

Component for Renal Carcinoma Detection in Abdominal Tomography Applying Watersheds Transform in the XAVIA PACS System

A. Orellana, L.M. García, Y. Feijoo, G. Ceruto, E.E. Cardero

Abstract— One of the most recognized campaigns in the world is the fight against cancer, being the renal system one of the most affected by this pathology. Renal Cell Carcinoma (RCC), the most common form of kidney cancer in adults, is the sixth leading cause of cancer death. Due to the increased use of imaging techniques, kidney lesions can be diagnosed incidentally in approximately 50% of cases. Cuba bets on the use of technology in health and the University of Informatics Sciences (UCI) has developed a system for the storage, transmission and visualization of medical images (XAVIA PACS), which is deployed in several hospitals in the country, but does not have a component that can perform the detection of RCC in tomographic images, making the diagnosis slower, which translates into fewer possibilities for the patient.

An informatic component was developed for the renal carcinomas detection in abdominal tomography images based on the Watersheds Transform. This component supports the diagnosis of RCC by specialists in the health centers where the XAVIA-PACS was deployed. An experiment was developed comparing the results with images from an international Database (KiTS 2019), in addition their diagnosis value was analyzed by leading medical specialists.

Index Terms— renal carcinoma detection, Watersheds Transform, diagnosis, XAVIA PACS.

I. INTRODUCCIÓN

El cáncer es una de las principales causas de muerte en el mundo, representa alrededor de un 13% de las mismas en el siglo XXI, cifra dada por la Organización Mundial de la Salud. Debido a su incidencia, la mayoría de las personas saben algo de la enfermedad e inevitablemente la mayoría también conoce a alguien que la ha padecido [1].

Este trabajo es sometido a evaluación en IEEE Latin American Transactions el 20 de enero de 2020. Es desarrollado con el apoyo del Centro de Informática Médica CESIM, de la Universidad de las Ciencias Informáticas UCI de la Habana, Cuba.

A. Orellana. Se encuentra vinculado a la Universidad de las Ciencias Informáticas UCI, La Habana, Cuba (e-mail: lmgarcia@uci.cu).

L.M. García. Se encuentra vinculado a la Universidad de las Ciencias Informáticas UCI, La Habana, Cuba (e-mail: aorellana@uci.cu).

Y. Feijoo. Se encuentra vinculado a la Universidad de las Ciencias Informáticas UCI, La Habana, Cuba (e-mail: yfeijoo@uci.cu).

G. Ceruto. Se encuentra vinculado a la Universidad de las Ciencias Informáticas UCI, La Habana, Cuba (e-mail: gceruto@uci.cu).

E.E. Cardero. Se encuentra vinculado a la Universidad de las Ciencias Informáticas UCI, La Habana, Cuba (e-mail: eecardero@uci.cu).

El cáncer de riñón es una enfermedad que generalmente tiene su inicio en este órgano, se produce cuando las células renales de uno o ambos riñones se vuelven cancerosas y luego crecen fuera de control y forman un bulto (llamado tumor). El Carcinoma de Células Renales o CCR es el tipo más común de cáncer renal en los adultos. De forma global, el CCR representa la sexta causa de muerte por cáncer y se estima que es la causa de la muerte de 95.000 personas por año en el mundo. Además, es de destacar que en las últimas 5 décadas se ha apreciado un constante incremento de su incidencia, que está en torno a un 2-4% por año [2].

Los estudios por imagen favorecen el advenimiento de nuevas técnicas quirúrgicas en el tratamiento del CCR y forman parte esencial en la evaluación de esta enfermedad. Las técnicas invasivas utilizadas para su diagnóstico, tales como biopsias quirúrgicas, estudios laparoscópicos o exploraciones, a veces pueden ser reemplazadas por técnicas no invasivas con imagen médica como la Tomografía Axial Computarizada (TAC o CT) o la resonancia magnética (RM o MRI), con beneficios evidentes para el paciente.

Con el fin de ayudar a los radiólogos y cirujanos en una planificación fiable de la intervención, son necesarios nuevos métodos y herramientas precisas y eficientes para localizar y segmentar adecuadamente el órgano de interés y las patologías presentes. La técnica de MRI ofrece mayor información para fines de diagnóstico. Sin embargo, la segmentación del riñón en imágenes de MRI representa un desafío debido a la presencia de artefactos característicos, como los volúmenes parciales, ruido, y en general, baja nitidez y escaso contraste entre órganos, de manera que el límite entre los diferentes tejidos suele ser confuso [3].

Actualmente, debido al aumento en el uso de las técnicas de imagen, las lesiones renales (benignas o malignas) pueden ser diagnosticadas en forma incidental aproximadamente en 50% de los casos. El incremento en las exploraciones abdominales mediante TAC, ha favorecido la identificación, caracterización y estadísticas de los tumores renales descubiertos incidentalmente, así como la corroboración de la sospecha diagnóstica [4].

Las imágenes obtenidas en una TAC, son almacenadas bajo el estándar DICOM (*Digital Imaging and Communication in Medicine*) utilizado internacionalmente y pensado para el

manejo, visualización, almacenamiento, impresión y transmisión de imágenes médicas. El estándar describe el formato de archivos y la especificación de los datos primordiales de un paciente en la imagen, así como el encabezado requeridos, describiendo un lenguaje común a distintos sistemas médicos. De esta forma, las imágenes vienen acompañadas de mediciones, cálculos e información descriptiva relevante para diagnósticos; por ejemplo, se agregan datos demográficos, identificación del paciente e información acerca de las condiciones de adquisición. En algunos casos se adiciona información del examen, la serie a la que pertenece la imagen y orden que tiene en el estudio [5].

Los sistemas PACS (Archivos de Imágenes y Sistemas de Comunicación) ofrecen una alternativa en el manejo de imágenes digitales en forma eficiente y a gran escala, a través de dispositivos conectados en red. El conjunto de estos dispositivos ofrece una serie de servicios que dan soporte a la operatividad de un área (radiología en el caso de aplicaciones médicas). Entre las características que los sistemas PACS deben ofrecer para obtener una buena aceptación en el medio clínico, se deben considerar: la facilidad, rapidez, seguridad en el acceso de imágenes y la calidad en su presentación [6].

