

# SEGMENTACIÓN DE ELEMENTOS ANATÓMICOS EN IMÁGENES MICROSCÓPICAS DE MADERA USANDO TÉCNICAS DE VISIÓN ARTIFICIAL

## SEGMENTATION OF ANATOMICAL ELEMENTS IN WOOD MICROSCOPIC IMAGES USING ARTIFICIAL VISION TECHNIQUES

Luis Fernando Espinosa <sup>1,✉</sup>, Rodrigo Javier Herrera<sup>2</sup>, Cesar Polanco-Tapia<sup>3</sup>

### RESUMEN

Las características de los elementos que componen las imágenes microscópicas de madera son claves para la identificación de la especie de la cual proviene una muestra. En este artículo se presentó un método novedoso de segmentación de poros, radios y fibras. La metodología propuesta utilizó un conjunto de algoritmos de visión artificial acordes a las características de cada elemento. Para los poros se usó un descriptor de texturas, un algoritmo de agrupamiento y contornos activos; para los radios se utilizaron morfología matemática y filtros de Gabor para destacarlos y para segmentar se procedió en tres pasos: agrupamiento *mean-shift*, un muestrador de Gibbs y apertura de área; la fibra fue tomada como el excedente de los procesos de segmentación anteriores. Resultados experimentales con 18 muestras segmentadas manualmente de la especie *Gaiadendron punctatum* demostraron la eficiencia del método propuesto, usando estadísticas de desempeño tales como la precisión a nivel global y la sensibilidad y especificidad por cada elemento.

**Palabras Claves:** *Gaiadendron punctatum*, identificación automática de maderas, microestructura de la madera, procesamiento digital de imágenes, segmentación de imágenes.

### ABSTRACT

The characteristics of the elements of wood microscopic images are keys to identify the species of which comes a sample. This paper presented a novel segmentation method for pores, rays and fiber. The proposed methodology uses a set of algorithms from digital image processing consistent with the characteristics of each element. For pores, a texture descriptor, a clustering algorithm and active contours were used; for radios, mathematical morphology and Gabor filters were used for emphasis and to segment proceeds in three steps: mean-shift clustering, a Gibbs sampler and area opening; the fiber was taken as the surplus of previous segmentation processes. Experimental results with 18 manually segmented samples of *Gaiadendron punctatum* species demonstrate the efficiency of the proposed method, using performance statistics such as the overall success rate and the specificity and sensibility by element.

**Keywords:** Digital image processing, *Gaiadendron punctatum*, image segmentation, wood automatic identification, wood microstructure.

<sup>1</sup> Estudiante de Maestría en Automatización Industrial, Universidad Nacional de Colombia, Bogotá D.C., Colombia.

<sup>2</sup> Profesor de la Facultad de Ingeniería, Universidad Distrital Francisco José de Caldas, Grupo de investigación IDEAS (Aplicaciones en señales), Bogotá D.C., Colombia.

<sup>3</sup> Profesor asistente de la Facultad del Medio Ambiente y Recursos Naturales, Universidad Distrital Francisco José de Caldas; Laboratorio de Tecnología de Maderas, Bogotá D.C., Colombia.

✉ Autor para correspondencia: lfespinosam@unal.edu.co

Recibido: 10.06.2014 Aceptado: 01.06.2015

## INTRODUCCIÓN

Conocer la especie de la cual proviene un leño puede representar la oportunidad para evitar que sean traficadas especies maderables en peligro, también las cualidades anatómicas de cada especie condicionan posteriores aplicaciones y los procesos que son aplicables a cada tipo de madera para hacerla útil. El proceso de identificación de maderas tiene como principal objetivo relacionar una muestra con un nombre, a partir de un conjunto de características que pueden ser macroscópicas o microscópicas. A nivel macroscópico, muchas características no son claramente categorizadas (textura, granos, figura, etc.) y requieren un nivel de experiencia muy alto para obtener resultados confiables. A nivel microscópico existen varias normas utilizadas en el estudio de la madera, de las cuales se destaca la lista de características anatómicas para la identificación de maderas duras del IAWA (*International Association of Wood Anatomists*) (Wheeler *et al.* 1989), asociadas a los elementos microanatómicos presentes en este tipo de maderas: poros, radios fibras y parénquima. Este proceso de caracterización es el paso fundamental en el objetivo de identificar una especie bajo estudio. Varios estudios han presentado caracterizaciones a nivel microscópico de diferentes especies (Rallo *et al.* 2007, Pereira-Goncalves *et al.* 2014), realizando una inspección visual para determinar las propiedades asociadas a la microestructura de cada muestra.


