silicio, etc. La incorporación de estos elementos químicos en los otolitos está en estrecha relación con los cambios fisiológicos en las distintas fases de desarrollo y con el medio ambiente que rodea al pez. (Luque & Ramírez, 1996)

En la mayoría de las especies de teleósteos, los otolitos Sagitta son los de mayor tamaño, por lo que, usualmente, son más utilizados para el estudio de la estructura. Estos presentan la siguiente estructura: (Vanina & Vaz-dos-santos, 2015)

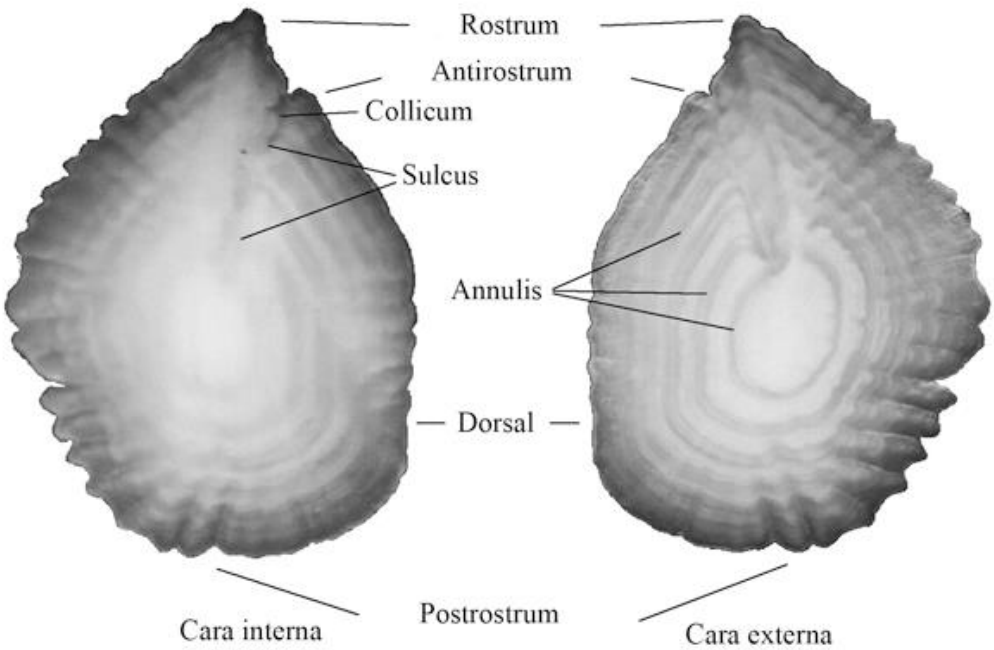

Figura 3. Otolito Sagitta (Cubillos, Aguayo, Neira, Sanhueza, & Castillo-Jordán, 2009)

- Sulcus: Depresión longitudinal que se encuentra sobre la cara interna o proximal del otolito, dividiéndolo en dos partes: región ventral y dorsal.
- Collicum: Deposito de carbonato cálcico con espesor variable, que se encuentra en la base del Sulcus.
- Rostrum: Protuberancia, generalmente aguda que se prolonga de la parte anterior del borde ventral. Se puede clasificar según su desarrollo.
- Antirostrum: Protuberancia redondeada angulosa o cónico, generalmente más pequeña que el Rostrum, situada como prolongación del borde dorsal de los otolitos.
- Postrostrum: Protuberancia de menor agudeza que se encuentra en la región posterior del otolito, contrario al Rostrum.
- Annulis: Anillo concéntrico formado con periodicidad fija. Estos anillos tienen apariencia opaca o hialina.

2.3 Crecimiento

El crecimiento del otolito es cíclico y está relacionado con el metabolismo, y sincronizado con factores ambientales externos. Numerosos investigadores han comprobado que la variación de las condiciones del medio (cambios de temperatura, alimentación, migraciones, etc…), así como los cambios en el desarrollo, modifican la estructura de los anillos de los otolitos.

En condiciones ambientales favorables, el crecimiento de los otolitos se ve favorecido, produciéndose en ellos, un incremento de las zonas hialinas (translúcidas), siendo estas más anchas que las zonas opacas, y siendo los cristales más delgados. Por el contrario, si las condiciones son adversas, el incremento es menor y los cristales más compactos.

Se ha observado, que el crecimiento de las zonas opacas está relacionado con periodos de crecimiento rápido (verano y otoño) y que las zonas hialinas se corresponden con periodos de crecimiento lento (invierno y primavera).

2.4 Función

Los otolitos, como ya hemos comentado anteriormente, se encuentran en el interior del aparato vestibular u oído interno. Estos, debido a los movimientos de la cabeza del pez, varían su posición presionando las máculas, que son unas regiones en las que existen numerosas células ciliadas bañadas por la endolinfa, el movimiento de los cilios, debido al desplazamiento de la cabeza, genera una corriente eléctrica que se transmite al cerebro a través del nervio vestibular. Gracias a esto, los peces son capaces de tener conocimiento sobre su posición, manteniendo el equilibrio y actuando como sensor de profundidad. (Vanina & Vaz-dos-santos, 2015)

El equilibrio del pez depende del ángulo de incidencia y la intensidad de la luz, por otra parte, la orientación, depende de las consecuencias de la descomposición de las fuerzas de gravedad y también, de la dirección de la luz.

Otra de las funciones de los otolitos es la detección de vibraciones, como las ondas sonoras, interviniendo estas, en la audición.

2.5 Finalidad

Conforme a todo lo expuesto anteriormente, el campo de investigación sobre la morfología, morfometría y composición de los otolitos está en pleno crecimiento y desarrollo, teniendo una gran aplicación en los estudios de reclutamiento y dinámica de poblaciones, permitiendo estimar el grado de crecimiento, mortalidad, comportamiento migratorio, etc…, en estudios de morfometría, permitiendo estimar la identificación de especies, en estudios de la microquímica, específicamente para el análisis de la biología ambiental en peces, entre otras muchas investigaciones posibles. (Luque & Ramírez, 1996)

En este proyecto se estudia, principalmente, las características morfométricas, es decir, el análisis cuantitativo de la forma de los otolitos, con las cuales, el profesional puede extraer información, como, por ejemplo, la identificación de las especies, entre otras.

La diversidad de aplicaciones de los otolitos ha propiciado la necesidad de instrumentar metodologías que desarrollen trabajos de calidad que contribuyan al mejor conocimiento de los otolitos.

Hay que resaltar, que para el análisis morfométrico de los otolitos, el empleo de nuevas técnicas de análisis de imágenes facilita el estudio de estos y ha supuesto una gran ayuda para los expertos, ya que gracias a estas nuevas técnicas es más

fácil diferenciar las características de los otolitos. Con estas nuevas técnicas se pretende facilitar el estudio de ellos.

2.6 Obtención de imágenes

En una forma general existen dos formas de extraer los otolitos: mediante un corte oblicuo de la zona dorsal del neurocráneo, o bien mediante un corte longitudinal de la zona ventral de las cápsulas óticas. (R. Leta & Keim, 1982)

La metodología de extracción de los otolitos de los peces varía de acuerdo a las especies consideradas, así como también de acuerdo al tamaño de los ejemplares.

Una vez extraídos, los otolitos se limpian del resto de tejidos y humores y se secan con un papel absorbente para su posterior preservación, lo cual facilita su manipulación en trabajos, así como su archivo dado el reducido espacio que ocupan.

En algunas especies, es importante mantener la condición de fresco de los otolitos, ya que cuando se archivan secos estos puedes pueden volverse opacos y dificultar su estudio. Normalmente, los otolitos son preservados en soluciones de glicerina (75%) y agua (25%), a las que se agrega unos cristales de timol, este último para para evitar el crecimiento de bacterias y hongos.

El grosor u opacidad de los otolitos, en algunas especies, dificulta el estudio de la estructura de los otolitos. Para ello, se han desarrollado técnicas que mejoran notoriamente su estudio, como puede ser, tinciones “in vivo” o “in vitro”, pulir una o ambas caras, extraer secciones delgadas, someterlos a calor, etc….

Una vez dispuesto el otolito, se procede a la obtención de imágenes de este, en nuestro caso, realizadas con lupa digital, algo más práctica que un microscopio, que está pensado para un mayor número de aumento.

3. SEGMENTACIÓN DE IMÁGENES

3.1 Introducción

Una imagen puede ser definida como una función bidimensional de intensidad de luz f (x, y) donde x e y representan las coordenadas espaciales y el valor de f en un punto cualquiera (x, y) es proporcional al brillo (o nivel de gris) de la imagen en ese punto. Una imagen digital es una imagen f (x, y) que se ha discretizado tanto en las coordenadas espaciales como en el brillo, y puede considerarse como una matriz cuyos índices de fila y columna identifican un punto de la imagen. El valor del correspondiente elemento de una matriz indica el nivel de gris en ese punto. Estos elementos se denominan pixel. (Palomino & Concha, 2009)

Para facilitar la interpretación, mejora y restauración de imágenes digitales existen diversas técnicas de procesamiento digital. El procesamiento permite la mejora del contraste, eliminar ruido, detección de formas, segmentación, etc. En estos dos últimos ejemplos se basa este proyecto.

El procesamiento de una imagen digital tiene varias etapas hasta llegar al resultado deseado.

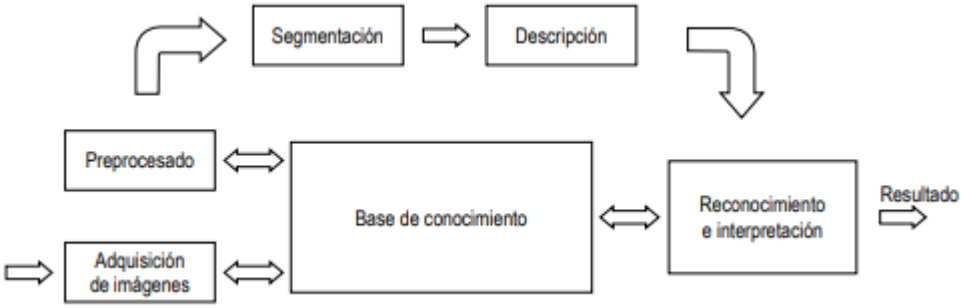

Figura 4. Etapas del procesamiento digital de imágenes (Palomino & Concha, 2009)

La primera etapa comprende la adquisición de imágenes, la cual requiere, un dispositivo para capturar el objeto y un digitalizador para la conversión a imagen digital.

La segunda etapa trata el procesado de la imagen, la cual realiza, como se ha explicado anteriormente, una mejora de la imagen detectando y eliminando las fallas encontradas.

La tercera etapa es la segmentación, la cual divide la imagen en sus partes constituyentes u objetos con el fin de separar las partes necesarias de procesamiento del resto de la imagen que no interesa de acuerdo a la aplicación que se quiera dar.

La cuarta etapa consiste en la descripción de la partes u objetos de interés segmentado en la etapa anterior.

Y, por último, la quinta etapa, la cual asigna una etiqueta al objeto segmentado según la descripción del apartado anterior.

3.2 Definición: Segmentación de imágenes

La segmentación subdivide una imagen en sus partes constituyentes con el fin de separar las partes de interés del resto de la imagen. Otra definición de la segmentación es la clasificación de los puntos de la imagen (pixeles), indicando las clases a las que pertenecen los diferentes pixeles. (Palomino & Concha, 2009)

En el proceso de detectar las partes en una imagen se identifican bordes de una imagen, o se segmenta regiones, líneas o curvas.

Los atributos básicos de segmentación de una imagen son la iluminación, los componentes en color, textura y forma.

Existen distintos tipos de métodos de segmentación de imágenes, los cuales, dependiendo de las características propias de cada imagen, pueden dar un mejor o peor resultado en la segmentación. Los algoritmos de segmentación de se basan en los siguientes principios: (Palomino & Concha, 2009)

- Discontinuidades del nivel de gris: Consiste en segmentar la imagen a partir de grandes cambios en los niveles de grises entre los pixeles. Algunas de las técnicas pertenecientes a este grupo son la detección de bordes, líneas, puntos aislados, etc.
- Similitud de niveles de gris: Métodos contrarios al anterior. En este caso, las divisiones de la imagen se hacen agrupando los pixeles según sus características similares. Algunas de las técnicas pertenecientes a este grupo son la umbralización, crecimiento de regiones, etc.

Algunas de las principales aplicaciones prácticas de la segmentación de imágenes son la localización de contornos en tumores, estudio de la estructura anatómica, localización de imágenes (teledetección), reconocimiento de huellas, etc.

3.3 Métodos de segmentación

Como se ha comentado en el apartado anterior, existen diversas técnicas de segmentación, las cuales son:

- Watershed: En el procesado de la imagen, las imágenes de niveles de grises son habitualmente consideradas como relieves topográficos. En la representación topográfica de dicha imagen, la altura de cada punto corresponde con el nivel de pixeles correspondiente. Esta representación es muy adecuada para poder percibir mejor el efecto de una determinada transformación sobre una imagen.

  El objetivo de la técnica Watershed es extraer las fronteras de las regiones que hay en una imagen. Como podemos apreciar en la siguiente imagen, el agua inundara toda la topografía de la imagen, hasta que las aguas de dos cuencas diferentes se unan y se forme líneas de unión que representan las fronteras de las regiones.

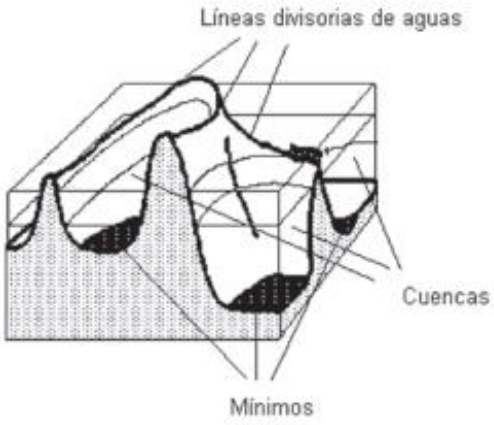

Figura 5. Ejemplo de un algoritmo de Watershed (Palomino & Pro concepcion, 2010)

La técnica de Watershed constituye una de las mejores herramientas de segmentación.

- Umbralización: Es uno de los métodos más importantes de la segmentación. Se define como una técnica que convierte una imagen con diferentes tonalidades en una imagen en blanco y negro según el umbral fijado. Es decir, si la imagen original es f(x, y), la imagen umbralizada g(x, y) se fija en un umbral U ($0 < U < 255$) de la siguiente forma: (Palomino & Concha, 2009)

$$g(x, y) = 255 \qquad \text{si } f(x, y) > \text{umbral} \tag{1}$$
$$g(x, y) = 0 \qquad \text{si } f(x, y) \leq \text{umbral}$$

Se selecciona un umbral que permita diferenciar correctamente el objeto que se desea segmentar, para ello se utiliza el histograma de la imagen, de forma que se pueda escoger el nivel de gris más conveniente.

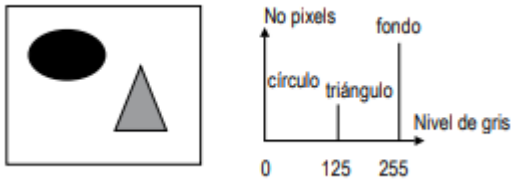

Figura 6. Imagen y su histograma (Palomino & Concha, 2009)

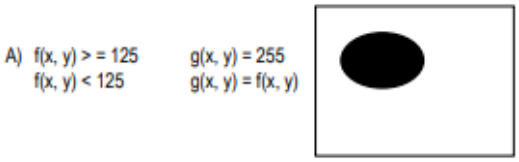

Figura 7. Umbralización (Palomino & Concha, 2009)

- Clustering: El agrupamiento o Clustering es una técnica de segmentación de imágenes para la clasificación de un conjunto de datos en subconjuntos, definidos como clusters. Cada subconjunto o cluster está definido por un centro, el cual representa un valor con características similares a los datos pertenecientes a dicho subconjunto. (Coto, 2003)

  Una de los métodos, dentro de las técnicas Clustering, que más destaca es el método K-means que consiste en fijar un número determinado de clusters y asignar en el interior de ellos nuevos cluster para recalcular nuevos cluster hasta conseguir la convergencia.

- Redes neuronales artificiales: Son redes de procesamiento inspiradas en las redes neuronales biológicas del cerebro humano. Están constituidas por elementos que se comportan de forma similar a la neurona biológica en sus

funciones comunes y organizadas de forma parecida a la que presenta el cerebro humano. Cada neurona de la red se corresponde a un pixel. (Olabe, 1998)

Las redes neuronales artificiales aprenden de la experiencia, generalizan de ejemplos previos a ejemplos nuevos, es decir, adquieren el conocimiento por medio del estudio.

La computación neuronal provee un acercamiento mayor al reconocimiento y percepción humana que los métodos tradicionales de cálculo. Este método es muy robusto frente al ruido y a las variaciones del parámetro de entrada.

- Split and merge: Es un método de segmentación que consiste en la división de la imagen en regiones uniformes, conforme a unos criterios de homogeneidad. Dependiendo de este criterio, las regiones adyacentes se fusionarán o no.

  Partiendo de una imagen inicial, esta se divide en cuatro regiones conforme a los criterios de homogeneidad establecidos. Si existe alguna subimagen que no es homogénea, se vuelve a dividir en cuatro regiones hasta que todas las regiones son homogéneas. Las regiones homogéneas se fusionan con las regiones homogéneas vecinas.

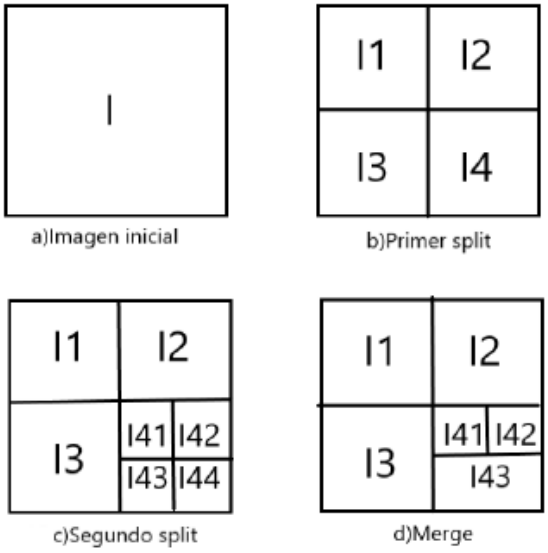

Figura 8.Segmentación Split and merge (División de región, s.f.)

- Contornos activos: Es una técnica de segmentación basada en la detección de formas, en la que, fijada una curva inicial, esta se va deformando hasta ajustarse al contorno deseado a partir de la minimización de energías externas e internas. (Mitiche & Ben Ayed, 2010)

  Sus principales ventajas son la capacidad de generar curvas suaves y cerradas asociadas a las componentes de interés dentro de la imagen, ofreciendo robustez frente al ruido y a la aparición de bordes falsos, problemas típicos de este tipo de métodos de segmentación. La principal desventaja, es su dependencia para la inicialización del proceso de contorneado, ya que se requiere la ubicación del contorno inicial lo más cercano al límite deseado.

  Este es el método que se emplea en este proyecto, el cual se explicará con más detalle en los próximos capítulos.

4. MÉTODO DE CONTORNOS ACTIVOS

El método de contornos activos o "Snakes", como se ha comentado anteriormente, se trata de un método de detección de contornos. El enfoque clásico de este se basa en deformar un contorno inicial C_0 hacia el límite del objeto detectado. La deformación se realiza tratando de minimizar lo máximo posible las energías externas e internas del contorno.

Este modelo no es capaz de manejar cambios en la topología del contorno en evolución. Por lo tanto, la topología de la curva final será la de la C_0 (curva inicial), al menos que se implementen procedimientos especiales, el cual, no es el caso.