En la Universidad de Ciencias Informáticas (UCI) se desarrollan aplicaciones, investigaciones y servicios para la Salud [7],[8],[9],[10],[11], entre ellos el Sistema para el almacenamiento, transmisión y visualización de imágenes médicas XAVIA PACS. Este sistema cuenta con un visor de propósito general, con varias funcionalidades para el manejo de imágenes como la reconstrucción multiplanar y tridimensional de estudios tomográficos, permite determinar el área y perímetro de cualquier elemento en la imagen médica, y el acceso a una base de datos con las imágenes de todos los pacientes.

A pesar de tener y gestionar un cúmulo importante de imágenes digitales los especialistas médicos no cuentan con una herramienta de apoyo que les permita obtener una mejor apreciación de la patología, lo que se traduce en un aumento de tiempo para determinar el diagnóstico del paciente. Este hecho disminuye el número de casos que se pueden atender en los hospitales y la posibilidad de gastar más recursos al repetir exámenes por deficiencias en la calidad del resultado. Además, desde el sistema no es posible actualmente la segmentación de riñones y la detección de carcinomas renales, lo cual limita sus funcionalidades y las opciones de aprovechamiento de los datos almacenados en el sistema por los especialistas.

La presente investigación tiene como objetivo desarrollar un componente de software para detectar carcinomas renales en imágenes de tomografía abdominal desde el sistema XAVIA-PACS para disminuir el tiempo de diagnóstico de esta patología en Cuba. Para ello es vitalmente importante el preprocesamiento de las imágenes para la selección de algoritmos de segmentación eficientes.

Los métodos científicos utilizados en esta investigación fueron el Histórico Lógico para realizar un análisis crítico valorativo de la información contenida en las fuentes bibliográficas consultadas, con el objetivo de conocer cuáles son las tendencias y cómo se ha comportado el desarrollo de

software en torno a la detección de carcinomas renales en imágenes de tomografía abdominal. El Inductivo Deductivo, para evaluar la problemática existente teniendo en cuenta el funcionamiento del proceso de diagnóstico por imágenes médicas y determinar aspectos particulares a tener en cuenta en la propuesta de solución. Además, se aplicó la Modelación para confeccionar modelos y diagramas que ayudan a la comprensión de los procesos a desarrollar como parte de la investigación. Adicionalmente, se aplicó un experimento para validar los resultados obtenidos por el componente de detección de carcinomas renales, en imágenes de tomografía abdominal.

II. FORMULACIÓN DEL PROBLEMA

La segmentación es la división de una imagen en un conjunto de regiones homogéneas y significativas, de tal manera que los píxeles en cada región particionada poseen un conjunto similar de propiedades o atributos. Estos conjuntos de propiedades de la imagen pueden incluir los niveles de grises, el contraste o propiedades texturales.

La segmentación de imágenes de órganos como el hígado, el páncreas y los riñones en las tomografías computarizadas abdominales son necesarios en la actualidad para los sistemas de diagnóstico asistido por ordenador (CAD) y la asistencia en cirugía laparoscópica. Los tejidos tienen diferentes tamaños y formas dependiendo de los pacientes y la similitud de escala de grises entre el riñón y sus tejidos vecinos, como el hígado y el bazo. La segmentación precisa de los riñones en las secuencias de TAC abdominal es una tarea esencial para la planificación quirúrgica y la cirugía para la extirpación de tumores renales.

Los métodos de segmentación están determinados por el tipo de imagen, la estructura anatómica u objeto a identificar y el objetivo específico que se quiere lograr con el proceso. Elementos como el ruido, volúmenes parciales y movimientos en la imagen, también pueden tener consecuencias significativas en el desempeño de los algoritmos de segmentación, porque cada imagen y tipo de tejido tiene un conjunto de características propias. Existen diversos métodos de segmentación y no es factible la utilización de una técnica genérica que se aplique a todas las situaciones que requieren de procesamiento de la imagen médica. Se utiliza una combinación de las técnicas de segmentación existentes, en función de la imagen y lo que se quiera alcanzar como resultado [12].

La correcta segmentación de imágenes del riñón en TAC abdominal es crucial para la toma de decisiones en procedimientos clínicos [13]. No obstante, la segmentación de imágenes del riñón en TAC abdominal es un trabajo desafiante debido a la similitud entre el parénquima del riñón y las estructuras adyacentes [14].

Para realizar las tareas de segmentación existen algoritmos que aportan diversos resultados, en dependencia de las imágenes con las que trabajen y su funcionamiento particular. Estos métodos se pueden clasificar en dependencia de su nivel de automatización en métodos manuales, semiautomáticos y automáticos.

Segmentación manual: La manera más general y fácil de lograr la segmentación es manualmente dibujando elementos importantes de las estructuras presentes en las imágenes médicas. En este caso, el usuario delinea con alguna herramienta las estructuras relevantes, lo que le da la ventaja de

redibujar cualquier porción y corregir algún error introducido. Este método es robusto (siempre aplicable), pero consume mucho tiempo, cuando se trabaja imágenes muy grandes se vuelve impracticable e impreciso debido a que el usuario generalmente se desvía del contorno deseado y si los objetos son difíciles de delinear, pueden ser difíciles de segmentar.

Segmentación semiautomática: En este tipo de modalidad el ordenador realiza el proceso, pero el usuario interviene en determinados momentos sobre el mismo, como por ejemplo para definir las regiones de interés mediante dispositivos de entrada u otros parámetros, así como para corregir resultados.

Segmentación automática: La segmentación automática, como su nombre lo indica es el tipo de segmentación donde el ordenador realiza todo el proceso de manera automática sobre la imagen objetivo. Es improbable que los métodos de segmentación automática reemplacen alguna vez a los métodos manuales, pero si es probable que se conviertan en elementos cruciales para el análisis de imágenes médicas.

En la presente investigación fue seleccionada la segmentación semiautomática, debido a que el riñón constituye un órgano difícil de identificar de manera automática por la proximidad con otros órganos y tejidos. Esta condición propicia que el especialista determine de forma manual el área comprendida por el riñón y el sistema se encargue de la segmentación de la imagen.

A. Casos Exitosos en la Aplicación de la Segmentación Semiautomática

La segmentación renal en la TAC es un trabajo sustancialmente desafiante debido a que los valores de intensidad del parénquima renal son similares a los de las estructuras adyacentes. Diferentes métodos han sido estudiados a lo largo de los años para la segmentación de estructuras u órganos de interés.

Los métodos más utilizados incluyen modelo deformable, método basado en agrupamiento, crecimiento regional, modelos estadísticos de forma, segmentaciones basadas en el conocimiento y en el conjunto de niveles [15].

Moe and Theingi [16] desarrollaron un algoritmo en *Matlab* para la segmentación efectiva de los riñones en los exámenes abdominales de TAC. Realizaron el pre procesamiento en secuencias y segmentaron las imágenes de los riñones con las más parecidas estructuras morfológicas. La segmentación fue implementada, especificando las regiones de interés (*Region of Interest* o *ROI*) para obtener un exacto volumen del riñón, forma y textura. Como resultado, se observaron 250 imágenes de TAC de 20 pacientes, de los cuales se seleccionaron 14 a 73 imágenes por un experto radiólogo. Se aplicaron umbrales al método de *Canny* para la detección de bordes y el ROI definiendo los bordes de interés, esto permitió la segmentación de los riñones y mostró un mejor resultado en base al gradiente con el 82% para el riñón izquierdo y 89% para el riñón derecho.

En [17] la investigación se centró en implementar un método de segmentación semiautomática. Definen que la segmentación de las imágenes de nivel gris se utiliza para proporcionar información como la estructura anatómica y la identificación de la Región de Interés, es decir, localizar tumores, lesiones y otras anomalías. Determinan que los métodos basados exclusivamente en imágenes realizan segmentación basada únicamente en la información disponible en la imagen, entre

ellas se incluyen los umbrales, la región de crecimiento, operaciones morfológicas, conjuntos de niveles de contornos activos, conectividad difusa y cortes de gráficos.

En [18] afirman que los procesamientos morfológicos de imágenes son importantes en la extracción y filtrado de imágenes. Las imágenes usadas en su investigación fueron pre procesadas utilizando las técnicas de escala de grises, ecualización de histogramas y filtrado, donde las características del procesamiento de imágenes ayudaron a generar una plantilla que conduce a un menor número de iteraciones que se realizan en la imagen. Luego se realiza la segmentación de umbrales en la plantilla para extraer la región deseada, y finalmente la sustracción de imágenes se usó para obtener la región que contiene el riñón extraído de la imagen de la tomografía.

En todos los casos el preprocesamiento de la imagen constituye un paso importante, donde influye la precisión en la detección de estructuras. En el sistema XAVIA PACS, el preprocesamiento se realiza a partir de transformaciones a la imagen con el objetivo de eliminar ruido y armonizarla en caso de sufrir diferencias en niveles de exposición en distintos puntos; a estas condiciones se ajusta el presente trabajo. Además, se resaltan bordes para que en fases posteriores se puedan delimitar con mayor facilidad las diferentes estructuras representadas en la imagen.

B. Métodos y Algoritmos para Segmentación Semiautomática

La Transformada *Watersheds* es un método de segmentación que se basa en el análisis de una representación tridimensional de la superficie de intensidad en una imagen. La palabra *Watersheds* designa las crestas que dividen las áreas de drenaje en un sistema hidrográfico, asociando el concepto de cuenca, o área geográfica que drena hacia un río o embalse [19-20]. El algoritmo se define en un proceso morfológico combinado con una segmentación basada en bordes, para producir una técnica híbrida. *Watersheds* se aplica cuando se desea segmentar una imagen, pero no se puede determinar el fondo de la misma. Convierte las líneas de una imagen en montañas y las regiones uniformes en valles que pueden ser usados para segmentar objetos.

Por otra parte, *K-means* es uno de los algoritmos de aprendizaje sin supervisión más simples. Este algoritmo resuelve el conocido problema de agrupación, sigue una manera fácil de clasificar un conjunto de datos, a partir de un número diferente de agrupaciones. Después de leer y mostrar la imagen original, especifica la dirección del elemento estructural con su diámetro y reconstruye la imagen. Luego reconstruye la salida y complementa el resultado. Después, determina el número de grupos, se remodela la imagen y se crea un segmento de imagen, los últimos pasos se encargan de especificar el tumor.

El algoritmo *Fuzzy c-means* plantea técnicas analíticas de *clustering* "difuso", se basa en la optimización de la función objetivo o alguna modificación de la misma. Este método solo tiene en cuenta la intensidad de la imagen con la salvedad de que las imágenes con ruido presentan problemas. Existen varias modificaciones para aumentar la inmunidad al ruido, pero aún ninguna funciona bien en todos los casos. La clasificación probabilística es sensible a la estimación precisa de la función de densidad de probabilidad [21].

En el caso del método de los k vecinos más cercanos *KNN* (*k-nearest neighbors*), como todos los métodos de clasificación supervisados, precisa de acceso a parejas de ejemplo y clase conocidas y de otra serie de imágenes para prueba y clasificación, en otras palabras, son necesarios datos de entrenamiento para su clasificador [22].

En la fase de entrenamiento se proporcionan una serie de ejemplos pertenecientes a diferentes clases, de manera que se pueden visualizar los agrupamientos de clases en el espacio de características n -dimensional, siendo n el número de elementos del vector, de características descriptoras. Ante una nueva entrada de la que se extraen dichas características, el clasificador le asigna la clase más común a la que pertenecen sus k vecinos más cercanos, siendo k un valor típicamente pequeño. Los vecinos más cercanos se estiman mediante el cálculo de una distancia, habitualmente la distancia Euclidiana. Estos vecinos más cercanos son aquellos con los que se presenta menor distancia [22].

De los algoritmos investigados, *K-means* y *Watersheds* son los dos más utilizados para tratar la problemática de esta investigación, y en general, en lo que a detección por imagen se refiere. Constituyen algoritmos probados en sistemas de procesamiento de imágenes de primer nivel [22-23].

La investigación proporcionada por [24] compara los algoritmos *Watersheds* y *K-means*, específicamente para la detección de tumores cerebrales, la misma permite dar una aproximación de cual algoritmo permite obtener un mejor resultado, reluciendo en este caso *Watersheds* como más adecuado.