El Snake se representa como una curva paramétrica mediante $r(s) = \big(x(s), y(s)\big), con\ s \in (0,1)$, donde la energía funcional de la curva se compone básicamente de dos componente, uno que controla la suavidad de la curva (energías internas) y otro que atrae la curva hacia el límite del objeto detectado (energías externas). Esta, puede definirse como,

$$E(C) = \alpha \int_0^1 r(s)\, ds + \beta \int_0^1 r(s) ds + \gamma \int_0^1 r(s)\, ds \qquad (2)$$

donde α, β y γ son constantes positivas reales. El parámetro α puede referirse a la energía del contorno, dado que un valor alto de este puede hacer que la curva evolucione rápidamente hacia el contorno deseado. Por otra parte, el parámetro β puede referirse a la energía de curvatura o suavidad, dado que un valor alto de este puede provocar una curva demasiado suave donde puede no detectarse

profundidades en el objeto. Estas dos energías representan la energía interna de la curva, es decir:

$$E_{INT} = E_{CONTORNO} + E_{SUAVIDAD} \quad (3)$$

Por último, el parámetro γ es el responsable de atraer el contorno hacia el objeto detectado. Un valor alto de este puede provocar que colapse y no ajustarse bien al contorno deseado. Este parámetro se corresponde con la energía externa de la curva, la cual, a su vez, está formada por dos energías denominadas de imagen y restrictivas:

$$E_{EXT} = E_{IMAGEN} + E_{RESTRICTIVAS} \quad (4)$$

Donde la energía de imagen se corresponde con las energías que atraen el Snake hacia las características relevantes de la imagen y la energía restrictiva son aquellas energías introducidas directamente por el usuario.

La energía de imagen se puede expresar como:

$$E_{IMAGEN} = V_{LIN} * E_{LIN} + V_{BORD} * E_{BORD} + V_{TERM} * E_{TERM} \quad (5)$$

Siendo V_{LIN}, V_{BORD}, V_{TERM} los pesos que se le da a la energía de línea, de borde y terminación, respectivamente. Según como se ajusten estos términos, se puede modificar el comportamiento de la Snake. (Kass, Witkin, & Terzopoulos, 1988)

La energía de línea es la intensidad de la imagen. Dependiendo del signo de V_{LIN}, el Snake se ve atraído por las líneas más claras u oscuras de la imagen.

$$E_{LIN}\big(r(s)\big) = I(x(s), y(s)) \tag{6}$$

La energía de borde permite encontrar los bordes de la imagen. Se define como:

$$E_{BORD}\big(r(s)\big) = -||\nabla I\big(x(s), y(s)\big)||^2 \tag{7}$$

Donde $\nabla I(x(s), y(s))$ es el gradiente de la imagen. El Snake se verá atraído por las zonas con mayor valor de gradiente.

Existe un pequeño problema, en el cual, la Snake puede quedar atrapada en estructuras pequeñas, como por ejemplo el ruido. Para ello, se emplea una función gaussiana de desviación estándar σ que desenfocará la imagen para eliminar las estructura de pequeña escala antes de determinar el gradiente de la imagen. La nueva ecuación de la energía de borde queda de la siguiente manera:

$$E_{BORD}\big(r(s)\big) = -|(\nabla^2 h_\sigma\big(\mathrm{x(s), y(s)}\big)) * I\big(x(s), y(s)\big)|^2 \tag{8}$$

Donde h_σ es la función gaussiana de desviación estándar σ. Si la escala σ es muy grande se desenfocará la imagen demasiado sin conseguir alcanzar el contorno perfectamente detallado. Por ello, lo que se realiza es comenzar con una gran escala y después disminuir la escala para refinar el contorneado.

La energía de terminación o de vértices parte de una imagen ligeramente suavizada

$$C(x(s), y(s)) = h_\sigma\big(\mathrm{x(s), y(s)}\big) * I\big(x(s), y(s)\big) \tag{9}$$

y se obtiene a partir del grado de curvatura de las curvas o vértices de la imagen. El grado se obtiene como:

$$\theta = tan^{-1}\left(\frac{\frac{\partial C}{\partial y}}{\frac{\partial C}{\partial x}}\right) \tag{10}$$

El vector unitario paralelo y perpendicular a la dirección de gradiente se puede calcular como:

$$n = (\cos(\theta), \sin(\theta)) \tag{11}$$

$$n \perp = (-\sin(\theta), \cos(\theta)) \tag{12}$$

A partir de estos vectores, podemos definir la energía de terminación como:

$$\mathrm{E_{TERM}} = \frac{\frac{\partial^2 \mathrm{C}}{\partial \mathrm{n}\perp}}{\frac{\partial^2 \mathrm{C}}{\partial \mathrm{n}}} \tag{13}$$

Con la energía de terminación, se mide el ángulo del gradiente. Si se produce un cambio brusco de este, la energía de terminación ha encontrado un mínimo local, al cual, la Snake se une.

Por otra parte, la energía restrictiva se puede expresar como:

$$E_{RESTRICTIVAS} = E_{MUELLE} + E_{VOLCÁN} \tag{14}$$

Donde la energía tipo muelle es equivalente a conectar un muelle desde un punto del Snake a otro punto de la imagen, atrayendo el Snake hacia el contorno. La energía o fuerza se calcula mediante:

$$E_{MUELLE} = -k(p1 - p2)^2 \tag{15}$$

donde p1 y p2 se corresponde con los puntos señalados y k es la constante de rigidez. (Kass, Witkin, & Terzopoulos, 1988)

Por último, la energía tipo volcán crea una fuerza de repulsión, alejando la Snake de una región marcada en la imagen, la cual, es el centro del volcán. La energía tipo volcán se puede expresar como:

$$E_{VOLCÁN} = 1/r \tag{16}$$

siendo r la distancia hasta el centro del volcán. (Kass, Witkin, & Terzopoulos, 1988)

El método de contornos activos descrito, se denomina contornos activos paramétricos, el cual, es capaz de localizar correctamente curvas que se encuentren cerca de la curva inicial C_0. Sin embargo, los términos de regularidad ($\alpha, \beta\ y\ \gamma$) no implican que la curva extraída sea suave, ello es debido a que la regularidad de la parametrización no implica la regularidad geométrica de la curva. Por otra parte, este método no permite a la curva romperse, por lo cual, no es posible detectar varios objetos a la vez. Para evitar estos inconvenientes fueron creados los métodos de contornos activos geométricos, otro tipo de método de contornos activos.

Los modelos geométricos están basados en la evolución de las curvas por flujo geométrico. En este modelo, la curva se deforma a una velocidad que depende de los parámetros geométricos y de la adaptación de esta al contorno. La implantación matemática de este método se apoya en los proyectos de S. Osher y J. Sethian, que permite cambios en la topología de la curva y la detección de varios objetos, con lo cual queda solucionado los inconvenientes del método de contornos activos paramétricos.

Dentro de este modelo geométrico, se encuentra el método Level Set, en el cual se basa este proyecto. A continuación, se explican los fundamentos de este.

4.1 Métodos Level Set

Osher y Sethian introdujeron en 1987 el método de conjunto de nivel (Level Set) para capturar interfaces y formas dinámicas. La idea básica del método Level Set es representar un contorno como el contorno de nivel cero (zero level set), y formular el movimiento del contorno mediante la función de ajuste de nivel (LSF). Este método se utiliza en diversas aplicaciones como son la dinámica de fluidos, visión por computadora, procesamiento de imágenes, etc…. (Mitiche & Ben Ayed, 2010)

Los primeros modelos de contornos activos se formulan en términos de un contorno paramétrico $C(s,t) : [0,1]x[0,\infty) \rightarrow R^2$. La evolución de la curva se expresa como:

$$\partial C / \partial t = F * N \tag{17}$$

donde F es la función de velocidad que controla el movimiento de la curva y N es el vector normal hacia dentro de la curva. La evolución de la curva en términos parametrizados se puede convertir en términos de contorno Level Set a partir de la incorporación de la curva de nivel cero de la función de ajuste de nivel (LSF) dependiente del tiempo $\phi(x, y, t)$. Suponiendo que la LSF ϕ toma valores negativos fuera del contorno de nivel cero y positivos dentro de él, como se puede ver en la figura 9, el vector normal puede expresarse como $N = -\frac{\nabla\phi}{|\nabla\phi|}$ donde ∇ es el gradiente (Osher y Sethian, 1987). Por lo tanto, la ecuación de la evolución de la curva se convierte en:

$$\partial\phi/_{\partial t} = F|\nabla\phi| \tag{18}$$

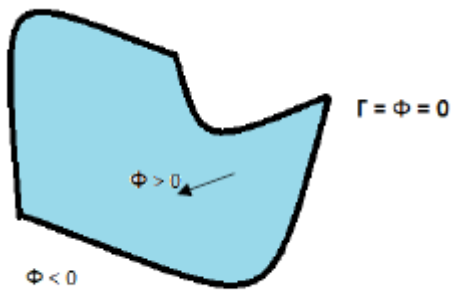

Figura 9. Valores de ϕ fuera, en el límite y dentro de la región de interés.

Los métodos Level Set pueden representar contornos de topologías completas y son capaces de manejar cambios topológicos, como son la fusión y división, lo que no puede realizar los modelos de contornos activos paramétricos, como se ha comentado en el capítulo anterior. En la figura 10, se puede visualizar como, según la evolución

del Level Set las curvas cerradas se dividen o unen. Esto, son los llamados cambios topológicos nombrados anteriormente. También, con este método, es fácil acceder a la región deseada de la segmentación ya que el signo de ϕ determina que puntos entran dentro y fuera del contorno. (Mitiche & Ben Ayed, 2010)

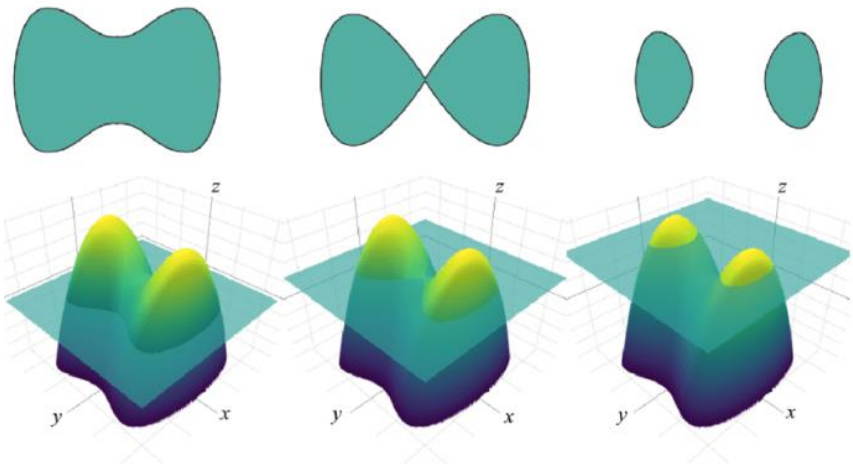

Figura 10. Ejemplos de evolución de la técnica de Level set a diferentes topologías (Wu, 2019)

4.1.1 Distancia de regularización de la evolución del Level Set (DRLSE)

Como se ha comentado anteriormente, los métodos de conjuntos de niveles se han utilizado en el procesamiento de imágenes, visión por computadora, etc…, ya que pueden representar contornos complejos y adaptarse a cambios topológicos, pero la función de conjunto de niveles desarrolla irregularidades durante su evolución, lo que puede causar errores numéricos y destruir la estabilidad de la evolución. Para ello, existe una solución llamada reinicialización (Ecuación 19) para reemplazar periódicamente la función de ajuste de nivel degradado con una función de distancia con signo. Sin embargo, la reinicialización plantea serios problemas como cuando y

como debe de realizarse, además de que afecta a la precisión numérica. (Li, Xu, Gui, & D. Fox, 2010)

$$\partial\phi/_{\partial t} = sign(\psi)(1 - \nabla\phi) \tag{19}$$

Chumming Li, Chenyang Xu, Changfeng Gui y Martin D. Fox proponen una nueva formulación del conjunto de niveles variacional en la que la regularidad de la función de conjunto de niveles se mantiene durante la evolución. La evolución del conjunto de niveles se deriva como el flujo de gradiente que minimiza una energía funcional con un término de regularización de distancia y una energía externa que impulsa el movimiento del conjunto de niveles cero hacia las zonas deseadas.

El término de regularización de la distancia se define como una función potencial tal que la evolución del conjunto de niveles derivado tiene un efecto de difusión único hacia delante y hacia atrás, que puede mantener una forma deseada de la función del conjunto de niveles, particularmente un perfil de distancia con signo cerca del Level Set cero establecido. Esto produce un nuevo tipo de evolución Level Set llamada evolución de conjuntos de niveles con distancia regularizada (DRLSE). El efecto de esta nueva evolución elimina la necesidad de reinicializar y, por lo tanto, evitar los errores numéricos.

En este proyecto, se emplea el código de la función DRLSE implementado en Matlab por el profesor Chunming Li (Li, Image computing, 2005).

4.1.1.1 Formulación de energía con regularización de la distancia

Para $\phi: \Omega \rightarrow \mathrm{R}$ siendo Ω el dominio de la función Level Set, la energía funcional se define como:

$$\varepsilon(\phi) = \mu R_P(\phi) + \varepsilon_{ext}(\phi) \tag{20}$$

Donde $R_P(\phi)$ es el termino de regularización, $\mu > 0$ es una constante y $\varepsilon_{ext}(\phi)$ es la energía exterior que depende de datos de interés. El termino de regularización del Level Set $R_P(\phi)$ se define como:

$$R_P(\phi) \triangleq \int_\Omega p(|\nabla\phi|)dx \tag{21}$$

y es utilizado para evitar inestabilidades del método DRLSE, provocados por valores no permitidos de los parámetros del método, explicados más adelante.

p es una función potencial p: $[0, \infty) \rightarrow R$. Esta función de potencial para la regularización de distancia se define como:

$$p = p_1(s) \triangleq 0.5(s-1)^2 \tag{22}$$

Que tiene s = 1 como punto mínimo único. Con este potencial $p = p_1(s)$, el termino de regularización Level Set $R_P(\phi)$ puede expresarse como:

$$P(\phi) = {}^{1}/_{2} \int_{\Omega} (|\nabla\phi| - 1)^2 dx \tag{23}$$

Que caracteriza la desviación ϕ con una función de distancia de signo. Sin embargo, la evolución del Level Set derivado para la minimización de energía tiene un efecto no deseado en la función Level set. Para evitar este efecto, introducimos una nueva función potencial p en el término de regularización de distancia R_p. Esta nueva función potencial tiene como objetivo mantener la propiedad de distancia con signo $|\nabla\phi| = 1$ en las zonas vecinas al Level Set cero, mientras se mantiene el LSF como una constante, con $|\nabla\phi| = 0$ en zonas alejadas del Level Set cero. Para mantener dicho perfil de la LSF, la función potencial p debe tener puntos mínimos en s = 1 y s = 0. Tal potencial es un potencial de doble fondo ya que tiene dos puntos mínimos. El uso del potencial de doble fondo p = p_2 evita el efecto no deseado que ocurre con p = p_1. La función p_2 se define como:

$$p_2(s) = {}^{1}/_{4\pi^2}(1 - \cos(2\pi s)), \qquad si\ s \leq 1 \tag{24}$$
$$p_2(s) = {}^{1}/_{2}(s-1)^2, \qquad si\ s \geq 1$$

4.1.1.2 Aplicación del método a la segmentación de imágenes

La formulación general de DRLSE se puede utilizar en diversas aplicaciones con diferentes definiciones de la energía externa. Para las aplicaciones de segmentación de imágenes, incluida la formación de imágenes basada en regiones o bordes, se puede usar para definir la energía externa.

4.1.1.3 Formulación de la regularización de la distancia de Level Set basado en bordes de contornos activos.

Sea una imagen en un dominio Ω, definimos una función de indicador de borde g por:

$$g \triangleq {}^{1}/_{1+\ |\nabla G_\sigma * I|^2} \tag{25}$$

Donde G_σ es un núcleo gaussiano con una desviación estándar. La convolución se utiliza para suavizar la imagen y reducir el ruido. Esta función generalmente toma valores pequeños en los límites de los objetos (bordes) que en otras zonas.

Para una función Level Set $\phi: \Omega \to R$, definimos una energía funcional $\xi(\phi)$ por:

$$\xi(\phi) = \mu R_P(\phi) + \lambda \mathcal{L}_g(\phi) + \alpha A_g(\phi) \tag{26}$$

Donde $\lambda > 0$ y $\alpha \in R$ son los coeficientes de los funcionales de energía $\mathcal{L}_g(\phi)$ y $A_g(\phi)$, que están definidos por:

$$\mathcal{L}_g(\phi) \triangleq \int_\Omega g\delta(\phi)\nabla\phi dx \tag{27}$$

$$A_g(\phi) \triangleq \int_\Omega gH(-\phi)dx \tag{28}$$

Donde δ y H son la función Delta de Dirac y la función Heaviside, respectivamente. Con la función delta δ de Dirac, la energía $\mathcal{L}_g(\phi)$ calcula la integral de línea de la función g a lo largo del contorno de nivel cero de ϕ. Al parametrizar el conjunto de nivel cero de ϕ como un contorno $C: [0,1] \to \Omega$, la energía $\mathcal{L}_g(\phi)$ puede expresarse como una línea integral una línea integral $\int_0^1 g\big(C(s)\big)|C'(s)ds$. La energía $\mathcal{L}_g(\phi)$ se minimiza cuando el contorno de nivel cero ϕ se encuentra en los bordes del objeto.

La energía funcional $A_g(\phi)$ calcula el área ponderada de la región $\Omega_\phi^- \triangleq \{x: \phi(x) < 0\}$. Esta energía se introduce $A_g(\phi)$ para acelerar el movimiento del contorno de nivel cero en el proceso de evolución hacia el contorno deseado.

Usando una LSF (función Level Set) que toma valores negativos dentro del contorno de nivel cero y positivos fuera, en este caso, si el contorno inicial se coloca se coloca fuera del objeto a segmentar, el coeficiente α debe de ser positivo, de modo que el contorno de nivel cero pueda reducirse en la evolución. En caso de, colocarse el contorno inicial en el interior del objeto, el coeficiente α debe de ser negativo.

A partir de lo explicado, se puede ver como $A_g(\phi)$ sirve para reducir la reducción o expansión del contorno de nivel cero.

En la práctica, la función delta de Dirac y la función Heaviside en los funcionales $\mathcal{L}_g(\phi)$ y $A_g(\phi)$ se aproximan mediante las siguientes funciones suaves δ_ε y H_ε, definidas como:

$$\delta_\varepsilon(x) = {}^{1}/_{2\varepsilon}\,[1 + \cos({}^{\pi x}/_{\varepsilon})] \qquad si\ x \leq \varepsilon \tag{29}$$
$$\delta_\varepsilon(x) = 0 \qquad si\ x > \varepsilon$$

$$H_\varepsilon(x) = {}^1/_2\left(1 + \frac{x}{\varepsilon} + \frac{1}{\pi}\sin({}^{\pi x}/_{\varepsilon})\right) \qquad si\ x \leq \varepsilon \tag{30}$$
$$H_\varepsilon(x) = 1 \qquad si\ x > \varepsilon$$
$$H_\varepsilon(x) = 0 \qquad si\ x < -\varepsilon$$

Sustituyendo estas dos ecuaciones anteriores en la ecuación 26, obtenemos:

$$\xi(\phi) = \mu \int_\Omega p(|\nabla\phi)dx + \lambda \int_\Omega g\delta_\varepsilon(\phi)|\nabla\phi dx + \alpha \int_\Omega gH_\varepsilon(-\phi)dx \tag{31}$$

Esta energía funcional se puede minimizar resolviendo el siguiente flujo de gradiente:

$$\frac{\partial\phi}{\partial t} = \mu div(d_P(\nabla\phi|)\nabla\phi) + \lambda\delta_\varepsilon(\phi)div\left(g\frac{\nabla\phi}{\nabla\phi|}\right) + \alpha g\delta_\varepsilon(\phi) \tag{32}$$

dado un LSF inicial $\phi(x,0) = \phi_0(x)$. El primer término de la ecuación anterior (32) está relacionado con la energía de regularización de la distancia $R_P(\phi)$ y el segundo y tercer término están relacionados con los términos de energía $\mathcal{L}_g(\phi)$ y $A_g(\phi)$, respectivamente. La ecuación es un modelo de contorno activo geométrico basado en bordes, que es una aplicación de la formulación general DRLSE.

4.1.1.4 Implementación de banda estrecha

El costo computacional de un método Level Set se puede reducir en gran medida gracias a la implementación de banda estrecha alrededor del Level Set cero. La implementación de banda estrecha requiere reinicialización, agregando más sofisticación en la implementación.

Para el método DRLSE, no se necesitan procesos de reinicialización ni extensión de velocidad en la implementación de banda estrecha debido al efecto de la regularización de la distancia comentado anteriormente. Por lo tanto, la implementación de banda estrecha de DRLSE es simple y directa, en la que el proceso de iteración solo consiste en actualizar el LSF para reducir significativamente el número de iteraciones y el tiempo de cálculo.

Se define por $\phi_{i,j}$ como una función Level Set definido en una cuadricula, y $\phi_{i-1,j}$ y $\phi_{i+1,j}$ o $\phi_{i,j-1}$ y $\phi_{i,j+1}$ al tener signos contrarios, son definidos como puntos de cruce. El conjunto de todos los puntos de cruce de cero del LSF son definidos como Z. Luego, la banda estrecha puede expresar como:

$$B_r = \bigcup_{(i,j)\epsilon Z} N_{i,j}^{(r)} \tag{33}$$

Donde $N_{i,j}^{(r)}$ es un bloque cuadrado $(2r+1)*(2r+1)$ centrado en el punto (i,j). Se establece r como un valor mínimo como r = 1, en cuyo caso la banda estrecha B_r es la unión 3x3 de los puntos de cruces cero vecinos.

La implementación de banda estrecha del DRLSE consta de los siguientes pasos:

1) Inicialización: Inicializar una LSF ϕ como una función ϕ_O. Luego, se construye la banda estrecha inicial $B_r^0 = \bigcup_{(i,j)\epsilon Z^0} N_{i,j}^{(r)}$.
2) Actualización del LSF: Actualizar $\phi_{i,j}^{k+1} = \phi_{i,j}^{k} + \tau L(\phi_{i,j}^{k})$ en la banda estrecha B_r^K.

3) Actualización de la banda estrecha: Se determina el conjunto de todos los puntos de cruces cero de $\phi_{i,j}^{k+1}$ en B_r^K, denotados como Z^{k+1}. Entonces, la banda estrecha se actualiza como:

$$B_r^{K+1} = \bigcup_{(i,j)\epsilon Z^{k+1}} N_{i,j}^{(r)} \tag{34}$$

4) Asignación de valores a los nuevos pixeles de la banda estrecha: Para cada punto (i,j) en B_r^{K+1} pero no en B_r^K, se establece $\phi_{i,j}^{k+1}$ en h si $\phi_{i,j}^{k} > 0$, o bien se establece $\phi_{i,j}^{k+1}$ en –h, donde h es una constante, que se puede establecer en r+1 como valor predeterminado.
5) Determinar la terminación de la iteración: Silo pintos de cruce cero dejan de variar durante m iteraciones consecutivas o k excede el número de iteraciones máximas, entonces se detiene la iteración, si no se detiene, se vuelve al paso 2.

4.1.2 Otros métodos Level set

El método anterior, distancia de regularización de la evolución del Level set, es el método, en el cual se basa este proyecto en su totalidad. Por otra parte, existen otros métodos también efectivos en la segmentación de imágenes como son:

1) El modelo Mumford y Shah

   Este método es el núcleo de la segmentación de imágenes variacional. Su formulación expresa la segmentación como un suavizado de imagen y

detección de bordes. Busca una aproximación suave $M: x = (x, y) \in \Omega \subset R^2 \rightarrow M(x) \in R$ de la imagen original $I: \Omega \subset R^2 \rightarrow R$ y un conjunto k de discontinuidades, para representar los límites de la imagen, minimizando lo funcional (Mitiche & Ben Ayed, 2010)

$$\mathcal{F}_{MN}(M, K) = \int_{\Omega} (I - M)^2 dx + \rho \int_{\Omega/K} ||\nabla M^2 \, dx + \lambda \rho l(K) \qquad (35)$$

Donde $\rho \, y \, \lambda$ son constante positivas, l es la longitud y $\nabla M = (M_x, M_Y) = \left(\frac{\partial M}{\partial X}, \frac{\partial M}{\partial Y}\right)$ es el gradiente espacial M.

El primer término, denominado término de datos, acerca la solución a una región cercana a la imagen observada. El segundo término, es una suavidad para una solución que varía a través de los bordes k. El último término, se relaciona con la longitud de los límites regulares.

Los algoritmos de segmentación variacional han seguido una versión simplificada de la función Mumford-Shah donde R_k es la partición determinada por k y $M(x) = M_K$, cada uno correspondiente a una aproximación constante de I dentro de la imagen.

$$\mathcal{F}_{MN}(M, K) = \sum_K \int_K (I - M_K)^2 dx + \lambda l(K) \qquad (36)$$

2) El modelo Chan-Vese

Sea $\gamma: s \in [0,1] \rightarrow x(s) = (x(s), y(s)) \in R^2$ una curva de plano cerrado parametrizada por la longitud del arco s. γ define una partición de Ω en dos

regiones $R_1 = R_\gamma$ correspondiente al interior de la curva y $R_2 = R_\gamma^C$ que corresponde al exterior. El problema consiste en encontrar una aproximación constante por parte de la imagen $I = \mu_1\ en\ R_1$; $I = \mu_2\ en\ R_2$, siguiendo la minimización con respecto a $\gamma\ y\ \mu_1, \mu_2$ de la función:

$$F_{CHAN-VESE} = \lambda_1 \int_{R1} (I - \mu_1)^2 dx + \lambda_2 \int_{R2} (I - \mu_2)^2 dx + \lambda \int_\gamma ds + v \int_{R1} dx (37)$$

Los primeros dos términos son términos de datos que miden la conformidad de la imagen dentro de cada región con el modelo constante por partes y los dos últimos términos son términos de regularización, uno mide la longitud de la curva y el otro el área de la región. Estos términos promueven la suavidad de los límites e inhiben regiones pequeñas y aisladas. λ_1, λ_2, λ y v son constantes positivas para modular la contribución de cada término.

La función Chan-Vese depende de dos tipos de variables, la curva γ y los parámetros de las regiones μ_1 y μ_2. Su minimización se puede obtener alternando dos pasos, uno para optimizar el funcionamiento con respecto a γ mediante la evolución de la curva con los parámetros fijos y el otro para determinar los parámetros óptimos con γ fijo. Los parámetros óptimos pueden calcularse analíticamente, y resultan ser las medias de muestra dentro de las regiones. El Chan-Vese funcional corresponde al modelo de Mumford-Shah de imágenes constantes por partes y partición de dos regiones. (Mitiche & Ben Ayed, 2010)

El ejemplo simple en la Figura 3.3 ilustra la relevancia de la funcionalidad Chan-Vese. La figura representa una región contra un fondo, ambos con

intensidades constantes, μ_1 y μ_2, respectivamente. Sobre todas las posiciones posibles de la curva, la suma de los términos de datos se minimiza solo cuando la curva coincide con el límite del cuadrado. Si la curva está dentro del objeto, tenemos $F_1(\gamma) = \int_{R1}(I - \mu_1)^2\, dx = 0$ y $F_2(\gamma) = \int_{R2}(I - \mu_2)^2\, dx > 0$. Si la curva está afuera, tenemos $F_1(\gamma) > 0$ y $F_2(\gamma) = 0$. Si la curva se cruza con el límite del objeto, tenemos $F_1(\gamma) > 0$ y $F_2(\gamma) > 0$. Estas tres configuraciones producen una suma estrictamente positiva de los términos de datos. Cuando la curva coincide con el límite del cuadrado, ambos términos de datos son cero.

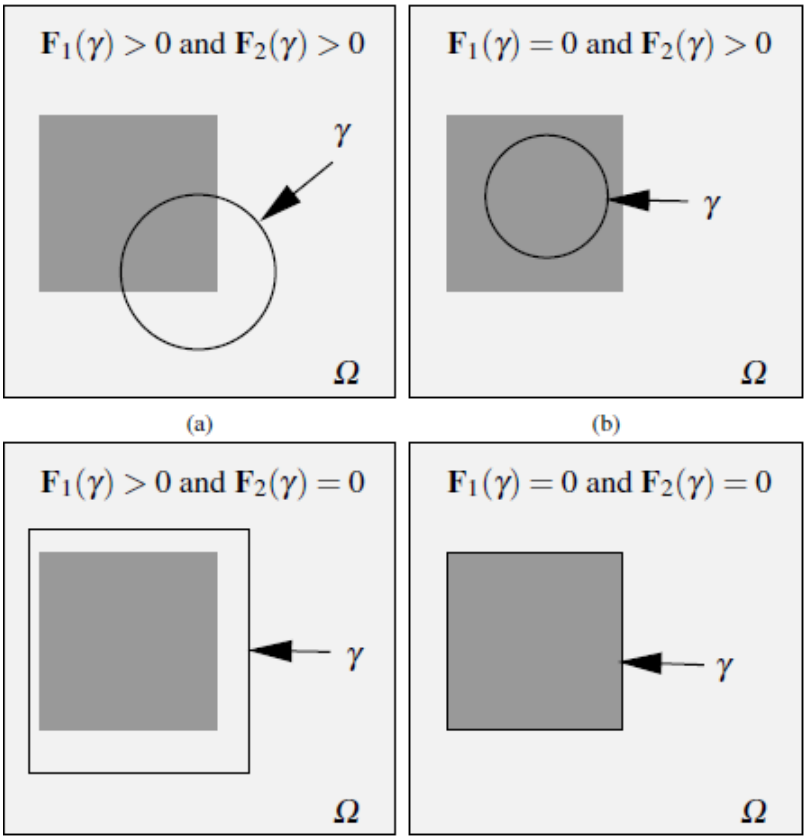

Figura 11. Todas las posiciones posibles de la curva según el modelo Chan-Vese (Mitiche & Ben Ayed, 2010)

5. ANÁLISIS DEL MÉTODO IMPLEMENTADO Y RESULTADOS

Como se ha comentado anteriormente, el método en el cual se basa este proyecto es el método de distancia de regularización de la evolución del Level set (DRLSE) (Li, Xu, Gui, & D. Fox, 2010), este ha sido implementado en Matlab por Chuning Li, cuyas variables, las cuales pueden ser de entrada o salida, son:

- Phi_0: Función Level set que se actualizará según la evolución del Level set.
- g: Función de indicador de borde. Esta toma valores pequeños en los límites del objeto.
- mu (μ): Coeficiente del término de regularización de distancia. Se encarga del suavizado de la función ϕ. Se define como 0.2/timestep.
- Timestep: Parámetro del paso del tiempo del programa.

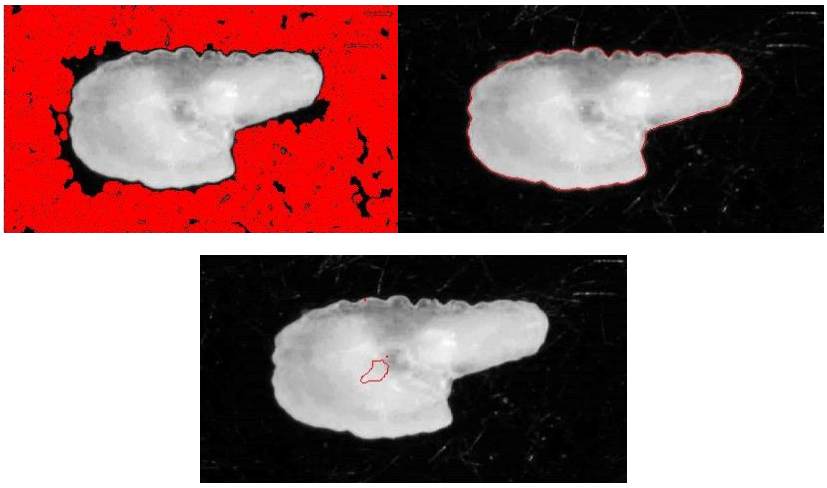

Figura 12. Segmentación con DRLSE del Otolito PIL-MLG#16. Efecto del parámetro timestep con valores -2, 1, 4, respectivamente.

Como se puede apreciar en la figura 12, el timestep no puede ser negativo, ya que puede producir que el contorno se desborde. Por otro lado, cuanto mayor sea el timestep mejor se ajustará la curva al contorno deseado, pero con valores altos se puede producir que la curva sea irregular e introducirse en el interior del objeto. Por lo tanto, el timestep debe ser un valor cercano o igual a uno.

- Lambda (λ): Coeficiente del término de longitud de la curva ponderada.

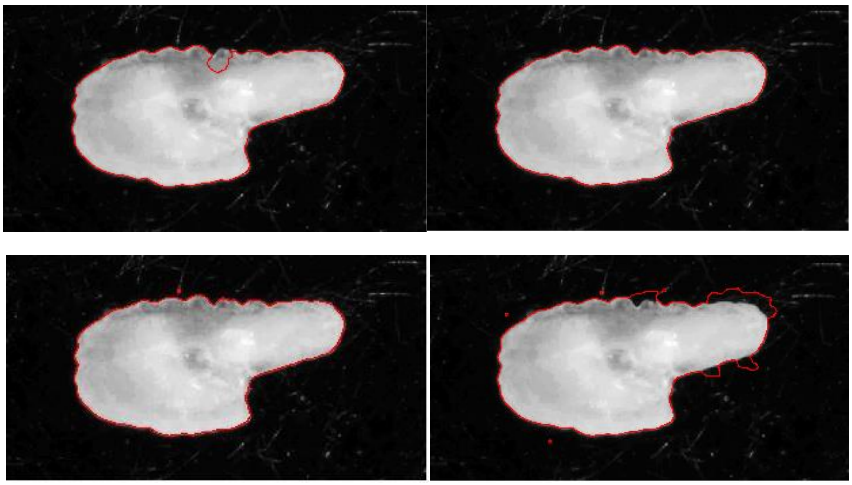

Figura 13. Segmentación con DRLSE del Otolito PIL-MLG#16. Efecto del parámetro Lambda con valores 1, 5, 10 y 50, respectivamente.

Como se puede ver en la figura 13, el parámetro lambda no influye lo suficiente en la evolución de la curva. Este, debe de ser mayor a cero y en este caso, debe ser un valor cercano o igual a 5.

- Alfa (α): Coeficiente del término del área ponderada. Este parámetro acelera la evolución de la curva cuando esta se encuentra lejos de objeto a segmentar. Su valor es positivo cuando el contorno inicial se encuentra fuera del objeto

y negativo cuando se encuentra en el interior de él. Este valor es el más influyente en la evolución de la curva ya que según su valor el contorno se ajustará más o menos a los bordes del objeto.

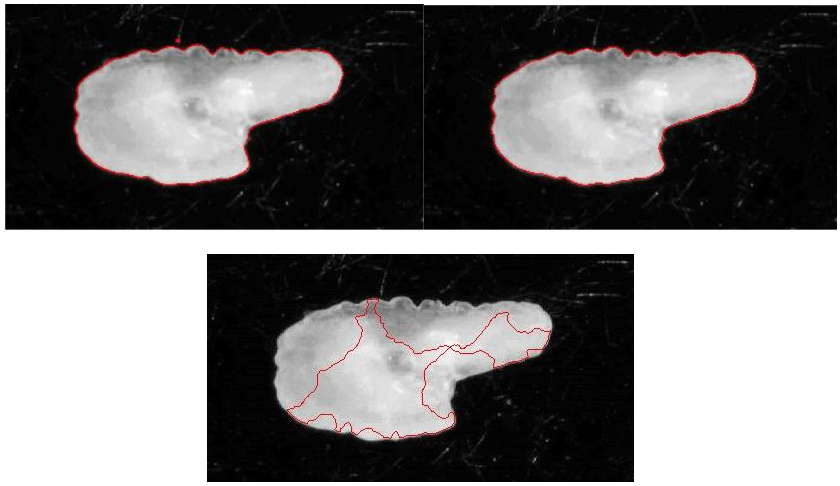

Figura 14. Segmentación con DRLSE del Otolito PIL-MLG#16. Efecto del parámetro alpha con valores 1, 5 y 10, respectivamente.

Como podemos ver en la figura 14, la elección del alpha es fundamental para una correcta adaptación de la curva al objeto. En próximos apartados se hará una explicación más detallada sobre este parámetro.

- Épsilon (ε): Ancho de la función Delta de Dirac.

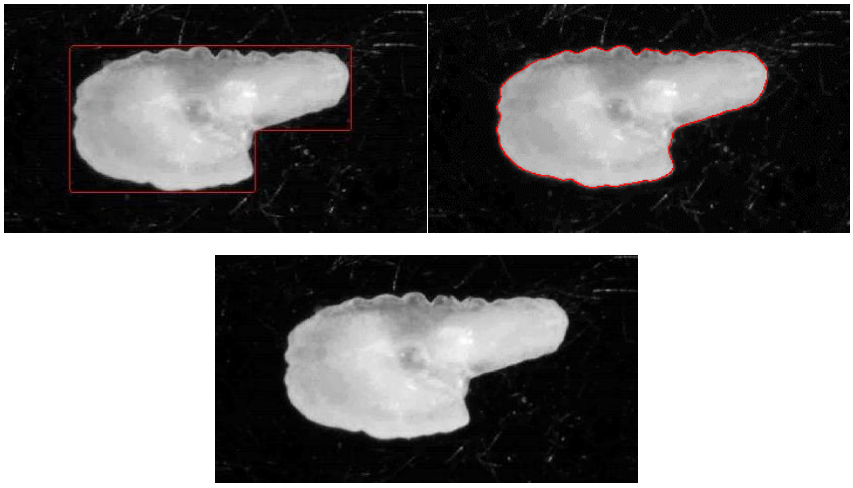

Figura 15. Segmentación con DRLSE del Otolito PIL-MLG#16. Efecto del parámetro épsilon con valores -2, 1 y 5, respectivamente.

Como se puede ver en la figura 14, este valor varia la curva bastante desapareciendo incluso cuando $\varepsilon = 5$. Este parámetro debe de tener un valor cercano o igual a uno y siempre mayor a 0.

- Iter: Numero de iteraciones. En este método existen dos tipos de iteraciones que son las iter_inner y iter_outer que son las iteraciones en el interior y exterior, respectivamente. El número de iteraciones no puede ser ni demasiado bajo ni demasiado alto, ya que un número no adecuado de estas puede provocar que la curva no se adapte lo mejor posible al objeto o hacer que colapse.

  El total de número de iteraciones es igual a $iter_{inner} * iter_{outer} + iter_{refine}$. Estas últimas iteraciones son las iteraciones de refinamiento, las cuales se fijan a diez.

- Potential Function: Elección de la función potencial en el término de distancia de regularización. Se proporcionan dos opciones, los cuales son

single-well o double-well, que corresponde a las funciones potenciales p1 (potencial único) y p2 (potencial doble), respectivamente.

- Sigma (σ): Representa la desviación estándar. Se trata de un parámetro para suavizar la imagen y controlar la sensibilidad al ruido, cuanto mayor es sigma mayor es la suavización, pero, al tener un valor alto de sigma también puede producirse que la evolución de la curva no sea la correcta y llegar a colapsar. Por lo tanto, el valor correcto de sigma es un valor cercano a 1 y siempre mayor a 0.