La evaluación de los resultados de un proceso de segmentación mediante la comparación con imágenes de referencia o *ground-truth* exige disponer de imágenes segmentadas en una forma que pueda ser considerada totalmente exacta. El cálculo de los coeficientes de *Dice*, de *Jaccard* y la distancia de *Vinet* son algunos de los métodos de evaluación de los algoritmos de segmentación utilizados para comparar distintos algoritmos de segmentación de imágenes. [23].

El algoritmo *K-means* presenta resultados más acertados y precisos que *Watersheds*, sin embargo, tiene un tiempo de ejecución mayor, esto se traduce en un alto impacto al establecer equilibrio entre precisión de la segmentación y tiempo de ejecución. En este caso [23] recomienda utilizar *Watersheds*. Los autores de esta investigación seleccionan el algoritmo *Watersheds* para identificar carcinomas renales en imágenes del sistema XAVIA PACS, debido a que obtiene un resultado semejante a *K-means*, en un menor tiempo de ejecución, aunque posee mayor complejidad técnica.

C. Transformada Watersheds

La técnica de *Waterseheds* constituye una de las más poderosas herramientas de segmentación aportada por la morfología matemática. Análogamente a otras técnicas de segmentación, el objetivo de la técnica del *Watersheds* es dividir en regiones la imagen de nivel de grises analizada.

En el algoritmo de *watersheds* se usan fuentes simuladas de agua en cada uno de los mínimos locales de luminancia o gradiente en la imagen (a mayor luminancia de los píxeles o mayor gradiente mayor elevación para el terreno simulado, generando mayor separación entre regiones contiguas), que

representan cuencas. Cada cuenca es llenada con agua hasta que ésta alcanza el punto más alto del relieve, formando represas (*watersheds*) en los puntos donde el agua de diversas cuencas se encuentra. Generalmente una de ellas se corresponde con el fondo de la imagen y el resto con los objetos o regiones que se pretende extraer. El objetivo último de esta técnica es determinar los contornos que definen dichos objetos. En este punto el problema es definir qué es contorno y que no lo es. La Fig. 1 constituye un ejemplo de lo anterior.




Fig. 1. Líneas divisorias de agua, cuencas y mínimos. Fuente: adaptado de [25].

III. IMPLEMENTACIÓN DE LA PROPUESTA

Luego de analizar diferentes procedimientos que desarrollaron varios autores de la literatura para realizar un Sistema de Diagnóstico Asistido por Computador (CAD), para la detección y segmentación carcinomas renales, se propone el desarrollo de un componente basado en la Transformada *Watersheds* para el sistema XAVIA PACS, capaz de detectar carcinomas renales en imágenes de tomografía abdominal.

El componente de software propuesto para el sistema XAVIA PACS analiza la imagen seleccionada por el radiólogo, en busca de estructuras de alta densidad dentro de la región abdominal y muestra un resultado de forma semiautomatizada. Para obtener la solución deseada, la imagen de tomografía transita por una serie de pasos, comenzando con una umbralización binaria basada en un umbral adaptativo. Para realizar este procedimiento se utiliza el método automático de *Otsu*, el cual elige umbral óptimo maximizando la varianza entre clases mediante una búsqueda exhaustiva [26].

Existen estructuras que se localizan cerca del borde del abdomen, estas estructuras de densidad similar al cuerpo pueden ser eliminadas tras la umbralización. Luego se señalan las estructuras que pudieran ser de interés mediante un algoritmo ROI y con la asistencia del especialista en radiología. Una vez realizado este paso se procede a separar el riñón de la imagen TAC con la creación de la máscara binaria.

Para separar el riñón de la imagen TAC, es importante crear una máscara que será una imagen binaria (0 o 1). Esta máscara se utiliza para restar las características no deseadas en las imágenes. El riñón aparece blanco, que es el valor de (1) y el fondo, que es la información de escariado, aparece (0). Esta máscara que tiene el tamaño del riñón y su valor y forma difieren de una imagen a otra se aplica sobre la imagen original para descartar la información irrelevante que multiplica la

imagen de la máscara con la imagen de estudio que produjo la imagen enmascarada.

A partir de estos procedimientos se realiza una de las partes más complejas e importantes de la solución, la segmentación, la cual es un proceso de extracción de sujetos o estructuras de interés desde el fondo y entre sí. La segmentación de la TAC implica separar la información importante que se utiliza para estudiar la región de interés del fondo. Aislar objetos en una imagen es una de las operaciones de procesamiento de imágenes más difíciles; la transformación de la cuenca se aplica a menudo para hacer este problema. La *Transformada Watersheds* encuentra cuencas de captación y líneas de cresta en una imagen tratándola como una superficie donde los píxeles de luz son altos y los píxeles oscuros son bajos. La segmentación mediante aplicación de la *Transformada Watersheds* da buenos resultados si puede identificar, o marcar, los objetos de primer plano y las ubicaciones de fondo [27]. Para visualizar lo anterior la Fig.2 representa el proceso desarrollado por los autores.

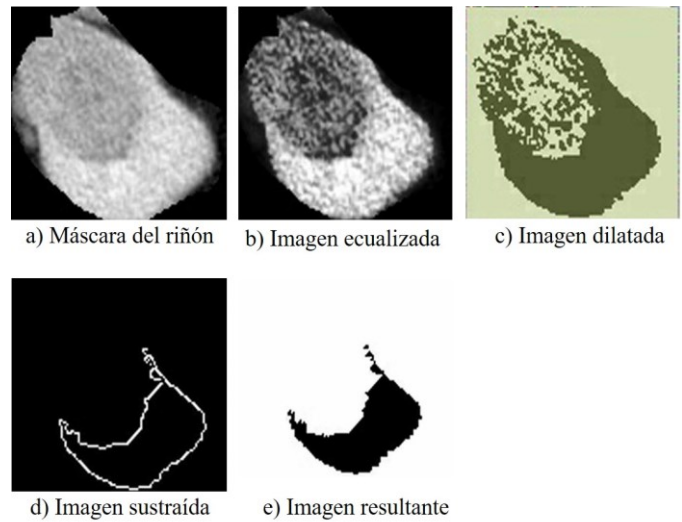


Fig. 2. Resultados arrojados por el componente.