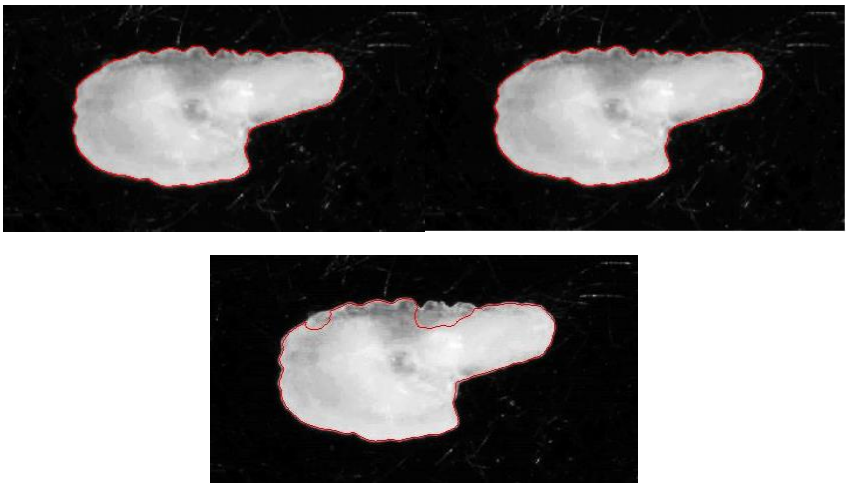

Figura 16. Segmentación con DRLSE del Otolito PIL-MLG#16. Efecto del parámetro sigma con valores 0.5, 1.5 y 4, respectivamente.

- hsize: Tamaño del filtro gaussiano. Su influencia en el resultado es mínima. Está relacionado con sigma, cuanto mayor es el valor de sigma, mayor debe de ser el valor de hsize.

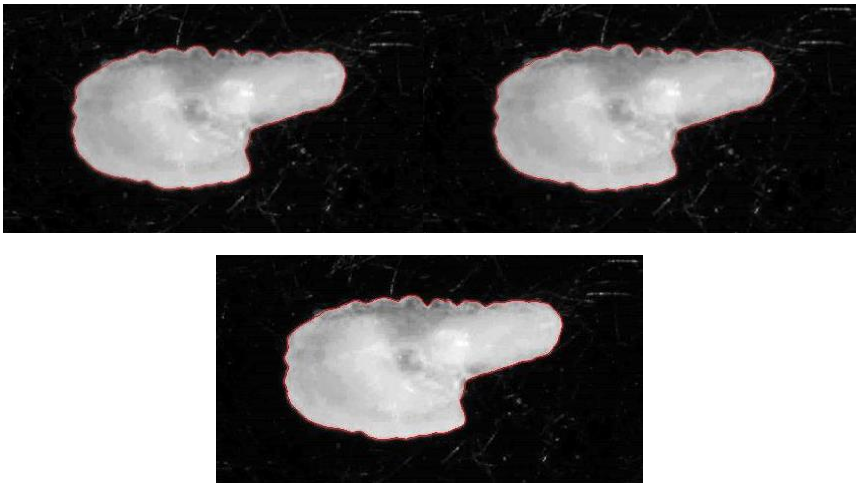

Figura 17. Segmentación con DRLSE del Otolito PIL-MLG#16. Efecto del parámetro hsize con valores 5, 15 y 20, respectivamente.

- Phy: Función Level set actualizada después de la evolución del Level set. Es la curva que se marca inicialmente y que va deformándose. Es el único parámetro de salida.

Para comenzar con la segmentación, se empieza estableciendo una región cercana al Otolito, esta debe estar lo más próxima al objeto a segmentar, debido a que si la región no se ajusta lo suficiente se pueden obtener resultados cuyos valores varían significativamente, es decir, la curva puede no ajustarse de manera correcta al contorno deseado. Para definir el contorno, se debe especificar las coordenadas x e y de los vértices del rectángulo.

Si el objeto a segmentar, en este caso el Otolito, es muy irregular, se puede establecer más de un rectángulo para que, de esta manera, se consiga un mejor ajuste al contorno deseado. Si estas regiones están lo suficientemente cerca, van a fusionarse para adaptarse mejor al contorno (figura 18b).

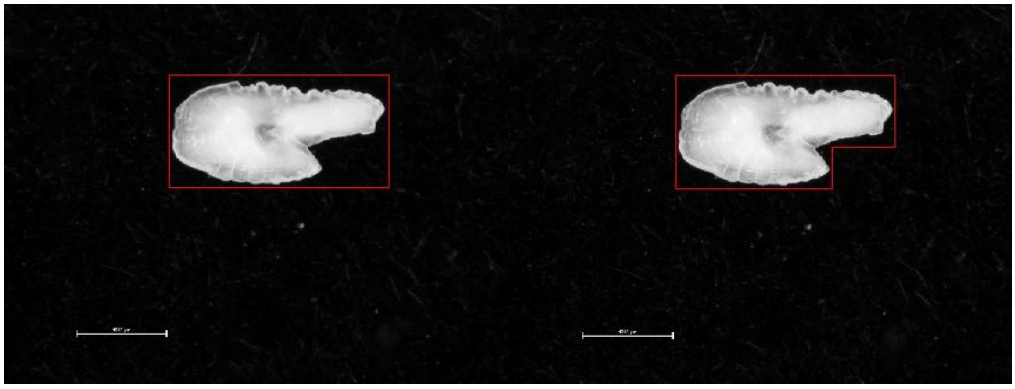

Figura 18. Región definida por el Level set cero a) Un rectángulo b) Dos rectángulos fusionados

Después, una vez que se ha definido el rectángulo o rectángulos iniciales, se puede apreciar de una manera más óptima la región definida mediante una gráfica, en la cual podemos apreciar la forma del Level set cero (figura 19).

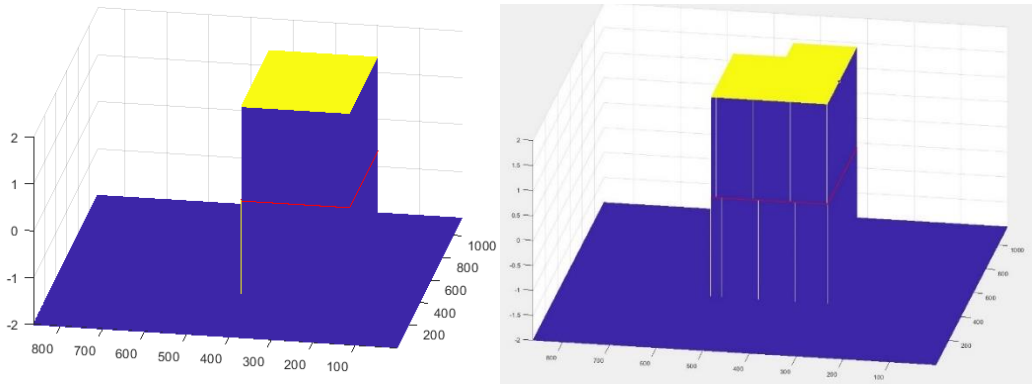

Figura 19. Región definida por el Level set cero a) Un rectángulo b) Dos rectángulos

Por último, tras realizarse por completo la segmentación, se puede apreciar cómo actúa el método DRLSE evolucionando el Level set cero hasta el contorno deseado (figura 20).

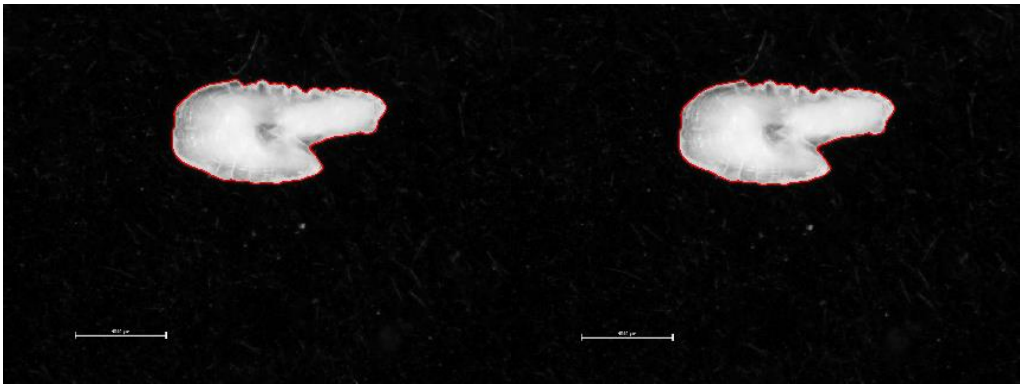

Figura 20. Evolución final del Level set a) Un rectángulo b) Dos rectángulos

Para ello, aparece una nueva gráfica (figura 21) donde se puede ver el resultado final de la segmentación.

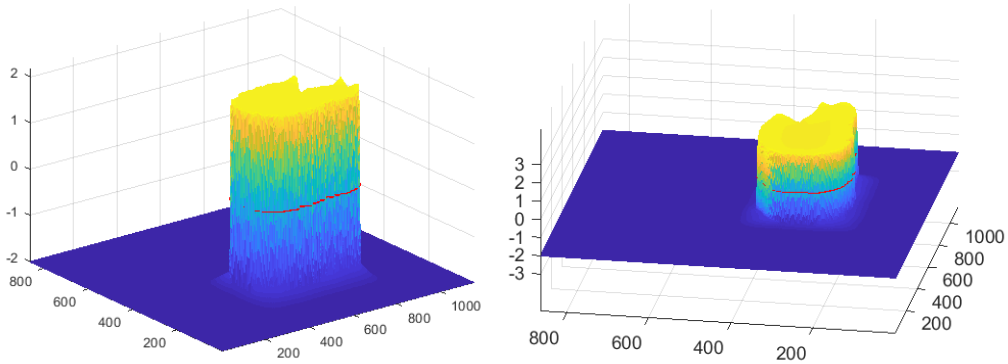

Figura 21. Evolución final del Level set a) Un rectángulo b) Dos rectángulos

En este caso, se puede apreciar, en la figura 21, como la curva se adapta algo mejor a contorno con la utilización de dos rectángulos iniciales, debido a la existencia de unos relieves pronunciados en la figura 21a, además de que, con un solo rectángulo definido, la curva no se encuentra lo más cercana posible al objeto a segmentar, pudiendo provocar resultados no exactos. Por ello, en este proyecto se ha utilizado dos rectángulos.

Para realizar la segmentación se ha realizado una variación del código DRLSE que varía el valor de alpha desde -2 a 6, obteniendo por cada valor el contorno resultante. Se ha elegido ese rango de alpha debido a que, a valores menores o superiores, respectivamente, la curva del Level set puede colapsar, además de que el número de falsos negativos, como se explicará más adelante, aumenta considerablemente (figura 22), por ello es innecesaria su representación.

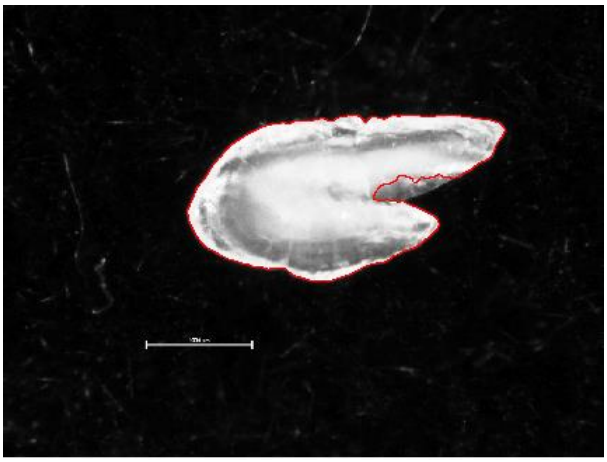

Figura 22. Evolución con alpha = 7 del Otolito PIL-ETP#36, donde el número de falsos negativos es demasiado grande

En este código se ha variado el valor de alpha, debido a que es el valor más influyente sobre la curva Level set. Para los demás parámetros del código, explicados anteriormente, se establecen los siguientes valores fijos:

- $timestep = 1$
- $mu = 0.2/timestep$
- $iter_{inner} = 50$
- $iter_{outer} = 20$
- $epsilon = 1.5$
- $sigma = 1.5$
- $lambda = 5$
- $hsize = 20$

A estos parámetros del código DRLSE, se les establece un valor fijo ya que no son tan influyentes en la curva como el parámetro alpha.

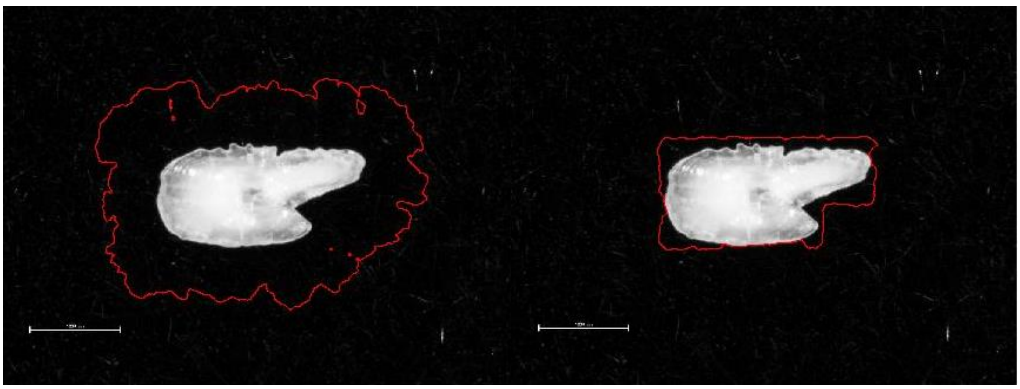

$alpha = -2$ $alpha = -1$

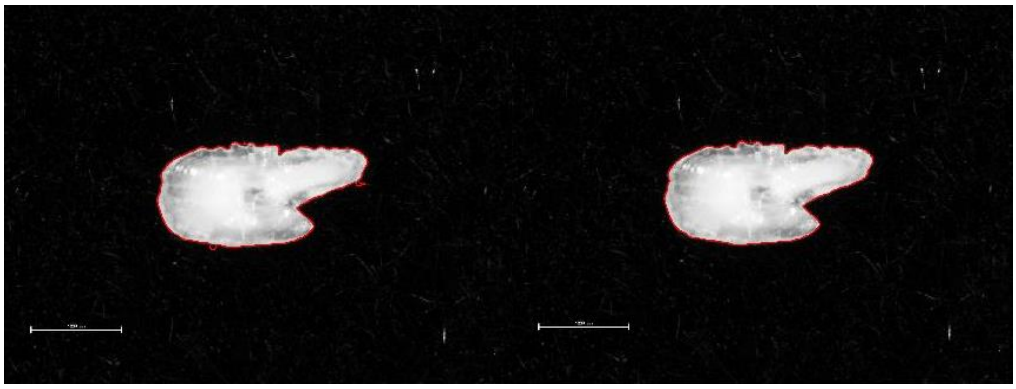

$alpha = 0$ $alpha = 1$

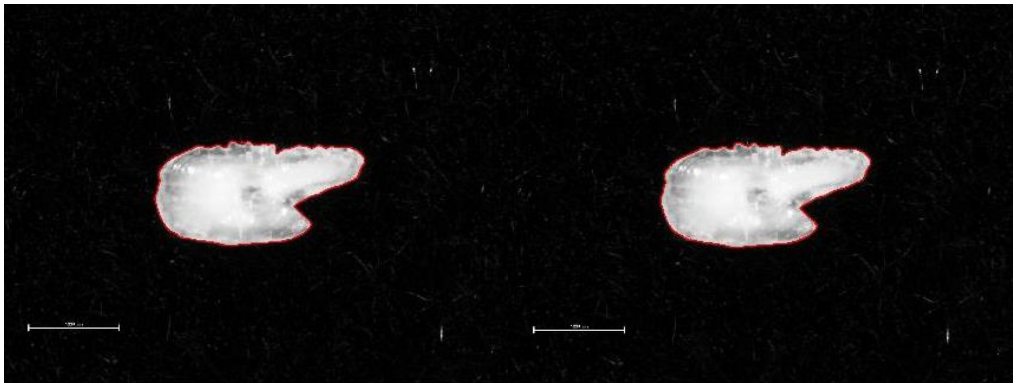

$alpha = 2$ $alpha = 3$

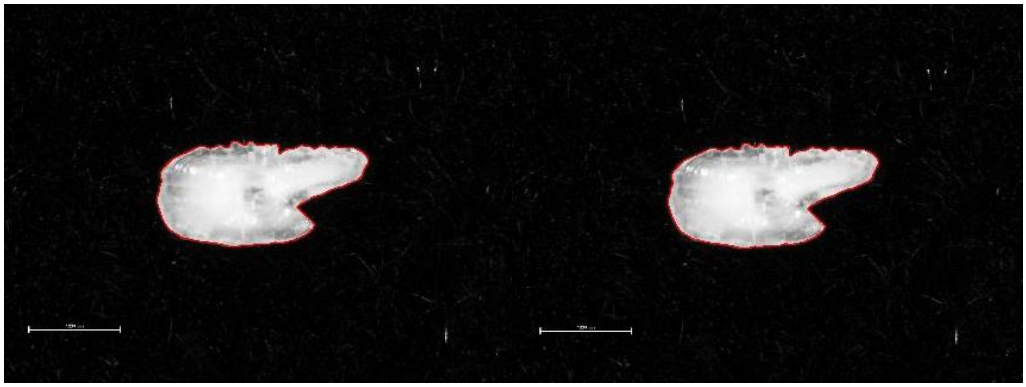

$alpha = 4$ $alpha = 5$

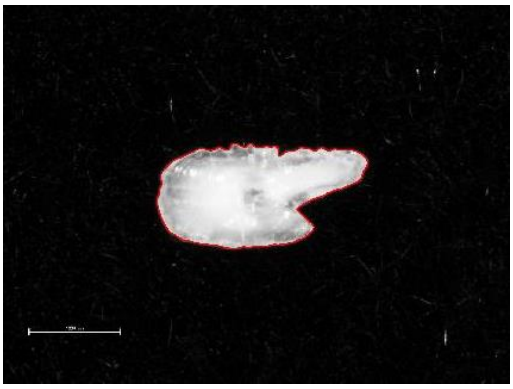

$alpha = 6$

Figura 23. Segmentación con DRLSE del Otolito PIL-TBK#1. Progresión de la curva según el parámetro alpha

Las diferencias de los contornos obtenidos en la figura 23 se aprecian bastante mejor en la tabla del otolito indicado, situada en el Anexo 3. Además, a valores de alpha negativos, la región inicial debe de estar situada en el interior del objeto a segmentar, el cual, no es el caso.

Una vez detectado el contorno del otolito, se requiere comparar con la imagen que contiene el contorno real. Para ello, se ha separado el contorno de la imagen con contorno real mediante el uso de los canales RGB.

La imagen con el contorno real se ha obtenido mediante el programa Photoshop, debido a que no se dispone de una librería con imágenes gold truth (con contornos reales) proporcionadas por expertos. Por ello, con el programa Photoshop se ha obtenido el contorno de unas 25 imágenes de otolitos y se han establecido como imágenes gold truth.

Como se ha comentado anteriormente, se ha separado el contorno de la imagen gold truth mediante los canales RGB. Estas imágenes presentan tres canales: rojo, verde y azul. En este caso, el contorno es de color verde y difiere con respecto al resto de colores de la imagen, pero difiere en distintos valores de los canales RGB. Conforme a lo comentado, se puede separar el contorno de la imagen con contorno real del resto de la imagen. En la figura 24 se puede ver un ejemplo de ello.

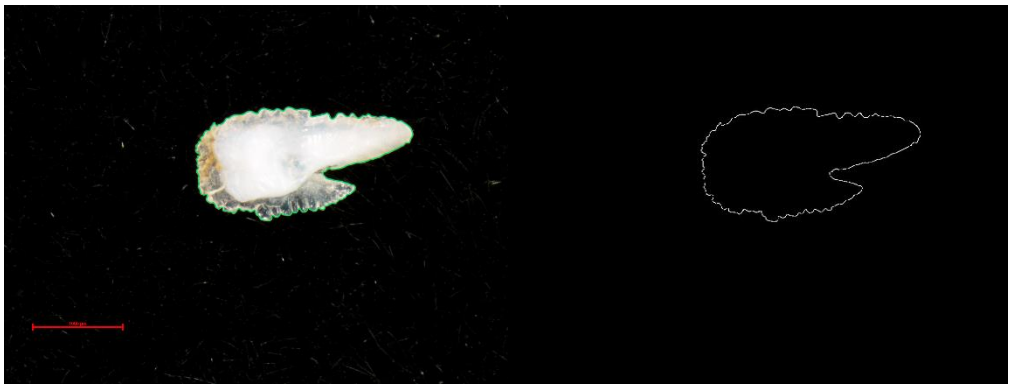

Figura 24. Imagen gold truth y contorno obtenido de la imagen con contorno real

Observando la figura 24, se puede apreciar la imagen binarizada del contorno obtenido de la imagen con contorno real. Para ello se ha establecido, como se ver

en la figura 25, la condición de que cualquier pixel con $R < 125, G > 210$ y $B < 125$ sea 1 (blanco), y en caso contrario 0 (negro). De esta manera, solo se obtiene el contorno de la imagen gold truth.

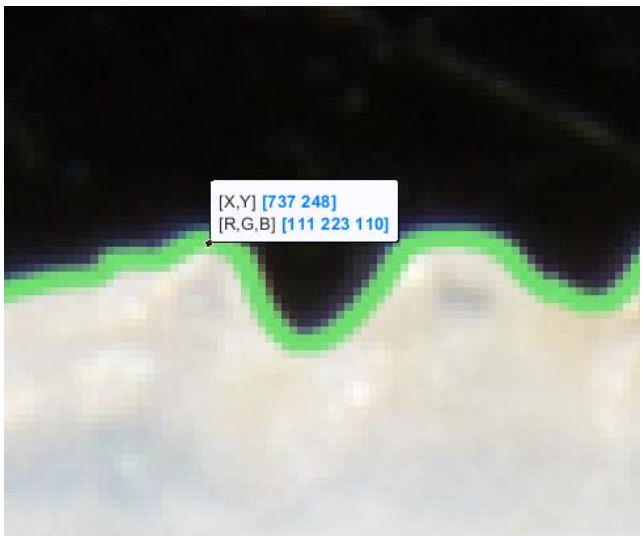

Figura 25. Índice de los canales RGB

Aplicando lo explicado anteriormente, se obtiene una imagen binarizada en la que se aprecia el contorno de la imagen gold truth. Una vez se obtiene el contorno de la imagen gold truth, se compara con el contorno obtenido de la segmentación. Para ello, se emplea la curva ROC.

5.1 CURVA ROC

La curva ROC se utiliza para evaluar cuantitativamente los resultados obtenidos de un algoritmo. En este caso, sirve para indicar la similitud existente entre el contorno de la imagen con contorno real y el contorno obtenido en la segmentación.

Para indicar el grado de similitud existen cuatro parámetros que clasifican los pixeles de las imágenes comparadas. Estos, son:

- Verdaderos positivos (TP): Son aquellos pixeles que coinciden tanto dentro de la región del contorno de la imagen gold truth como dentro del contorno obtenido.
- Verdaderos negativos (TN): Son aquellos pixeles que quedan fuera tanto de la región del contorno de la imagen gold truth como de la región del contorno obtenido en la segmentación.
- Falsos positivos (FP): Son aquellos pixeles que se encuentran dentro de la región del contorno obtenido en la segmentación, pero no se localizan en el interior del contorno de la imagen con contorno real.
- Falsos negativos (FN): Son aquellos pixeles que se encuentran en el interior del contorno de la imagen con contorno real, pero no en el interior del contorno obtenido.

Una vez comparadas las imágenes, se obtiene las regiones pertenecientes a los parámetros anteriores (TP, TN, FP y FN). A partir de los valores de los parámetros, se puede calcular la sensibilidad y especificidad, mediante las cuales se puede dibujar la curva ROC (sensibilidad respecto a 1 - especificidad). La sensibilidad es la razón de verdaderos positivos y la especificidad es la razón de verdaderos negativos y se calculan como:

$$sensibilidad = \frac{TP}{(TP+FN)} \tag{37}$$

$$especificidad = \frac{TN}{(TN+FP)} \tag{38}$$

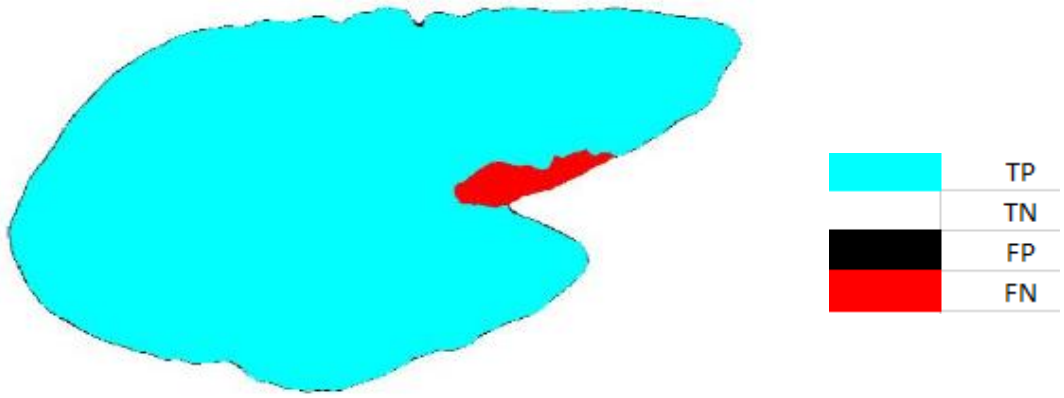

Figura 26. Diferenciación de regiones (TP, TN, FP y FN).

Como se puede apreciar en la figura 26, los verdaderos positivos son aquellas regiones en color azul celeste, los verdaderos negativos son las regiones de color blanco, los falsos positivos de color negro y los falsos negativos de color rojo.

A continuación, se muestra un ejemplo de la evolución del contorno para cada valor de alpha según el ejemplo de la figura 26.

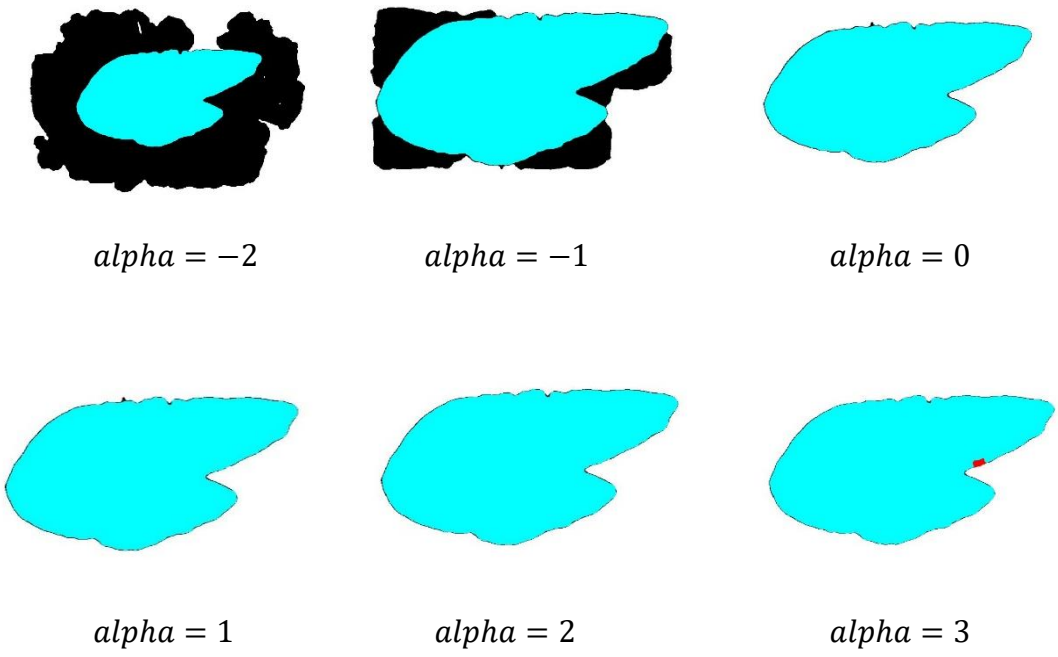

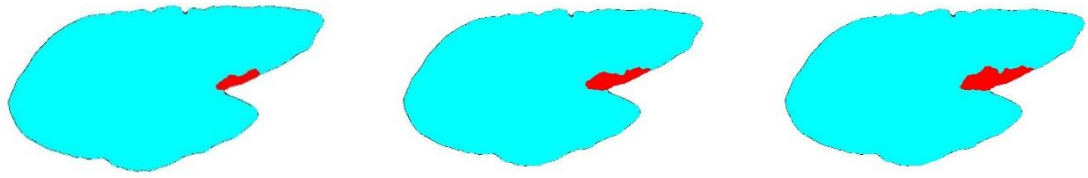

$alpha = 4$ $alpha = 5$ $alpha = 6$

Figura 27. Comparación de contornos según el valor de alpha

Una vez finalizada la segmentación, los datos son recogido en tablas (anexo 3). Conforme a la explicación anterior y los datos recogidos, se representa la curva ROC.

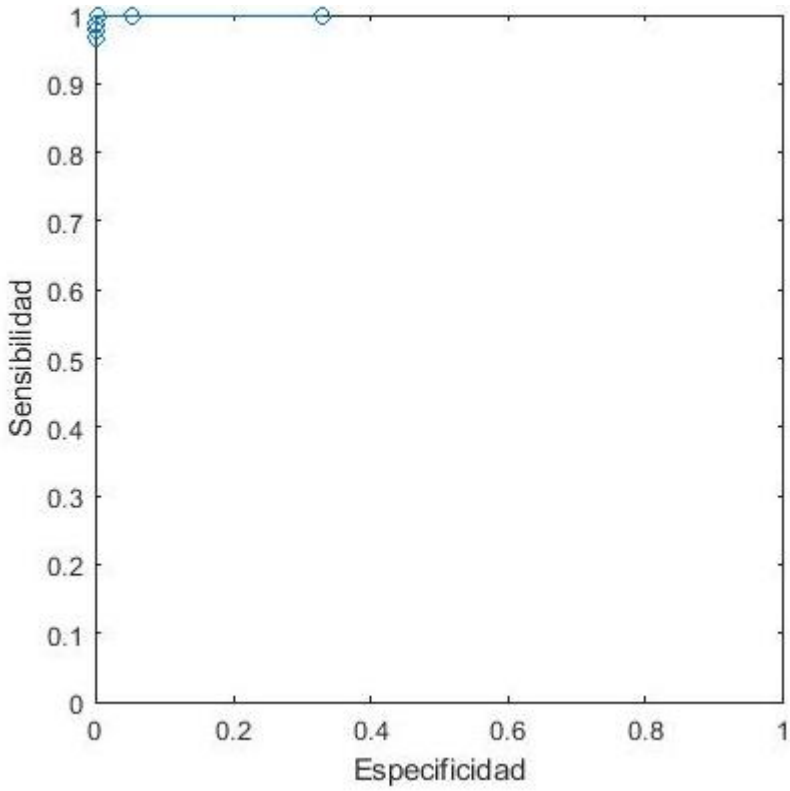

Figura 28. Representación curva ROC.

Como se puede apreciar en la figura 28, la curva ROC es bastante óptima, debido a que la mayoría de los puntos se encuentran en un valor, aproximadamente, de $sensibilidad = 1$ y $1 - especificidad = 0$. A partir de la gráfica, se puede observar como con valores de alpha negativos el valor de $1 - especificidad$ aumenta ligeramente pero, el valor de la sensibilidad se mantiene, esto es debido a que el contorno de la imagen gold truth es detectado en su totalidad, aunque con un número de falsos positivos (FP) demasiado grande. Por otro lado, se puede observar como con valores alpha positivos los valores de sensibilidad y 1 - especificidad se mantiene, aproximadamente, en 1 y 0, respectivamente, esto es debido a la proximidad del contorno Level set cero al objeto a detectar, además de la disminución considerable del número de falsos positivos.

El número de iteraciones se ha seleccionado entre -2 y 6, debido a que a valores de alpha inferior y superior, respectivamente, la curva del Level set puede colapsar, además de que el número de falsos negativos aumenta considerablemente, por ello es innecesaria su representación, como se ha explicado anteriormente.

Visualizando la figura 27 y 28, se puede apreciar que a valores de alpha negativos el número de falsos positivos es demasiado alto, como se ha comentado anteriormente. Por otro lado, a valores de alpha positivos el número de falsos positivos desciende considerablemente incluso acercándose a valores cercanos a 0. Aun así, conforme se aumenta el valor de alpha de 0 a 6, el número de falsos negativos va en aumento, de ahí que el valor máximo de alpha se estableciera en 6, debido a que a mayor número de alpha la curva Level set puede colapsar, como se ha comentado anteriormente. En definitiva, como se analizará posteriormente, a valores entre 1 y 5 la curva se aproxima de manera óptima al contorno deseado.

A partir de la curva ROC, se puede calcular el área bajo la curva (AUC). Con este valor se mide la precisión de lo analizado anteriormente. Este área posee un valor comprendido entre 0.5 y 1, siendo $AUC = 1$ una precisión excelente y $AUC = 0.5$ una mala precisión.

- [0.5, 0.6] → Mala precisión
- [0.6, 0.7] → Regular precisión
- [0.7, 0.8] → Buena precisión
- [0.8, 0.9] → Muy buena precisión
- [0.9, 1] → Excelente precisión

Este valor se calcula como:

$$AUC = \sum \Delta X_i Y_i \tag{39}$$

Donde X_i se corresponde con los valores de 1 - especificidad e Y_i con los valores de sensibilidad.

La mayoría de los otolitos analizados y comparados, presentan un AUC con una precisión excelente, esto es debido a la perfecta visualización de los otolitos en las imágenes administradas, además del gran contraste de estos con el fondo de las imágenes. Por ello, para el Level set es sencillo diferenciar los pixeles del contorno de los otolitos con el del fondo de las imágenes.

5.2 Parámetro alpha

Para realizar la segmentación se ha realizado un código, como ya se ha comentado, en el cual varia el valor de alpha desde -2 a 6. Pero, es importante obtener el valor definitivo de alpha para obtener unos resultados óptimos sin la necesidad de ir variando el valor de alpha en cada imagen de otolito. Para ello, se realizara una media de los valores de 1 - especificidad y sensibilidad entre los valores $alpha = 1$ y $alpha = 5$, donde se elige el valor de alpha con la sensibilidad y 1 - especificidad, más alto y más bajo, respectivamente.

Se ha elegido el rango entre 1 y 5, ya que como se ha comentado anteriormente, a valores inferiores a 1, existen demasiados falsos positivos.

Tabla 1. Media los valores de sensibilidad y 1-especificidad en cada iteración

Alpha	Sensibilidad	1-especificidad
1	0.9997	0.0016
2	0.9995	0.0013
3	0.9991	0.0011
4	0.9971	0.0009
5	0.9916	7.52e-04
6	0.9842	6.09e-04

Como se ha comentado anteriormente, se elige el valor de alpha con un valor de sensibilidad y 1-especificidad, más alto y más bajo, respectivamente. Para ello, como se puede visualizar en la tabla 1, el valor de alpha que cumple los requisitos es

$alpha = 4$, debido a que su valor de $sensibilidad = 0.9971$ y $1 - especificidad = 0.0009$ puede generar una tasa de error lo más baja posible, además de que se encuentran dentro un valor bastante óptimo.

Por otro lado, para confirmar que $alpha = 4$, se utiliza el coeficiente de correlación Matthews (MCC), el cual se define como:

$$MCC = \frac{(TP*TN-FP*FN)}{\sqrt{(TP+FP)(TP+FN)(TN+FP)(TN+FN)}} \tag{40}$$

Se realiza una media de los valores del coeficiente de Matthews desde $alpha = 1$ a $alpha = 5$ de todos los Otolitos analizados. Se ha elegido este rango, debido a que, a valores inferiores y superiores, respectivamente, la curva no se adhiere correctamente al contorno deseado o el número de falsos positivos y falsos negativos es grande, como se puede ver en las tablas disponibles en el Anexo 3.

Tabla 2. Media de MCC dependiente del parámetro alpha

Alpha	MCC
1	0.9919
2	0.9932
3	0.9942
4	0.9941
5	0.9917

El coeficiente de Matthews devuelve un valor entre -1 y 1. Un coeficiente de 1 o cercano representa una predicción perfecta, un coeficiente de 0 o cercano representa una predicción aleatoria y un coeficiente de -1 o cercano representa una predicción

nula. Por lo tanto, dependiendo de los valores visibles en las tablas 1 y 2, se puede apreciar como el valor $alpha = 4$ se encuentra dentro de los valores óptimos buscados.

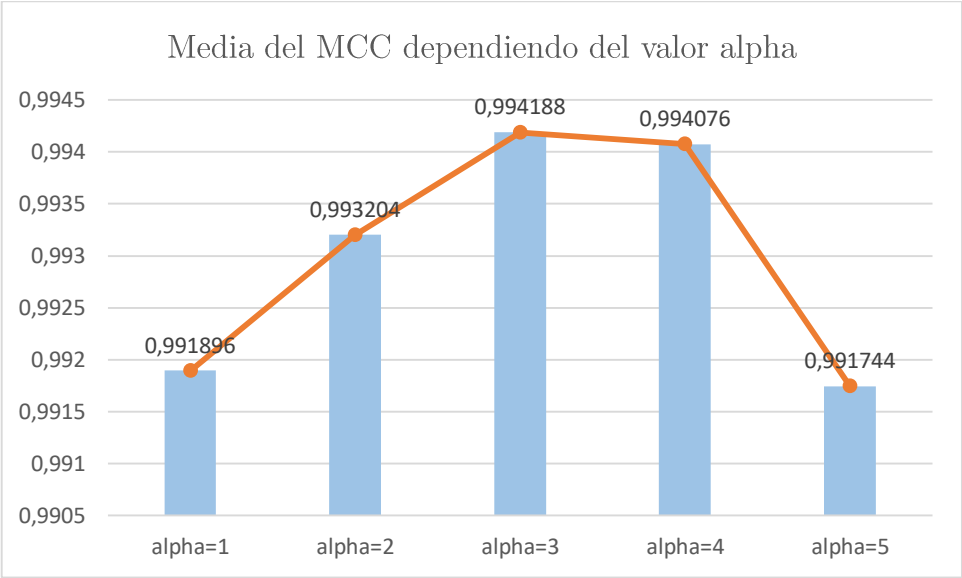

Figura 29. Media del MCC de los Otolitos dependiendo del parámetro alpha

5.3 Resultados obtenidos

Utilizando el valor de $alpha = 4$, se obtiene los siguientes resultados:

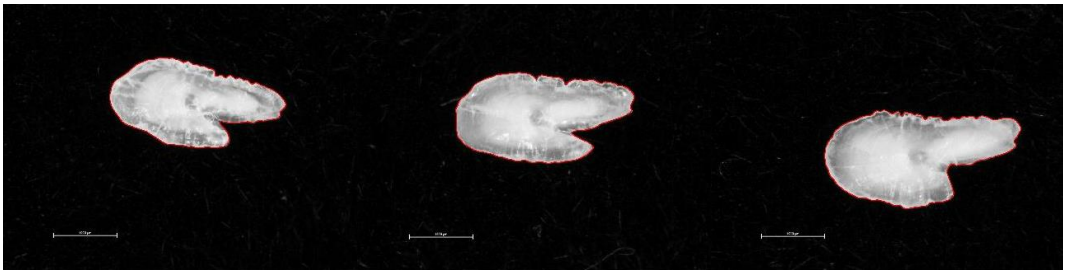

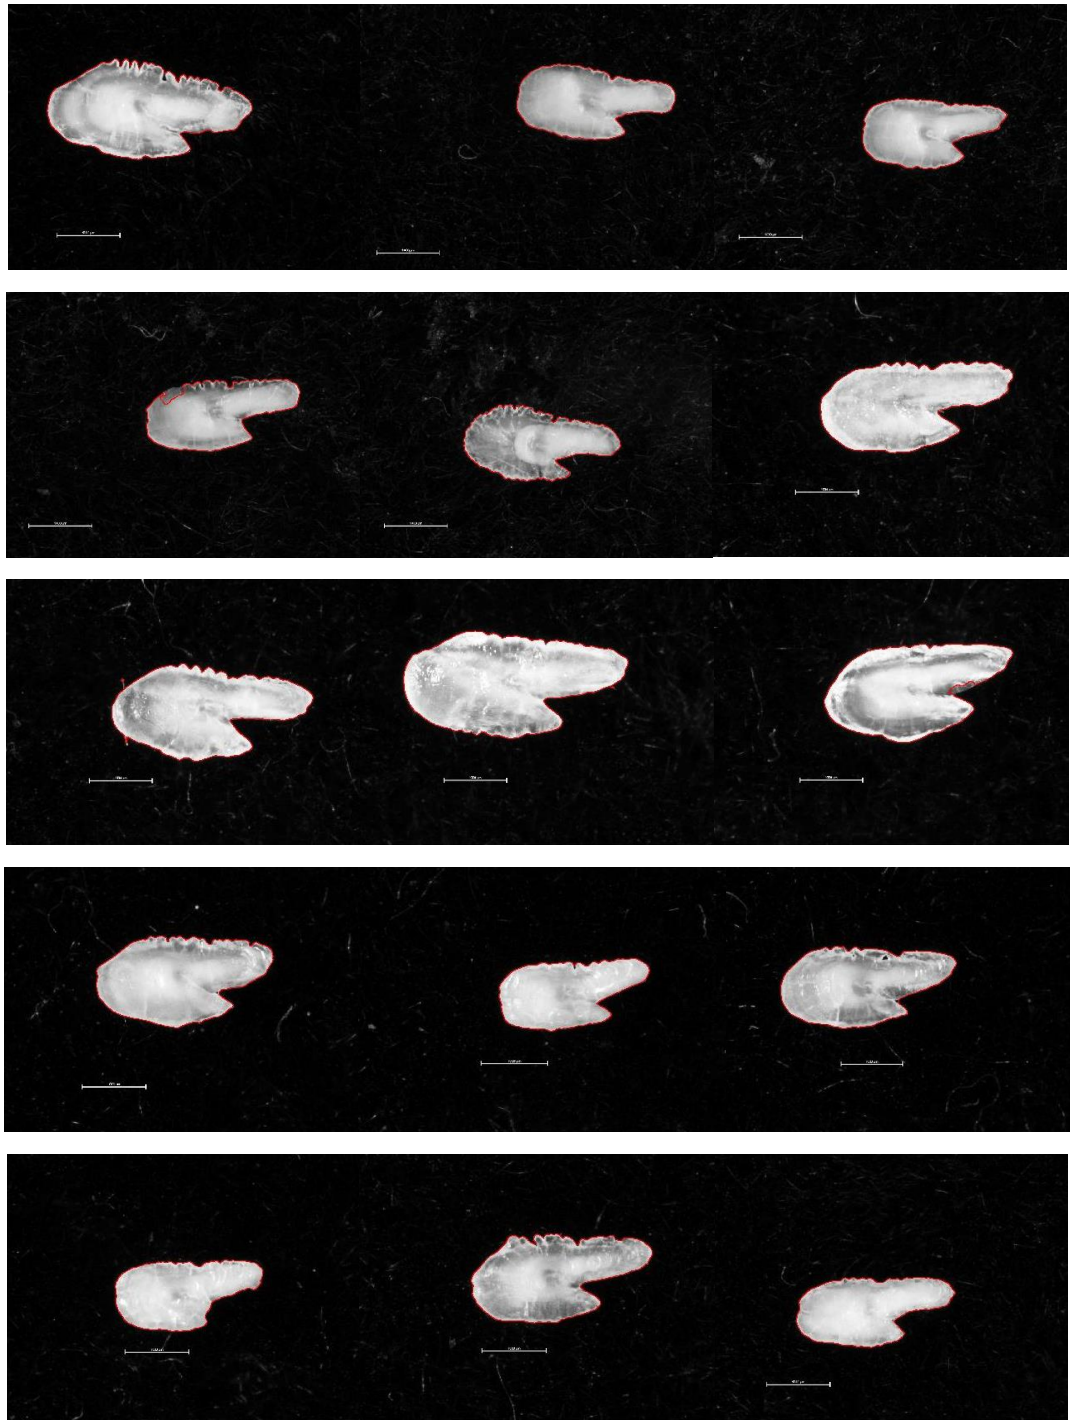

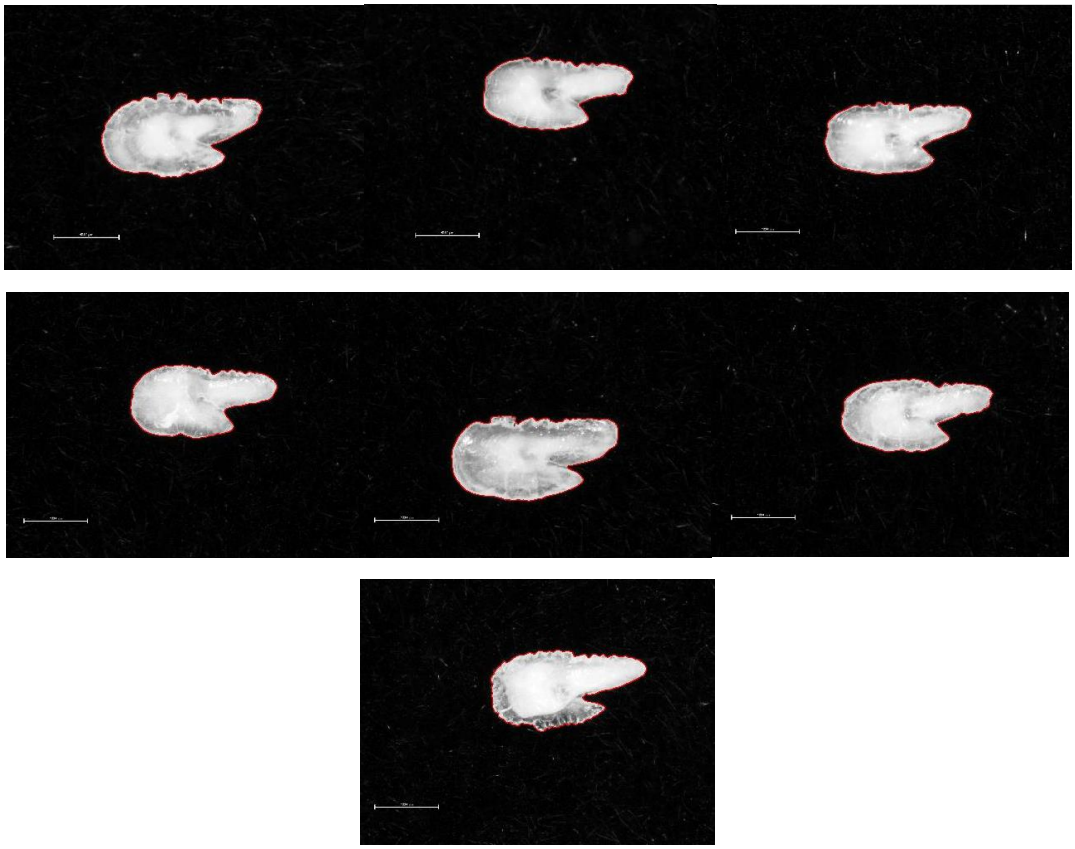

Figura 30. Contorno obtenido con alpha=4

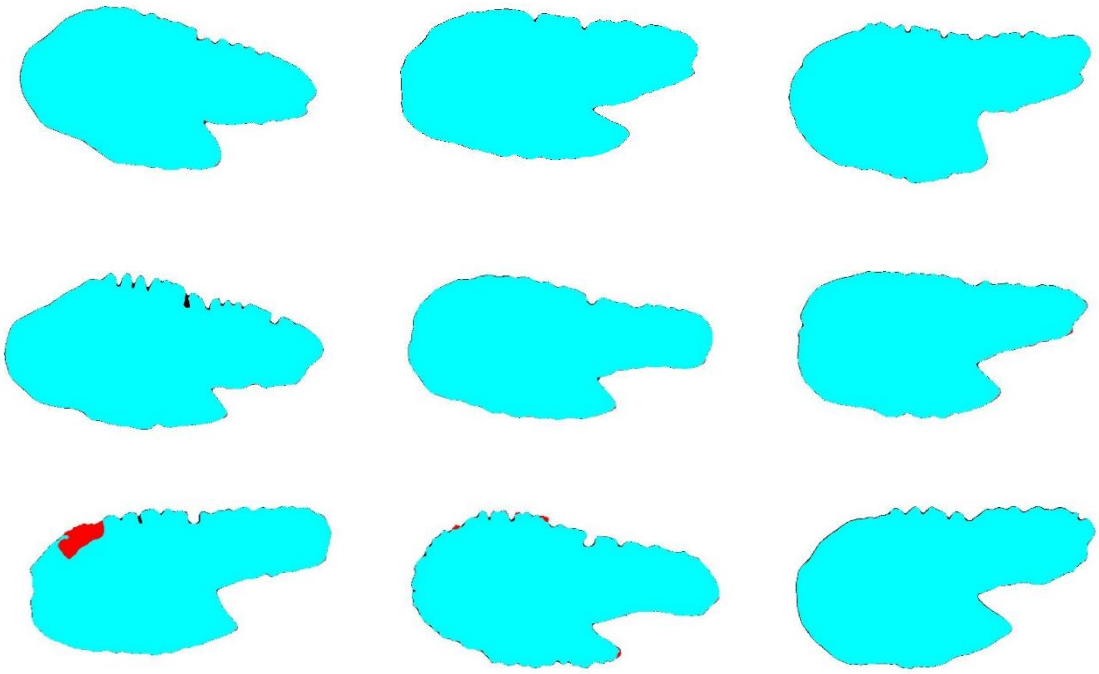

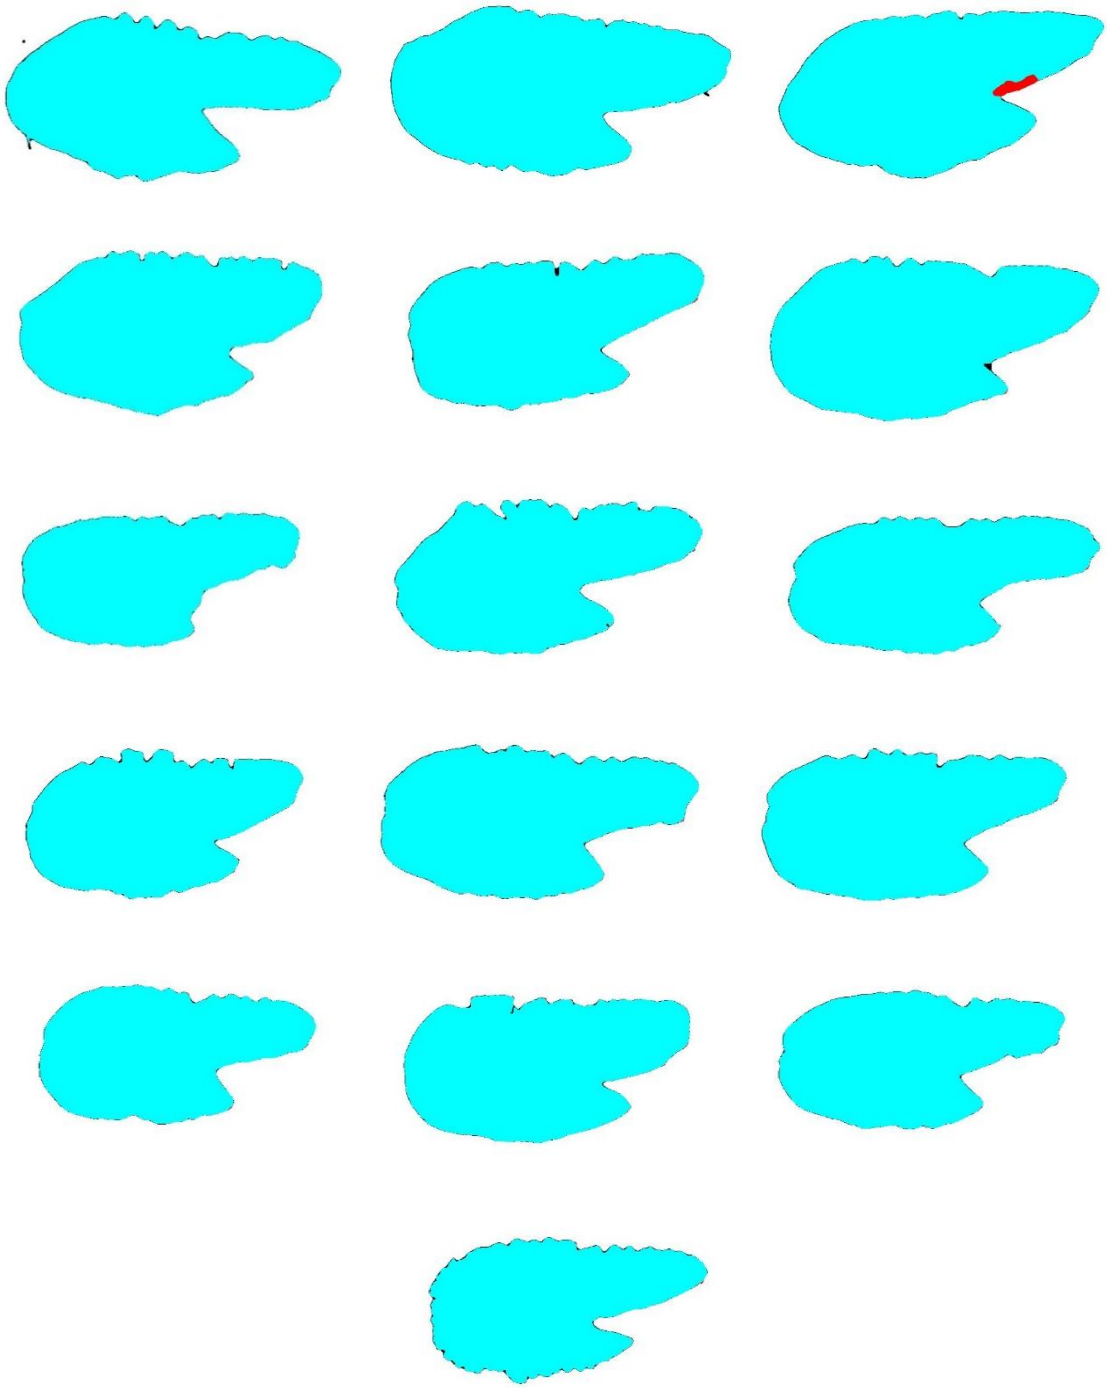

Figura 31. Comparación del contorno de la imagen gold truth con el contorno obtenido de la segmentación con valor alpha=4

Los resultados obtenidos con $alpha = 4$ se ajustan de manera óptima al contorno deseado, excepto en algunos casos, donde se puede apreciar un pequeño aumento del número de falsos negativos. Pero, en general los resultados son bastante buenos.

Debido a esto, se puede asumir que el parámetro alpha óptimo escogido es bastante fiable.

Por otro lado, la comparación de los contornos obtenidos de las imágenes gold truth con los contornos de la segmentación han resultado ser muy fiables debido a que los resultados de la medición del área bajo la curva (AUC) de las curvas ROC han tenido una precisión excelente, esto es debido al correcto funcionamiento del algoritmo implementado, además de la buena visualización de otolito, el contraste de este con respecto a fondo y el correcto establecimiento de la curva Level set cero. Los resultados del parámetro AUC se encuentran en el anexo 4.

5.4 Conclusión

Una vez finalizado el proyecto, se obtienen las siguientes conclusiones acerca de los temas tratados en este.

La primera conclusión trata sobre los otolitos y su interesante finalidad. Este, es utilizado por expertos o investigadores en numerosas aplicaciones como puede ser los estudios de reclutamiento y dinámica de poblaciones, en estudios de morfometría o en estudios de la microquímica. Sobre este objeto se ha realizado un estudio sobre su localización, morfometría, composición, función, método de extracción para su estudio y, sobre todo, sobre su finalidad, la cual es una de las base de este proyecto.

Otra importante conclusión trata sobre el código utilizado, el cual pertenece al método de segmentación de contornos activos basados en Level set, en concreto al

método DRLSE. Se ha empleado este método debido a su buen uso para la detección de contornos, gracias a su cálculo preciso y evolución estable de la curva Level set. Se ha realizado una adaptación de este con el cual además de la segmentación de los Otolitos realiza una comparación de los contornos de las imágenes gold truth con los contornos obtenidos en las segmentaciones dependiendo del valor de parámetro alpha, ya que es considerado como el más influyente.

Primeramente, antes de comenzar con la segmentación, se realizó un estudio sobre los parámetros involucrados para conocer el valor óptimo de cada uno de ellos, en especial, el valor de alpha, con el cual mediante la curva ROC, se ha obtenido los valores de sensibilidad y 1-especificidad de cada otolito. Realizando una media de cada parámetro y del coeficiente de Matthews, se ha elegido el valor de alpha óptimo, según el valor de estos.

Por otra parte, es necesario destacar la selección de la región del Level set cero ya que su influencia es esencial para una correcta segmentación. Por ello, en cada segmentación de Otolito se ha elegido una región lo más próxima al objeto a segmentar, ya que como se ha explicado, si se encuentra alejada, la curva no se va a adaptar correctamente debido a que se puede ver influenciada por otras estructuras.

Por lo tanto, es fundamental una correcta elección de los parámetros existente y la región del Level set cero. En nuestro caso, la elección, según los resultados, han sido bastante correctos, debido a que los valores obtenidos del área bajo la curva (AUC) de la curva ROC han resultado ser excelente, además de la buena adaptación de la curva al contorno deseado. Todo lo mencionado anteriormente, es indicativo de que el código implementado ha funcionado de manera correcta.

También, es digno de mención la facilidad de trabajo de software Matlab para el procesamiento de imágenes, permitiendo la implementación de algoritmos, como el implementado en este proyecto, además de funciones para el manejo de imágenes.

5.5 Líneas futuras

Una vez desarrollado el proyecto, existen formas con la que se puede mejorar y ampliar la implementación del método utilizado. Este método, esta realizado para analizar una sola imagen de otolito, una forma de mejorarlo sería realizar un ajuste del código, de forma que te analizara más de una imagen, con lo cual se puede reducir de manera considerable el trabajo del experto.

Por otro lado, se puede aumentar el número de parámetros o combinar el código con otro método, de forma que se perfeccioné aún más la detección de contornos.

Otra forma de mejorar el código es reducir el tiempo de compilado, el cual es siempre uno de los principales problemas en la segmentación de imágenes, ya que, si el programa ejecuta un número grande iteraciones, el tiempo de compilado es alto.

Para finalizar, cabe destacar que el código implementado puede ser utilizado en otras aplicaciones, además de la desarrollada en nuestro proyecto. Por ejemplo, en medicina, para la detección de tumores, segmentación de arterias y venas del sistema circulatorio, medidas de volúmenes de tejidos, etc..., en otros ámbitos, para la localización de objetos en imágenes de satélites, detección de huellas, reconocimiento facial, entre otras muchas aplicaciones.

Bibliografía

Coto, E. (2003). Métodos de segmentación de imágenes médicas. *Lecturas en Ciencias de la Computación*, 9-15.

Cubillos, L., Aguayo, M., Neira, M., Sanhueza, E., & Castillo-Jordán, C. (2009). Verificación de la edad y crecimiento del besugo Epigonus crassicaudus admitiendo error en la determinación de la edad. *Revista de biología marina y oceanográfica*, Vol. 44, 417-427.

División de región. (s.f.). Obtenido de https://nirantak.com/image-processing-region-splitting

Kass, M., Witkin, A., & Terzopoulos, D. (1988). Snake: Active contour models. *International Journal of Computer Vision*, Vol. 1, 321-331.

Li, C. (2005). *Image computing*. Obtenido de http://www.imagecomputing.org/~cmli/.

Li, C., Xu, C., Gui, C., & D. Fox, M. (2010). Distance Regularized Level Set Evolution and Its Application to Image Segmentation. *IEEE transactions on image processing*, Vol. 19, 3243- 3254.