Como modelo arquitectónico del componente para la detección de carcinomas renales en imágenes de tomografía abdominal se utilizó Tuberías y Filtros (*Pipes and Filter*) [28]. La necesidad de procesamiento de un objeto mediante un conjunto de transformaciones comprendidas en fases secuenciales, donde los datos fluyen de uno a otro y se transforman a medida que se mueven a través de la secuencia es cubierta por la arquitectura basada en tuberías y filtros. Los datos de entrada fluyen a través de estas transformaciones hasta convertirlas en salida y cada paso de procesamiento se implementa como una transformación. En la Fig. 3 se muestra la secuencia de técnicas aplicadas a las imágenes de TAC para identificar los carcinomas renales.

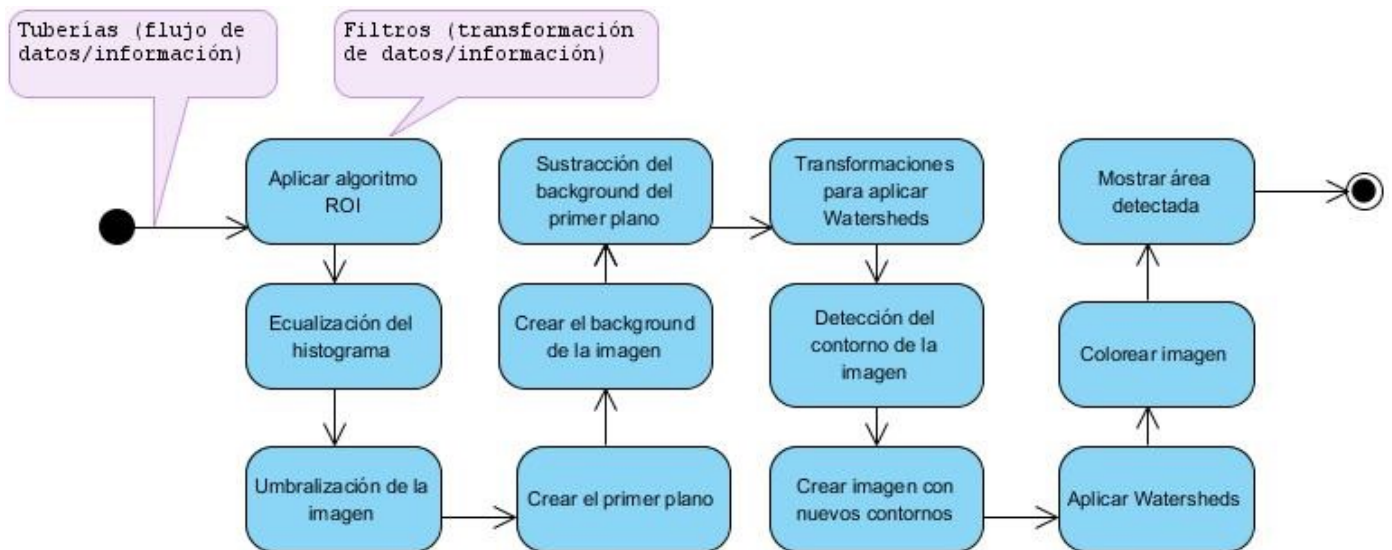


Fig. 3. Arquitectura basada en Tuberías y filtros para la identificación de carcinomas renales en imágenes de TAC.

La implementación de la propuesta estuvo asociada a las siguientes tecnologías y herramientas de desarrollo: Entorno Integrado de Desarrollo *Visual Studio 2017*, La herramienta de Ingeniería de Software Asistida por Computadora *Visual Paradigm. 8.0* Como Lenguaje de programación *C# 6.0* y la biblioteca libre de visión artificial *OpenCV 4.2*. Todo lo

anterior guiado por la Metodología de Desarrollo: *Agile Unified Process (AUP)*.

Para facilitar la comprensión y reproducción de las técnicas y mecanismos utilizados para futuras implementaciones, los autores de esta investigación tienen el propósito de especificar los principales métodos del componente desarrollado. Se hace

énfasis en las técnicas y algoritmos utilizados, dividiéndolos en tres fases.

A. Preprocesamiento de la Imagen.

El especialista selecciona en el visor del sistema PACS la opción Detectar Carcinomas Renales, para que el sistema visualice el área identificada como posible CCR. La imagen en análisis transcurre por una serie de transformaciones que se describen a continuación (a nivel de software constituyen opciones en el espacio de trabajo de la imagen a partir de un menú, estos algoritmos están disponibles en la literatura especializada):

1. El visor ejecuta el *RenalCarcinomaFilter* y envía la imagen sobre la cual desea realizar la detección y los puntos del área específica para su aplicación.
2. El especialista extrae el área señalada de la imagen original al aplicar el método *RoiCut*.
3. Obtener una primera máscara del riñón con el método *Threshold* umbralizando la imagen y resalta las diferencias entre los distintos valores.
4. Obtener el primer plano de la imagen al aplicar *FirstPlane*, a partir del cual se erosiona la imagen.
5. Crear un fondo asociado al primer plano con el uso de *BackGround*, dilatando la imagen con un *kernel* 2x2 de forma elíptica. Este realiza una sustracción de las imágenes del *background* al primer plano y de la misma se obtiene la imagen sobre la que se van a aplicar transformaciones.

B. Transformación de la Imagen y Obtención de Contornos para aplicar Watersheds.

Antes de aplicar *Watersheds* es necesario aplicar algunas transformaciones a las imágenes pre procesadas y realizar la detección de los bordes de las mismas:

1. Realizar transformaciones para preparar la imagen a partir del método *Transforme*, el cual recibe como entrada la sustracción del primer plano y el fondo.
2. Se aplica *FindContours* para identificar el total de marcas de la imagen y determinar los contornos de la imagen.
3. Se dibujan los contornos de la imagen al aplicar la función *DrawContoursw*; el resultado de la misma es la imagen necesaria para aplicar el algoritmo *Watersheds*.

C. Aplicación del algoritmo Watersheds.

Se aplica el algoritmo *Watersheds* de la siguiente forma:

1. Se crea una lista de colores con valores aleatorios, creando un color por cada valor de intensidad encontrado (Fig. 4).
2. Se aplica el algoritmo *Watersheds*.
3. Se pinta la imagen resultante con la lista de colores aleatorios obtenidos usando el método *Paint*.
4. Se obtiene la imagen resultante calculando un promedio entre el resultado del algoritmo y la imagen coloreada.

Algorithm 1: Algoritmo Watersheds

```

entrada: watershedImage, markers, colorTable, componentCount
1 subproceso watershed(watershedImage, markers)
2 {
3   Aplicar algoritmo watershed;
4 }
5 subproceso paint(watershedImage, markers, colorTable,
   componentCount)
6 {
7   while Se encuentra en filas do
8     while Se encuentra en columnas do
9       if Borde de componentCount then
10        textDibujar de negro
11        if Dentro de componentCount then
12          Dibujar de colorTable
13 }

```

Fig. 4. Pseudocódigo correspondiente a los pasos finales del algoritmo *Watersheds*.

Los algoritmos *RoiCut*, *DrawContour*, *FindContours*, *BackGround*, *Treshold*, *FirstPlane* utilizados en esta investigación están integrados al Sistema XAVIA PACS y se encuentran publicados en la literatura a disposición de la comunidad científica.

IV. RESULTADOS

El cáncer a nivel mundial, ha mostrado aumento de incidencia y prevalencia lo que propicia que se potencie el desarrollo de CAD. Con el objetivo de facilitar las investigaciones realizadas y el proceso de comprobación de los resultados obtenidos, se han creado bases de datos que concentran el criterio de un grupo de especialistas médicos, con imágenes y la información referente a las mismas.

A. Composición del Banco de Pruebas

Se utilizó el sistema CAD propuesto por el *Kidney Tumor Segmentation Challenge* (KiTS19) para contrastar sus resultados con los del componente desarrollado en esta investigación. La propuesta del *KiTS19* es una oportunidad de competir entre sistemas *CAD* del mundo, la misma propone un *CAD* especializado en identificar tumores y anomalías en el riñón, el mismo está avalado por especialistas de la Universidad de Minnesota y de Melbourne [29].

El conjunto de imágenes de prueba está integrado por imágenes del *KiTS Challenge Repository* [30], el cual presenta 210 pacientes, de los cuales 102 presentan alguna variante de CCR. Los mismos son obtenidos por distintos equipos que arrojan resultados variados en cuanto calidad de la imagen tanto por las dimensiones como por la imagen en sí misma.

Todos los pacientes que se sometieron a nefrectomía parcial o radical para uno o más tumores renales en el Centro Médico de la Universidad de Minnesota entre 2010 y 2018 fueron candidatos para su inclusión en esta base de datos. Se excluyeron los casos en los que no se pudo encontrar una TC abdominal en fase arterial preoperatoria. De los casos restantes, se seleccionaron 300 al azar [31].

B. Selección de la Muestra Utilizada en el Experimento

Para determinar qué parte de una población debe examinarse se utilizó el muestreo el cual es una herramienta de la

investigación científica que cumple la finalidad de hacer inferencias sobre una población. El Muestreo Intencional es un tipo de muestreo no probabilístico, el investigador selecciona los elementos que son representativos o con posibilidades de brindar mayor información.

Para detectar CCR se realizó un experimento de tipo Intencional. Se seleccionaron casos al azar, entre ellos: case_00020, case_0059, case_0102, case_00149, case_00173, case_00200, los cuales están contenidos en las nueve series utilizadas para validar el componente desarrollado por *KiTS* [28].

C. Análisis de los Resultados Obtenidos

Se obtuvo los resultados del componente desarrollado y luego por la propuesta desarrollada por el *KiTS*. Las imágenes seleccionadas presentan distintas características, entre ellas posición del *CCR*, su forma, variante y tamaño, también presentan distintas calidades de imagen.

La Fig. 5 muestra los resultados de aplicar ambos componentes, resultado necesario para contrastar ambos valores para poder determinar el grado con el que la presente investigación tiene valor diagnóstico.




Fig. 5. Resultados arrojados por el componente desarrollado y el *KiTS*.

1ra columna (Imágenes de muestra seleccionada), 2da columna (Resultado arrojado por el componente desarrollado) y 3ra columna (Resultado arrojado por el *KiTS*)

A simple vista se aprecia que el componente desarrollado basado en la *Transformada Watersheds* logra un valor aproximado al de *KiTS*, siendo este un sistema de primer nivel. En la fila cinco, columna B, el componente logró detectar estructuras que la propuesta del *KiTS* despreció. En los 5 casos se logró detectar *CCR* sin la ocurrencia de falsos positivos dentro del experimento. Por tanto, los resultados arrojados son fiables para establecer que el componente propuesto en la investigación detecta *CCR* y tiene valor diagnóstico. Como limitante de este trabajo se encuentra que no se ha aplicado en contexto real en un hospital, lo cual conduce a una nueva fase de investigación.

D. Integración al Sistema XAVIA PACS

El Sistema para la Visualización, Transmisión y Almacenamiento de Imágenes Médicas XAVIA PACS parte del Proyecto Desarrollo de la Plataforma para la gestión de la información imagenológica cubana. Es un sistema que propicia la gestión de las imágenes digitales y se encuentra implantado en prestigiosos hospitales cubanos con alta aceptación de los especialistas en salud.

Para la realización de las pruebas de integración del componente informático para la detección de carcinomas renales en imágenes de tomografías abdominal sobre el sistema XAVIA-PACS se eligió el tipo de prueba incremental, con un enfoque ascendente. Esta permite probar el programa en pequeñas porciones, lo que facilita la detección de los errores existentes.

Para probar la integración del componente y así mostrar la detección del *CCR*, se realizaron los siguientes pasos (Fig. 6):

1. Se ejecutó el XAVIA PACS y se seleccionó una TAC de abdomen con *CCR*.
2. Se seleccionó la opción Detectar carcinomas renales y se seleccionó el área del riñón.




Fig. 6. Componente integrado al sistema XAVIA PACS donde detecta *CCR* en una imagen de tomografía abdominal.

Tras haber ejecutado el caso de prueba diseñado para la prueba de integración, el cual arrojó resultados satisfactorios, se demostró la correcta integración del componente con el visor XAVIA-PACS. Así mismo, este componente puede funcionar de manera independiente o integrado a visores de imágenes DICOM en otras plataformas. Una restricción del resultado es que solo admite imágenes DICOM, teniendo en cuenta que es desarrollado para cumplir los criterios del XAVIA PACS.