Luque, A., & Ramírez, T. (Mayo de 1996). *Otolitos: una introducción a su potencial uso para el estudio de la biología de los peces*. Obtenido de http://www.encuentros.uma.es/encuentros32/otolit.html

Mathworks. (1984-2020). *Mathworks*. Obtenido de Mathworks: https://la.mathworks.com/help/matlab/index.html?s_tid=CRUX_lftnav

Mitiche, A., & Ben Ayed, I. (2010). *Variational and Level Set Methods in Image Segmentation*. Springer.

Olabe, X. B. (1998). Redes Neuronales Artificiales y sus aplicaciones. *Publicación de escuela ingenieros*, Vol. 1, 1-11.

Ortega Cardentey, D. R., & Iznaga Benitez, A. (2008). Técnicas de segmentación de imágenes médicas. *Revista de la convencion científica de ingeniería y arquitectura*, Vol. 1, 1-7.

Palomino, N., & Concha, U. (2009). Técnicas de segmentación en procesamiento digital de imagenes. *Investigación de sistemas e informática*, 9-16.

Palomino, N., & Pro concepcion, L. (2010). Wastershed: un algoritmo eficiente y flexible para segmentación de imágenes de geles 2-DE. *Revista de investigación de sistemas e informática*, 7(2), 35-41.

R. Leta, H., & Keim, A. (Mayo de 1982). *Lectura de edades en otolitos de peces teleosteos*. Obtenido de http://www.fao.org/3/AC567S/AC567S05.htm

Secor, D., Deany, J., & Laban, H. (1991). Manual for Otolith Removal and Preparation for Microestructural Examination. *Otolith microstructure examination and analysis. Canadian special publication of fisheries and aquatic sciences*, 117, 19-57.

Vanina, A., & Vaz-dos-santos, A. (2015). *Métodos de estudios con Otolitos: principios y aplicación.* Ciudad Autónoma de Buenos Aires: 1ª ed. edición bilingue. Ministerio de educación.

Velez, J. F., Sánchez, Á., B. Moreno, A., & L. Esteban, J. (2005). Verificación off-line de firmas manuscritas: Una propuesta basada en snakes paramétricos. *In Proc. Spanish Symp. on Shape Recognition and Artificial Intelligence (SNRFAI)* .

Wu, Q. (2019). Delineating Nested Depression Hierarchy. *JAWRA Journal of the American Water Resources Association*, 55(2), 354-368.

Anexos

Anexo 1. Código en Matlab

Código ejecutable implementado a partir de la función DRLSE (Li, Image computing, 2005):

El código implementado es una modificación del código del profesor Chunming Li (Li, Image computing, 2005), donde se muestra un modelo de contorno activo basado en bordes como una aplicación de la distancia de regularización de la evolución del Level set (DRLSE). En él, se han realizado una serie de modificaciones acorde al proyecto realizado, como puede ser el aumento de iteraciones para la detección del contorno de los Otolitos según el valor del parámetro alpha, la comparación del contorno de la imagen gold truth con el contorno obtenido en la segmentación, la representación gráfica de la curva ROC según los valores de verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos, obtenidos en la comparación, además de, el cálculo del área bajo la curva (AUC) de cada curva ROC obtenida.

```
clear all;
close all;

Imagen=imread('PIL-TBK#6-CONTORNOS.png');
Ip=imresize(Imagen, 0.45);
[m,n,p]=size(Ip);
imf=Ip(:,:,1:3);
imshow(imf);
img=zeros(m,n);
```

```
for i=1:m
     for j=1:n
        R=imf(:,:,1);
        G=imf(:,:,2);
        B=imf(:,:,3);
         if(R(i,j)<125 && B(i,j)<125 && G(i,j)>210)
            img(i,j)= 1;
        else
            img(i,j)=0;
        end
     end
end
figure(1)
imshow(img);
I=imread('PIL-TBK#6.png'); %lectura de la imagen
Iw=imresize(I, 0.45);
Img=double(Iw(:,:,1));

% parametros
timestep=1;
mu=0.2/timestep;
iter_inner=50;
iter_outer=20;
lambda=5;
i=1;
for alpha=-2:6
    alfa=alpha+1;
    epsilon=1.5;
    sigma=1.5;
    G=fspecial('gaussian',20,sigma); % Gaussiano filtro
    Img_smooth=conv2(Img,G,'same');  % suavizado de la imagen por convolucion
gaussiana
    [Ix,Iy]=gradient(Img_smooth);
    f=Ix.^2+Iy.^2;
    g=1./(1+f);

    % Inicializacion de la funcion level-set
    c0=2;
    initialLSF = c0*ones(size(Img));
    % Establecimiento de la region inicial R0 con dos rectángulos
    initialLSF(226:501,428:810)=-c0;
    initialLSF(226:376,810:944)=-c0;
    phi=initialLSF;

    figure(2);    % Representacion grafica de la funcion level-set
    mesh(-phi);
```

```
    hold on;  contour(phi, [0,0], 'r','LineWidth',2);
    title('Initial level set function');
    view([-80 35]);

    figure(3);   %Representacion de la region abarcada por los dos rectangulos
    imagesc(Img,[0, 255]); axis off; axis equal; colormap(gray); hold on;
contour(phi, [0,0], 'r');
    title('Initial zero level contour');
    pause(0.5);

    potential=2;
    if potential ==1
        potentialFunction = 'single-well';  % uso del potencial-simple --->
p1(s)=0.5*(s-1)^2
    elseif potential == 2
        potentialFunction = 'double-well';  % uso del potencial-doble
    else
        potentialFunction = 'double-well';  % uso por defecto del potencial-doble
    end

% Comienzo de la evolucion level-set
    for n=1:iter_outer
        phi = drlse_edge(phi, g, lambda, mu, alfa, epsilon, timestep, iter_inner,
potentialFunction);
        if mod(n,2)==0
            figure(3);
             imagesc(Img,[0, 255]); axis off; axis equal; colormap(gray); hold on;
contour(phi, [0,0], 'r');
        end
    end

% refine del contorno del Level-set cero con alfa=0
    alfa=0;
    iter_refine = 10;
    phi = drlse_edge(phi, g, lambda, mu, alfa, epsilon, timestep, iter_inner,
potentialFunction);

    finalLSF=phi;
    figure;
    imagesc(Img,[0, 255]); axis off; axis equal; colormap(gray); hold on;
contour(phi, [0,0], 'r');
    hold on;
    contour(phi, [0,0], 'r');
    str=['Final zero level contour, ', num2str(iter_outer*iter_inner+iter_refine),
' iterations'];
    title(str);
    figure;
```

```
    mesh(-finalLSF);
    hold on;
    contour(phi, [0,0], 'r','LineWidth',2);
    view([-80 35]);
    str=['Final level set function, ', num2str(iter_outer*iter_inner+iter_refine),
' iterations'];
    title(str);
    axis on;
    [nrow, ncol]=size(Img);
    axis([1 ncol 1 nrow -5 5]);
    set(gca,'ZTick',[-3:1:3]);
    set(gca,'FontSize',14)
    bwims=(finalLSF<0);
    im=logical(img);
    im2=bwpropfilt(im,'Area',1);
    imb=bwmorph(im2,'fill');
    bwim2=imfill(imb,'holes');



    %CURVA ROC
    imTP=bwim2 & bwims; %cALCULO TP
    imFN=bwim2>imTP; %Calculo FN
    imshow(imFN);
    imFP=bwims>imTP; %Calculo FP
    imshow(imFP);
    imTN= ~(imTP | imFN | imFP); %Calculo TN
    imshow(imTN);
    IM= 1*imTP + 2*imFN + 3*imFP;
    map=[0 1 1;1 0 0;0 0 0];
    cmap=colormap(map);
    IMcolor = label2rgb(IM, cmap, 'w');
    imshow(IMcolor);
    title(['alpha=',num2str(alpha)]);
    TP(i)=sum(imTP(:));
    TN(i)=sum(imTN(:));
    FP(i)=sum(imFP(:));
    FN(i)=sum(imFN(:));
    sens(i)=TP(i)/(TP(i)+FN(i)); %Calculo sensibilidad
    espec(i)=TN(i)/(TN(i)+FP(i)); %Calculo especificidad
    if((1-espec(i)) ==0 && sens(i) == 0)
       break;
    end
    i=i+1;
end

sens=sens(:);
```

```
espec=espec(:);
espec2=1-espec;
```

```
figure;
plot(espec2,sens,'o-'); %dibujar curva ROC
title('Curva ROC');
ylabel('Sensibilidad');
xlabel('1-Especificidad');
axis square;
xlim([0 1]); ylim([0 1]);
TP=TP';
FP=FP';
TN=TN';
FN=FN';
h=alpha(end);
alpha=-2:h;
alpha=alpha';
tabla=table(alpha,TP,TN,FP,FN,sens,espec2); %Tabla con todos los parametros de la
curva ROC


%Parametro area bajo la curva (AUC)

sensdef=flipud(sens);
espec2def=flipud(espec2);
n=length(espec2def);
r = n-1;
AUC=0; %Inicializacion
xm=zeros(n); %Creacion de matrices de ceros
incdef=zeros(n);
for i=2:n
    xm(i)= (espec2def(i)+espec2def(i-1))/2; %Cálculo de la media entre dos puntos
    if(i<=r)
        incdef(i)=xm(i)-xm(i-1); %Cálculo del incremento del intervalo entre Xm
        AUC=AUC+(incdef(i)*sensdef(i)); %Cálculo de AUC
    end
end
incdef(n)=1-xm(n-1); %Definición de la última posición
incdef(1)=xm(1); %Definicion de la primera posición

AUC = AUC + (incdef(1)*sensdef(1));
AUC = AUC + (incdef(n)*sensdef(n));
```