Para verificar el adecuado funcionamiento del componente para la detección de carcinomas renales, se hace necesario el cálculo de indicadores para evaluar el rendimiento del proceso de diagnóstico. Para medir el rendimiento se relacionan los indicadores sensibilidad (S), especificidad (E) y precisión (P). La sensibilidad y la especificidad son útiles para medir la efectividad. La sensibilidad de una prueba diagnóstica es su habilidad para detectar individuos con cáncer. La especificidad es su habilidad para identificar aquellos individuos que no tienen cáncer. La precisión relaciona los indicadores anteriores y brinda una idea general de la eficacia del resultado.

En [32] se define un conjunto de etiquetas asociadas a distintos intervalos de precisión que van desde "No es de utilidad" para valores inferiores al 50% hasta "Excelente" para valores superiores al 90%. A nivel internacional los valores de precisión comprendidos entre el 80% y el 100% son considerados altos valores de precisión del proceso de diagnóstico.

El muestreo es una herramienta de la investigación que permite seleccionar un subgrupo de la población de interés. Los elementos en el muestro accidental son seleccionados de forma arbitraria sin tener en cuenta un criterio especial, hasta que se alcance la cantidad deseada.

La población está compuesta por las imágenes que aparecen en KiTS. De esta se seleccionaron 182 clasificadas como CCR. Una vez obtenidas las imágenes se realizó el experimento obteniéndose los resultados relacionados en la Tabla I para 9 iteraciones.

TABLA I.
RESULTADOS DEL EXPERIMENTO PARA CALCULAR LA PRECISIÓN EN LA
DETECCIÓN DE CCR.

Sensibilidad	Especificidad	Precisión	FP	FN
83,72	77,27	81,53	7	5
88,88	68,96	80	4	9
90,62	69,69	80	3	10
85,29	83,87	84,61	5	5
85,36	87,5	86,15	6	3
93,18	77,14	81,53	3	9
84,84	78,12	81,53	5	7
89,74	80,76	86,15	4	5
81,81	76,19	80	8	5

Los resultados del experimento con la base de las instancias seleccionadas permitieron alcanzar un 82,38% de precisión considerándose un alto valor según lo definido en [32]. Además, para los indicadores Sensibilidad y especificidad se obtuvieron valores de 87.04 y 76.01 respectivamente.

E. Pruebas de Aceptación de Tipo Alfa

Estas pruebas son realizadas por el cliente para certificar que el sistema es válido para él. Son pruebas funcionales sobre el sistema una vez terminado y buscan comprobar que se satisfacen los requisitos establecidos.

Se procedió a su validación por una especialista en imagenología del Hospital Hermanos Ameijeiras de la Habana. Fueron mostrados 10 casos con presencia de CCR en distintos lugares del parénquima del riñón, variadas morfologías y calidades de imagen. Como resultado la especialista comprobó que el sistema detecta correctamente el CCR y la zona del parénquima renal que tiene alguna afectación, dígame necrosis o

hematomas, por lo que esta acredita que el componente informático desarrollado tiene valor diagnóstico y puede ser utilizado en el visor XAVIA-PACS para la detección de CCR en imágenes de tomografía abdominal.

F. CONCLUSIONES

Los métodos científicos empleados posibilitaron fundamentar teórica y metodológicamente la presente investigación.

El análisis de algoritmos para la detección de CCR propició seleccionar *Watersheds* como el más pertinente para la propuesta de solución.

La comparación de los resultados de aplicar el componente propició asegurar que es capaz de detectar CCR en imágenes de tomografía abdominal utilizando la Transformada *Watersheds* y similar a la propuesta KiTS, se obtuvo un 82,38% de precisión pudiéndose afirmar como alto teniendo en cuenta indicadores de la literatura.

La aplicación de pruebas de software mostró el correcto funcionamiento de la propuesta, comprobándose el valor diagnóstico del componente y la ausencia de errores.

La solución XAVIA PACS cuenta con un componente capaz de identificar estructuras cancerígenas presentes en las imágenes de tomografía del abdomen, siendo de ayuda para el especialista como consulta de segunda opinión.

REFERENCIAS

- [1] Patuzzi, J., et al. (2012). Haciendo Visible El Cáncer. El Rol del Diagnóstico por imágenes en oncología. ESR-Sociedad Europea de Radiología [en línea], Disponible en: <https://www.internationaldayofradiology.com/>.
- [2] Trigo, J.M. y Bellmunt, J. (2008). Estrategias actuales en el tratamiento del carcinoma de células renales: fármacos dirigidos a dianas moleculares., ISSN 380-92.
- [3] American Cancer Society. (2017). Kidney Cancer Early Detection, Diagnosis, and Staging. Atlanta, Ga: American Cancer Society: s.n. ISBN 1-800-227-2345.
- [4] Mirjana, R. (2007). Kidney cancer. Department of Radiotherapy, Institute of Oncology Ljubljana, Slovenia: Radiol Oncol. ISBN 10019-007-0012.
- [5] Pascau, J. (2017). DICOM, almacenamiento y comunicación de imágenes médicas. Hospital General Universitario Gregorio Marañón: s.n.
- [6] Grupo PAS. (2018). Estándar y Protocolo de Imágenes Médicas DICOM. Universidad de Deusto: s.n.
- [7] Orellana, A., Pérez-Alfonso, D., & Larrea, O. U. (2015). Analysis of Hospital Processes with Process Mining Techniques. MEDINFO 2015: EHealth-enabled Health: Proceedings of the 15th World Congress on Health and Biomedical Informatics. vol. 216, pp. 310-314. 978-161449-564-7
- [8] Orellana, A., Ramirez, Y. E. P., & Larrea, O. U. A. (2015). Process Mining in Healthcare: Analysis and Modeling of Processes in the Emergency Area. IEEE Latin America Transactions, vol. 13 no. 5, pp. 1612-1618.
- [9] Orellana, A., Armenteros, O. U. L., Ramirez, Y. E. P., & Alfonso, D. P. (2016). Inductive visual miner plugin customization for the detection of eventualities in the processes of a hospital information system. IEEE Latin America Transactions, vol. 14 no.4, pp. 1930-1936.
- [10] Orellana, A., Sentí, V. E. & Alfonso, D. P. (2018). MVD. A Model for the Detection of Variability in Hospital Processes Using Process Mining. Latin America Transactions, IEEE, vol. 16 no. 3. pp. 968-976. ISSN 1548-0992
- [11] Orellana, A., Domínguez, L. C., & Martínez, A. V. (2018). Analysis of Hospital Processes from the Time Perspective Using Process Mining. IEEE Latin America Transactions, vol. 16 no. 6, pp. 1741-1748.
- [12] Ruíz, M.D., Álvarez, E.E.C. y Correa, L.M.C. (2017). Algoritmo para la disminución de falsos positivos en la identificación de nódulos pulmonares solitarios en imágenes de tomografía de tórax.

- [13] Ali, A.H., Hassan, E.H. y Nazzar, A. (2016). Analysis and Classification of Kidney Images Using Watershed Segmentation and Texture Properties., vol. 5, pp. 592-604. ISSN 2320-088X.
- [14] Song, H., Wang, S., Zhang, Q. y Kang, W. (2014). Kidney segmentation in CT sequences using SKFCM and improved GrowCut algorithm [en línea]. Belfast, UK.: From IEEE International Conference on Bioinformatics and Biomedicine (BIBM 2014). Disponible en: <http://www.biomedcentral.com/1752-0509/9/S5/S5>.
- [15] Faleh H.M., Nada A.M. y Aabdul H.I. (2017). Automated Methods to Segment Kidneys and Detect Tumors Using CT Images. S.I.: Iraqi Journal of Science. ISBN 0067-2904.
- [16] Myint, T. y Myint, M. (2015). Effective Kidney segmentation using gradient base approach in abdominal CT images. S.I.:
- [17] Mredhula. L (2017). Detection and classification of tumors in CT images. Research Scholar, Department of CSE, Sathyabama University: Indian Journal of Computer Science and Engineering (IJCSSE).
- [18] Natarajan, P., Singh, B.P., Dwivedi, S. y Nanc, S. (2013). Kidney Segmentation in CT - Scan Image. International Journal of Scientific & Engineering Researc.
- [19] Dougherty, E.R. y Lotufo, R.A. (2003). Hands-on morphological image processing. Washington, Estados Unidos: Spie Press.
- [20] González, R.C. y Woods, R.E. (2008). Digital image processing. 3ra. Pearson Prentice Hall, New Jersey: s.n.
- [21] Mengual, P.C. (2016). Segmentación automática del cerebro mediante técnicas de tratamiento digital de imagen. Universidad Politécnica De Valencia: s.n.
- [22] Bericurtua, A. (2016). Desarrollo de algoritmos de procesamiento de imagen avanzado para interpretación de imágenes médicas. Aplicación a segmentación de hígado sobre imágenes de Resonancia Magnética multisequencia. Tesis doctoral. Bilbao: Universidad de País Vasco (UPV/EHU).
- [23] Rodríguez, Y. (2012). Comparación de Algoritmos de Segmentación sobre Imágenes de Hematología Celular [en línea]. Trabajo de Diploma. Santa Clara: Universidad Marta Abreu de las Villas. Disponible en: <http://dspace.uclv.edu.cu/bitstream/handle/123456789/2631/Yusnielys%20Rodr%C3%adguez%20Gutierrez.pdf?sequence=1&isAllowed=y>.
- [24] Mustafa D., I. y Mawia A., H. (2016). A Comparison between Different Segmentation Techniques used in Medical Imaging [en línea]. Sudan University of Science and Technology, Khartoum, Sudan: s.n. Disponible en: <http://article.sapub.org/10.5923.j.ajbe.20160602.03.html>.
- [25] Beucher, S. (1992). The watershed transformation applied to image segmentation. Scanning microscopy-supplement-pp. 299-299.
- [26] Xu, X., Xu, S., Jin, L., & Song, E. (2011). Characteristic analysis of Otsu threshold and its applications. Pattern recognition letters, vol. 32, no. 7, pp. 956-961.
- [27] Sharma, K., Rupprecht, C., Caroli, A., Aparicio, M.C. y Remuzzi, A. (2017). Automatic Segmentation of Kidneys using Deep Learning for Total Kidney Volume Quantification in Autosomal Dominant Polycystic Kidney Disease. Scientific Reports. s.n.
- [28] Larman, C. (2003). UML y Patronos. S.I.: s.n.
- [29] KITS. (2019). KiTS19 Challenge Homepage [en línea]. S.I.: s.n. Disponible en: <https://kits19.grand-challenge.org/>.
- [30] KITS CHALLENGE REPOSITORY. (2019). S.I.: s.n. Disponible en: <https://github.com/neheller/kits19/tree/master/data>.
- [31] KITS SURGICAL TEAM. (2019). The KiTS19 Challenge Data: 300 Kidney Tumor Cases with Clinical Context, CT Semantic Segmentations, and Surgical Outcomes. S.I.: s.n.
- [32] ALTMAN, D. G. y BLAND, J. M. (1994). Diagnostic tests 1: Sensitivity and specificity. British Medical Journal. vol.308, pp.1552-1554.



Luis Miguel García Portal graduado de Ingeniero en Ciencias Informáticas en la Universidad de las Ciencias Informáticas UCI, La Habana, Cuba. Desarrollador de aplicaciones informáticas para el sector sanitario, especialista en tratamiento de imágenes médicas.



Yosvel Feijoo Ortiz graduado de Ingeniero en Ciencias Informáticas en la Universidad de las Ciencias Informáticas UCI, La Habana, Cuba. Desarrollador de aplicaciones informáticas para el sector sanitario, especialista en tratamiento de imágenes médicas.



Gerardo Ceruto Marrero graduado de Ingeniero en Ciencias Informáticas en la Universidad de las Ciencias Informáticas UCI, La Habana, Cuba. Desarrollador de aplicaciones informáticas para el sector sanitario, especialista en tratamiento de imágenes médicas.



Emilio E Cardero Álvarez graduado de Ingeniero en Ciencias Informáticas en la Universidad de las Ciencias Informáticas UCI, La Habana, Cuba. Desarrollador de aplicaciones informáticas para el sector sanitario, especialista en tratamiento de imágenes médicas.



Arturo Orellana García graduado de Ingeniero en Ciencias Informáticas en la Universidad de las Ciencias Informáticas, La Habana, Cuba en el año 2012. Obtuvo el grado de Máster en Informática Aplicada en 2015 y PhD en 2016. Investigador de tecnologías y Sistemas de Información de Salud.