Anexo 2. Imágenes gold truth

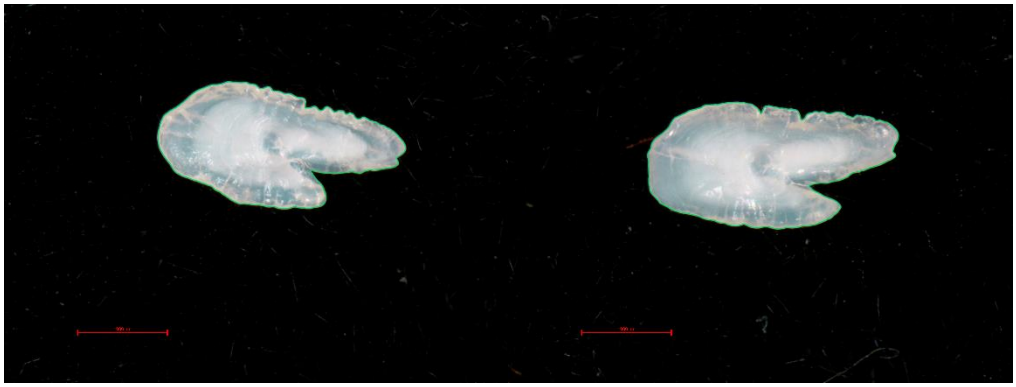

PIL-AGA#7 PIL-AGA#21

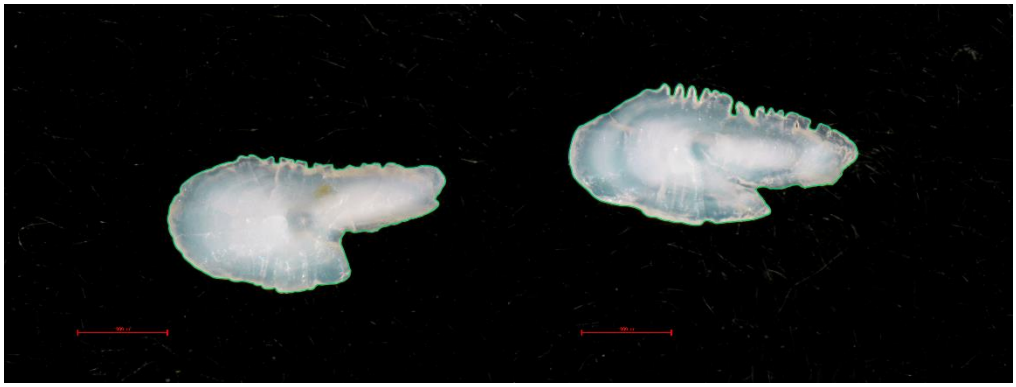

PIL-AGA#38 PIL-AGA#48

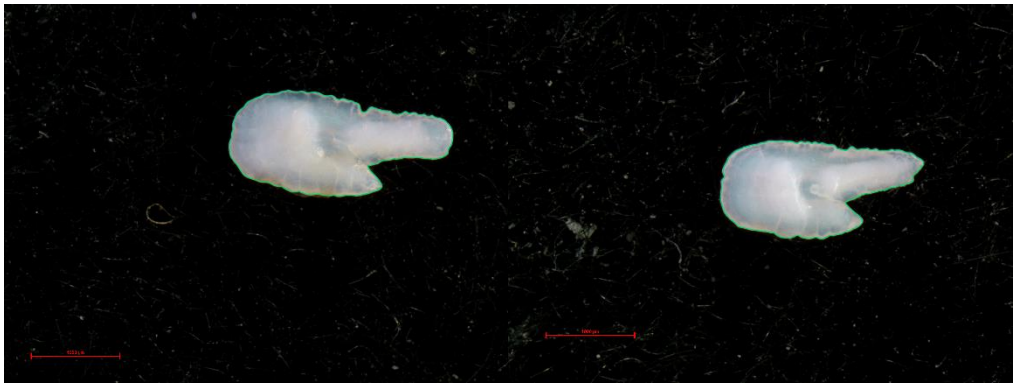

PIL-ANB#1 PIL-ANB#5

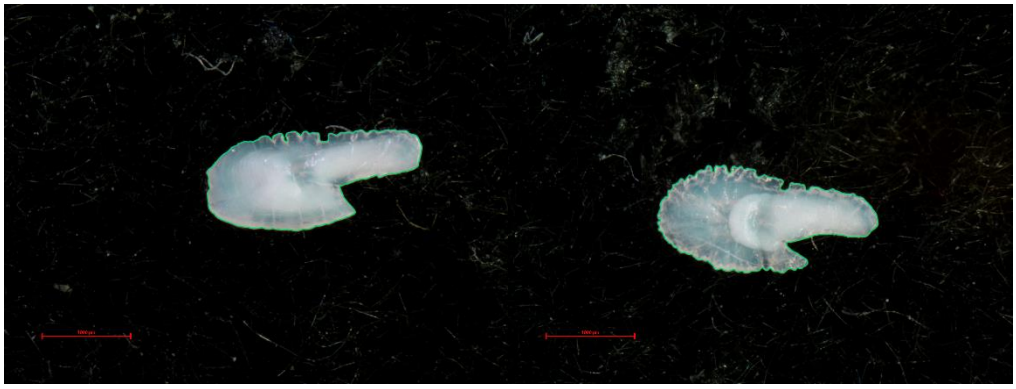

PIL-ANB#13 PIL-ANB#46

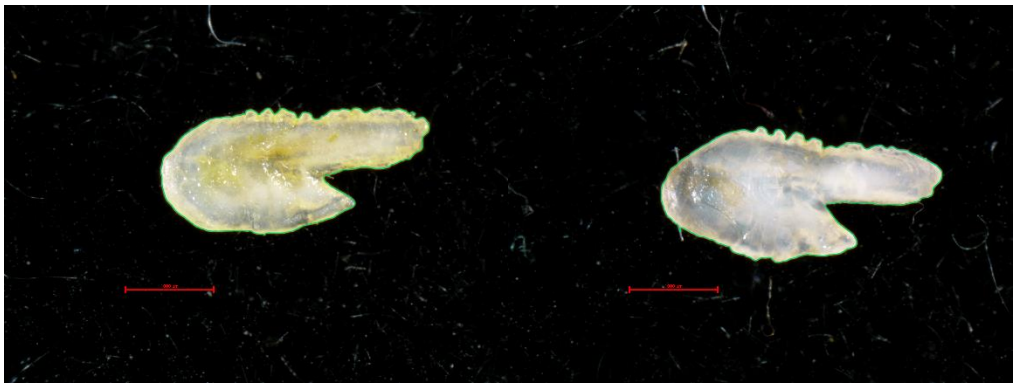

PIL-ETP#22 PIL-ETP#26

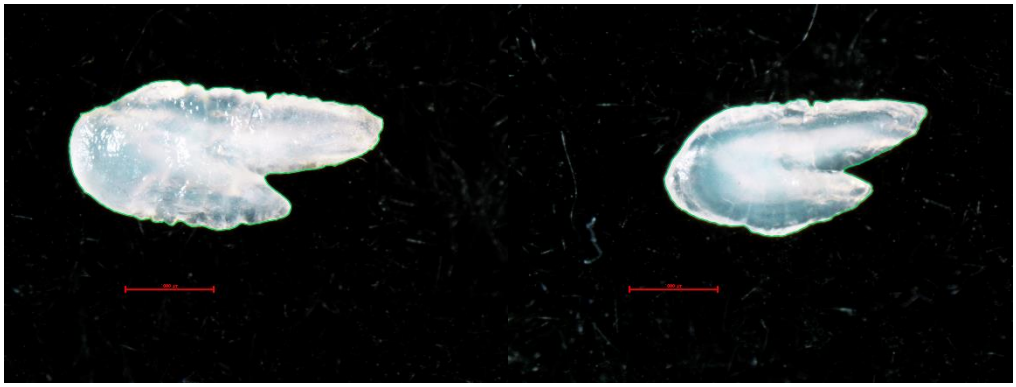

PIL-ETP#28 PIL-ETP#36

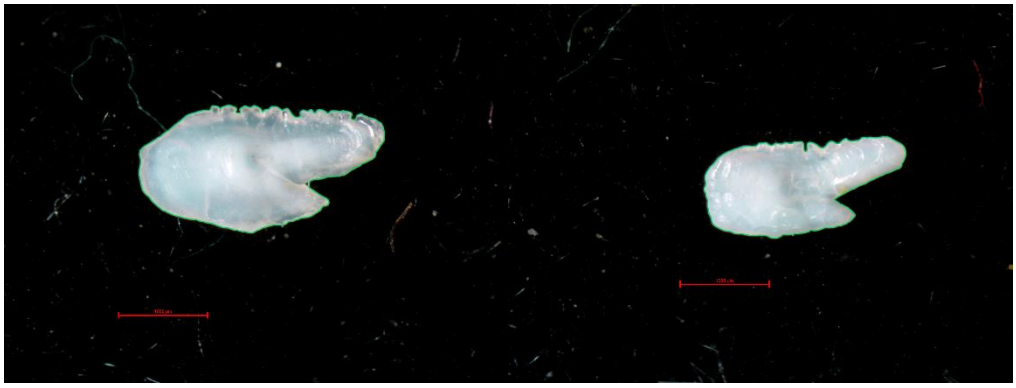

PIL-HUE#3 PIL-HUE#5

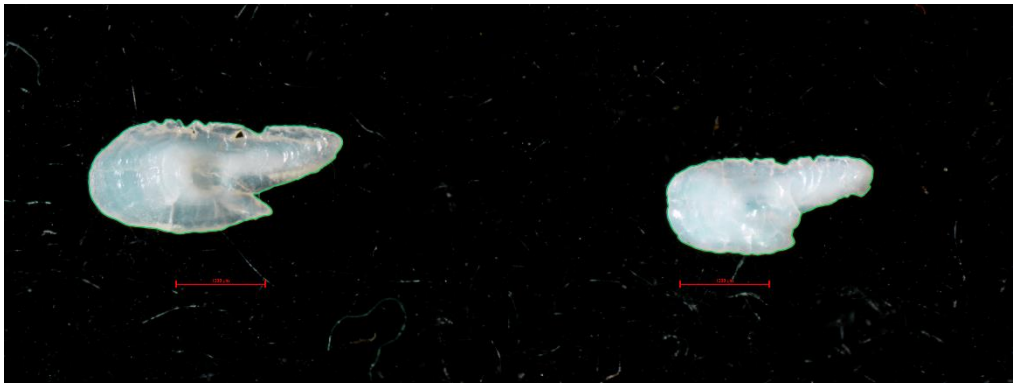

PIL-HUE#6 PIL-HUE#9

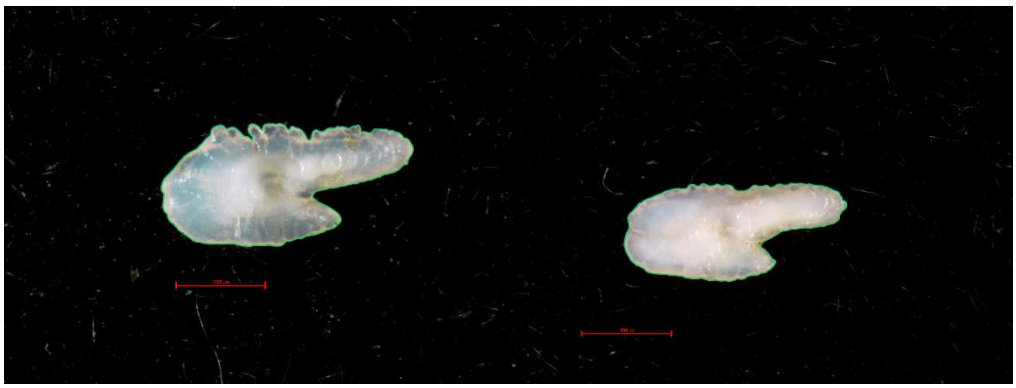

PIL-HUE#25 PIL-MDQ#1

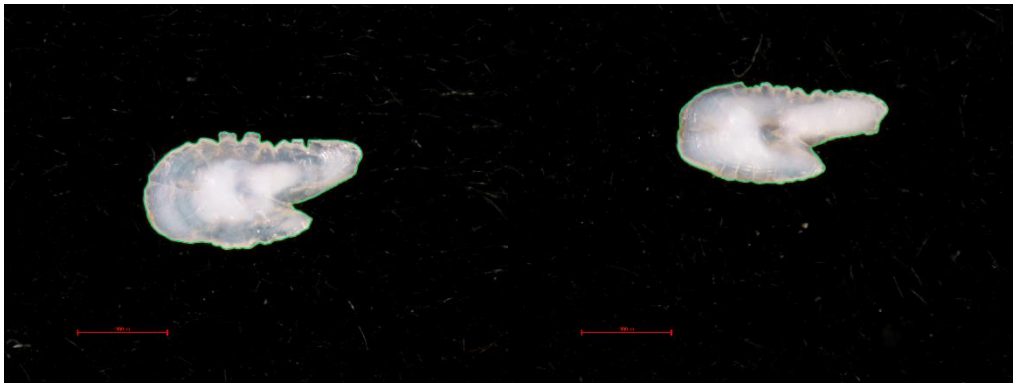

PIL-MDQ#8 PIL-MDQ#13

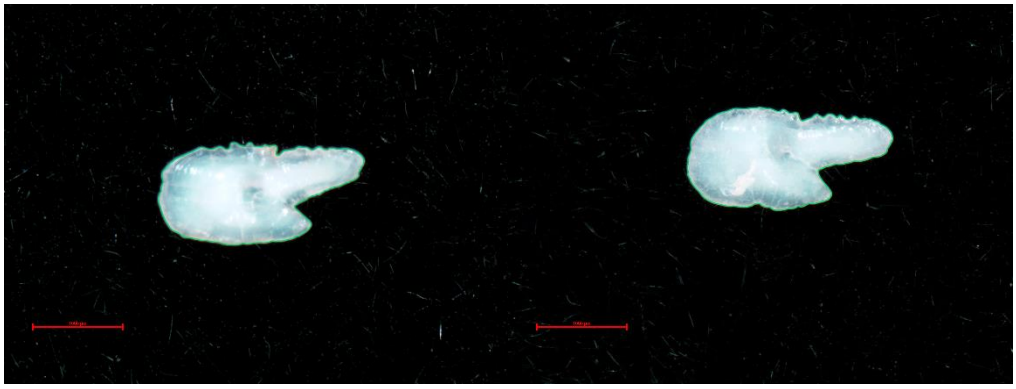

PIL-TBK#1 PIL-TBK#3

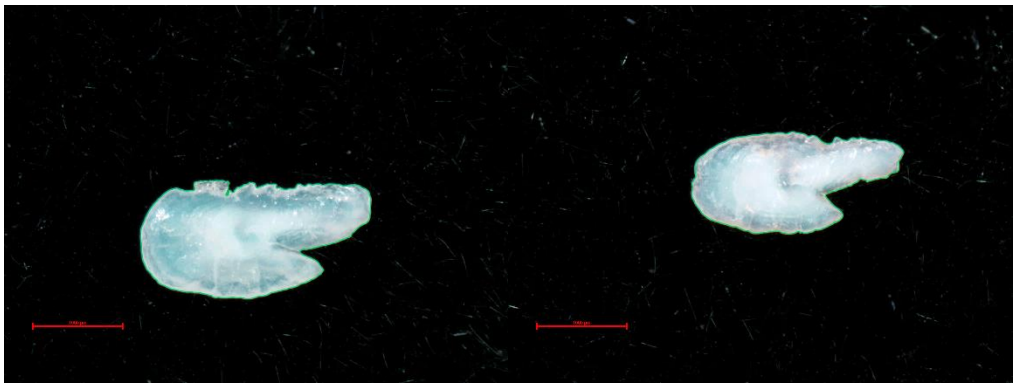

PIL-TBK#4 PIL-TBK#7

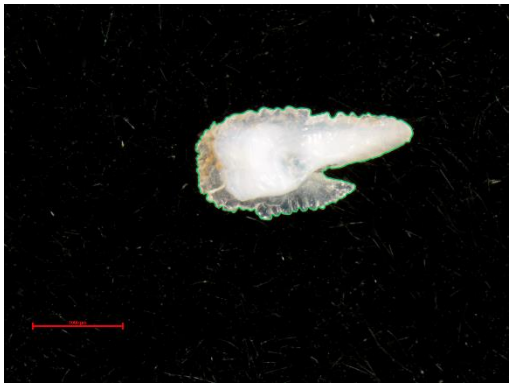

PIL-TBK#39

Anexo 3. Tablas necesarias para la representación de la curva ROC

- PIL-AGA#7:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	104624	402381	279427	0	1	0.4098
-1	104623	643763	38045	1	1	0.0558
0	104606	680354	1454	18	0.9998	0.0021
1	104585	680631	1177	39	0.9996	0.0017
2	104563	680802	1006	61	0.9994	0.0015
3	104532	680964	844	92	0.9991	0.0012
4	104491	681098	710	133	0.9987	0.0010
5	104434	681213	595	190	0.9982	8.7268e-04
6	104325	681297	511	299	0.9971	7.4948e-04

- PIL-AGA#21:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	94808	434258	257366	0	1	0.3721
-1	94808	664178	27446	0	1	0.0397
0	94802	690221	1403	6	0.9999	0.0020
1	94796	690533	1091	12	0.9999	0.0016
2	94783	690717	907	12	0.9997	0.0013
3	94756	690904	720	52	0.9995	0.0010
4	94728	691046	578	80	0.9992	8.3571e-04

5	94686	691150	474	122	0.9987	6.8534e-04
6	94635	691252	372	173	0.9982	5.3786e-04

- PIL-AGA#38:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	104624	402381	279427	0	1	0.4098
-1	104623	643763	38045	1	1	0.0558
0	104606	680354	1454	18	0.9998	0.0021
1	104585	680631	1177	39	0.9996	0.0017
2	104563	680802	1006	61	0.9994	0.0015
3	104532	680964	844	92	0.9991	0.0012
4	104491	681098	710	133	0.9987	0.0010
5	104434	681213	595	190	0.9982	8.7268e-04
6	104325	681297	511	299	0.9971	7.4948e-04

- PIL-AGA#48:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	111220	387136	288076	0	1	0.4266
-1	111220	625828	49384	0	1	0.0731
0	111201	673161	2051	19	0.9998	0.0030
1	111171	673587	1625	49	0.9996	0.0024
2	111141	673815	1397	79	0.9993	0.0021
3	111091	673999	1213	129	0.9988	0.0018
4	111034	674151	1061	186	0.9983	0.0016
5	110765	674277	935	455	0.9959	0.0014
6	110014	674381	831	1206	0.9892	0.0012

- PIL-ANB#1:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	84721	729395	181212	0	1	0.1990
-1	84720	878393	32214	1	1	0.0354
0	84707	909073	1534	14	0.9998	0.0017
1	84698	909513	1094	23	0.9997	0.0012
2	84687	909828	779	34	0.9996	8.5547e-04
3	84655	910019	588	66	0.9992	6.4527e-04
4	84591	910188	419	130	0.9985	4.6013e-04
5	84518	910285	322	203	0.9976	3.5361e-04
6	84395	910361	246	326	0.9962	2.7015e-04

- PIL-ANB#5:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	57505	613073	115854	0	1	0.1589
-1	57505	710308	18619	0	1	0.0255
0	57496	726453	2474	9	0.9998	0.0034
1	57474	728103	824	31	0.9995	0.0011
2	57446	728315	612	59	0.9990	8.3959e-04
3	57412	728457	470	93	0.9984	6.4478e-04
4	57347	728573	354	158	0.9973	4.8565e-04
5	57278	728668	259	227	0.9961	3.5532e-04
6	57192	728747	180	313	0.9946	2.4694e-04

- PIL-ANB#13:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	78214	778121	138993	0	1	0.1516
-1	78214	893297	23817	0	1	0.0260
0	78201	911184	5930	13	0.9998	0.0065
1	78182	915724	1390	32	0.9996	0.0015
2	78162	916016	1098	52	0.9993	0.0012
3	78128	916535	579	86	0.9989	6.3133e-04
4	75795	916724	390	2419	0.9691	4.2525e-04
5	67273	916856	258	10941	0.8601	2.8132e-04
6	56579	916922	192	21635	0.7234	2.0935e-04

- PIL-ANB#46:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	79978	773538	141812	0	1	0.1549
-1	79976	874560	47900	2	1	0.0446
0	79941	904050	11300	37	0.9995	0.0123
1	79895	914152	1198	83	0.9990	0.0013
2	79837	914435	915	141	0.9982	9.9962e-04
3	79702	914617	733	276	0.9965	8.0079e-04
4	79569	914808	542	409	0.9949	5.9212e-04
5	79138	914920	430	840	0.9895	4.6977e-04
6	77980	915018	332	1998	0.9750	3.6270e-04

- PIL-ETP#22:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	122123	600529	272676	0	1	0.3123

-1	122123	832056	41149	0	1	0.0471
0	122118	870247	2958	5	1	0.0034
1	122114	870993	2212	9	0.9999	0.0025
2	122106	871259	1946	17	0.9999	0.0022
3	122092	871488	1717	31	0.9997	0.0020
4	122079	871721	1484	44	0.9996	0.0017
5	122060	871914	1291	63	0.9995	0.0015
6	121997	872108	1097	126	0.9990	0.0013

- PIL-ETP#26:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	125991	564375	304962	0	1	0.3508
-1	125991	811580	57757	0	1	0.0664
0	125982	866364	2973	9	0.9999	0.0034
1	125978	866883	2454	13	0.9999	0.0028
2	125973	867189	2148	18	0.9999	0.0025
3	125961	867536	1801	30	0.9998	0.0021
4	125939	867773	1564	52	0.9996	0.0018
5	125902	867978	1358	89	0.9993	0.0016
6	125855	868169	1168	136	0.9989	0.0013

- PIL-ETP#28:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	167356	459967	368005	0	1	0.4445
-1	167356	764943	63029	0	1	0.0761
0	167353	825184	2788	3	1	0.0034

1	167350	825854	2118	6	1	0.0026
2	167338	826105	1867	18	0.9999	0.0023
3	167328	826336	1636	28	0.9998	0.0020
4	167313	826578	1394	43	0.9997	0.0017
5	167295	826808	1164	61	0.9996	0.0014
6	167266	827002	970	90	0.9995	0.0012

- PIL-ETP#36:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	126871	583275	285182	0	1	0.3284
-1	126871	823075	45382	0	1	0.0523
0	126870	866237	2220	1	1	0.0026
1	126863	866594	1863	8	0.9999	0.0021
2	126854	866876	1581	17	0.9999	0.0018
3	126518	867119	1338	353	0.9972	0.0015
4	125361	867319	1138	1510	0.9881	0.0013
5	123919	867502	955	2952	0.9767	0.0011
6	122773	867669	788	4098	0.9677	9.0736e-04

- PIL-HUE#3:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	115184	568675	311469	0	1	0.3539
-1	115183	839944	40200	1	1	0.0457
0	115164	877988	2156	20	0.9998	0.0024
1	115156	878446	1698	28	0.9998	0.0019
2	115133	879082	1062	51	0.9996	0.0012

3	115099	879268	876	85	0.9993	9.9529e-04
4	115059	879452	692	125	0.9989	7.8623e-04
5	115015	879585	559	169	0.9985	6.3512e-04
6	114948	879708	436	236	0.9980	4.9537e-04

- PIL-HUE#5:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	73795	660178	261355	0	1	0.2836
-1	73795	895499	26034	1	1	0.0283
0	73786	920162	1371	9	0.9999	0.0015
1	73775	920432	1101	20	0.9997	0.0012
2	73753	920633	900	42	0.9994	9.7663e-04
3	73733	920797	736	62	0.9992	7.9867e-04
4	73692	920919	614	103	0.9986	6.6628e-04
5	73629	921054	479	166	0.9978	5.1979e-04
6	76556	921189	344	239	0.9968	3.7329e-04

- PIL-HUE#6:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	106431	596152	292745	0	1	0.3293
-1	106431	853092	35805	0	1	0.0403
0	106423	887393	1504	8	0.9999	0.0017
1	106417	887654	1243	14	0.9999	0.0014
2	106407	887849	1048	24	0.9998	0.0012
3	106387	888024	873	44	0.9996	9.8212e-04
4	106363	888191	706	68	0.9994	7.9424e-04

5	106321	888393	504	110	0.9990	5.6699e-04
6	106258	888531	366	173	0.9984	4.1175e-04

- PIL-HUE#9:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	75105	672289	247934	0	1	0.2694
-1	75105	899340	20883	0	1	0.0227
0	75102	919016	1207	3	1	0.0013
1	75089	919205	1018	16	0.9998	0.0011
2	75076	919396	827	29	0.9996	8.9870e-04
3	75054	919541	682	51	0.9993	7.4112e-04
4	75031	919653	570	74	0.9990	6.1942e-04
5	74970	919765	458	135	0.9982	4.9771e-04
6	74903	919872	351	202	0.9973	3.8143e-04

- PIL-HUE#25:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	109481	599409	286438	0	1	0.3233
-1	109481	842144	43703	0	1	0.0493
0	109467	883191	2656	14	0.9999	0.0030
1	109462	884174	1673	19	0.9998	0.0019
2	109454	884567	1280	27	0.9998	0.0014
3	109423	884792	1055	58	0.9995	0.0012
4	109388	884986	861	93	0.9992	9.7195e-04
5	109328	885132	715	153	0.9986	8.0714e-04
6	109047	885265	582	434	0.9960	6.5700e-04

- PIL-MDQ#1:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	78736	683604	232988	0	1	0.2542
-1	78736	890450	26142	1	1	0.0285
0	78727	915173	1419	9	0.9999	0.0015
1	78717	915486	1106	19	0.9998	0.0012
2	78708	915648	944	28	0.9996	0.0010
3	78691	915820	772	45	0.9994	8.4225e-04
4	78668	915975	617	68	0.9991	6.7315e-04
5	78631	916097	495	105	0.9987	5.4004e-04
6	78577	916210	382	159	0.9980	4.1676e-04

- PIL-MDQ#8:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	93668	658013	243647	0	1	0.2702
-1	93667	861396	40264	1	1	0.0447
0	93649	899500	2160	19	0.9998	0.0024
1	93640	900262	1398	28	0.9997	0.0016
2	93626	900471	1189	42	0.9996	0.0013
3	93612	900640	1020	56	0.9994	0.0011
4	93595	900780	880	73	0.9992	9.7598e-04
5	93563	900916	744	105	0.9989	8.2514e-04
6	93525	901036	624	143	0.9985	6.9206e-04

- PIL-MDQ#13:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	78500	676674	240154	0	1	0.2619
-1	78500	888638	28190	0	1	0.0307
0	78495	914790	2038	5	0.9999	0.0022
1	78490	915542	1286	10	0.9999	0.0014
2	78485	915785	1043	15	0.9998	0.0011
3	78478	915968	860	22	0.9997	9.3802e-04
4	78457	916139	689	43	0.9995	7.5150e-04
5	78426	916283	545	74	0.9991	5.9444e-04
6	78378	916411	417	122	0.9984	4.5483e-04

- PIL-TBK#1:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	78006	696560	220762	0	1	0.2407
-1	78006	887273	30049	0	1	0.0328
0	78003	915388	1934	3	1	0.0021
1	77996	915980	1342	10	0.9999	0.0015
2	77989	916234	1088	17	0.9998	0.0012
3	77971	916515	807	35	0.9996	8.7973e-04
4	77946	916686	636	60	0.9992	6.9332e-04
5	77892	916842	480	114	0.9985	5.2326e-04
6	77816	916979	343	190	0.9976	3.7391e-04

- PIL-TBK#3:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	77410	690272	227646	0	1	0.2480

-1	77410	889121	28797	0	1	0.0314
0	77397	916646	1272	13	0.9998	0.0014
1	77391	917018	900	19	0.9998	9.8048e-04
2	77383	917200	718	27	0.9997	7.8220e-04
3	77376	917339	579	34	0.9996	6.3078e-04
4	77356	917490	428	54	0.9993	4.6627e-04
5	77329	917583	335	81	0.9990	3.6496e-04
6	77276	917680	238	134	0.9983	2.5928e-04

- PIL-TBK#4:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	107165	635024	253139	0	1	0.2850
-1	107165	854820	33343	0	1	0.0375
0	107140	886453	1710	25	0.9998	0.0019
1	107122	887027	1136	43	0.9996	0.0013
2	107107	887219	944	58	0.9995	0.0011
3	107079	887369	794	86	0.9992	8.9398e-04
4	107042	887526	637	123	0.9989	7.1721e-04
5	107008	887671	492	157	0.9985	5.5395e-04
6	106944	887773	390	221	0.9979	4.3911e-04

- PIL-TBK#7:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	79310	670645	245364	0	1	0.2679
-1	79310	882845	33173	0	1	0.0362
0	79306	914317	1701	4	0.9999	0.0019

1	79291	914981	1037	19	0.9998	0.0011
2	79281	915150	868	29	0.9996	9.4758e-04
3	79268	915307	711	42	0.9995	7.7619e-04
4	79248	915441	577	62	0.9992	6.2990e-04
5	79217	915559	459	93	0.9988	5.0108e-04
6	79175	915659	359	135	0.9983	3.9191e-04

- PIL-TBK#39:

Alpha	TP	TN	FP	FN	Sensibilidad	1-especificidad
-2	84852	715648	194828	0	1	0.2140
-1	84852	872567	37909	0	1	0.0416
0	84829	907206	3270	23	0.9997	0.0036
1	84803	908908	1568	49	0.9994	0.0017
2	84774	909098	1378	78	0.9991	0.0015
3	84746	909270	1206	106	0.9988	0.0013
4	84706	909461	1015	146	0.9983	0.0011
5	84661	909591	885	191	0.9977	9.7202e-04
6	84600	909715	761	252	0.9970	8.3583e-04

Anexo 4. Valores de AUC

$AUC = 1$	$AUC = 1$
$AUC = 1$	$AUC = 1$
$AUC = 1$	$AUC = 1$
$AUC = 1$	$AUC = 1$
$AUC = 1$	$AUC = 1$
$AUC = 1$	$AUC = 1$
$AUC = 1$	$AUC = 1$
$AUC = 1$	$AUC = 1$
$AUC = 1$	$AUC = 1$
$AUC = 1$	$AUC = 1$
$AUC = 1$	$AUC = 1$
$AUC = 1$	$AUC = 1$
$AUC = 1$	