Con el objetivo de reducir los errores de caracterización y estandarizar el proceso, desde tiempo atrás se vienen usando sistemas computarizados que asisten esta labor (Espinoza y Miller 1991, Koch *et al.* 2011, Sarmiento *et al.* 2011). Una etapa fundamental consiste en la separación automática de los elementos de microanatomía en imágenes obtenidas para su posterior caracterización (Hermanson y Wiedenhoef 2012). Se han propuesto varios métodos de segmentación de imágenes de microanatomía utilizando técnicas de procesamiento digital de imágenes, en especial para los poros. Por ejemplo, se ha utilizado morfología matemática y el método de umbralización de Otsu para la segmentación de poros (Pan y Kudo 2011), con versiones que mejoran el proceso de selección del umbral usando un algoritmo genético (Wang *et al.* 2009). Una combinación entre métodos de tratamiento de imagen y técnicas estadísticas ha sido utilizada para realizar un análisis cuantitativo de las características de los vasos en diferentes especies (Chen y Evans 2010). Existen también sistemas semiautomáticos para la caracterización de poros y anillos de crecimiento, como es el caso del sistema ROXAS, que requiere una serie de parámetros específicos de la especie a evaluar para la identificación de estos elementos (Wegner *et al.* 2013). Otros elementos han sido caracterizados en este tipo de imágenes, como lo son la organización de las células de fibra en el corte transversal, identificados automáticamente usando el algoritmo watershed (Brunel *et al.* 2012). Además se han presentado propuestas de segmentación de múltiples elementos en imágenes de microanatomía del plano transversal, usando clasificación multiescala basado en operaciones morfológicas y técnicas de agrupamiento (Roncancio *et al.* 2003). Más aun, se han obtenido características de poros (usando el método de Otsu) y características relacionadas con la textura (métodos de extracción GLCM y LBP) para la clasificación de diferentes especies maderables usando una máquina de vectores de soporte (Martins *et al.* 2013).

En este artículo se presenta un nuevo método de segmentación para 3 elementos que componen las imágenes microscópicas de maderas: poros, radios y fibra, utilizando algoritmos de procesamiento de imágenes relacionados con descripción de texturas, agrupamiento y análisis de contornos. La metodología propuesta es evaluada sobre diferentes muestras de la especie *Gaiadendron punctatum* y comparada con segmentaciones manuales.

## MATERIALES Y MÉTODOS


### Base de datos de fotografías

Las fotografías utilizadas en este estudio corresponden a la especie *Gaiadendron punctatum* (Ruiz & Pav.) G. Don, de la cual se obtuvieron un total de 18 imágenes. Todas fueron obtenidas usando un microscopio Axiostar Plus con lentes Carl Zeiss, usando una escala de 10x, al cual se adaptó una cámara fotográfica digital Canon Power Shot G9 – 610, configurada para almacenar las capturas con una resolución de 12 megapíxeles. La Figura 1 presenta un ejemplo de las fotografías utilizadas en este estudio. Este conjunto de fotografías fue obtenido de tres muestras de campo en el Laboratorio de Maderas de la Universidad Distrital Francisco José de Caldas. Esta especie proviene tanto de la zona urbana como rural de la ciudad de Bogotá D.C., Colombia.



**Figura 1.** Ejemplo de fotografía de la estructura microanatómica del corte transversal de *Gaiadendron punctatum*.

En la Figura 2 se presenta una región en detalle de la fotografía mostrada como ejemplo en la Figura 1, indicando las tres microestructuras a identificar: poros, radio y fibra. Cada estructura posee características diferentes en forma, tamaño y textura, las cuales son utilizadas para definir las técnicas de segmentación de imagen apropiadas.




**Figura 2.** Elementos de microanatomía en fotografía de corte transversal de *Gaiadendron punctatum*.

### Preprocesamiento de las imágenes

Para esta implementación se descartó la información relativa al color, así que se realizó una transformación del espacio RGB a escala de grises. De las imágenes se extrae la región de interés, la cual corresponde sólo a la sección de la imagen que no está afectada por el borde circular de color negro generado por el proceso de captura en el microscopio (Figura 2).

La captura de fotografías para realizar caracterización microanatómica de maderas está expuesta a factores que contaminan con ruido la imagen digital resultante. El factor que está ligado a las variaciones de iluminación presentes sobre la muestra, genera sobre la imagen un cambio de intensidades que distorsiona la información; dado que estas podrían influir en el desempeño de los métodos de segmentación que serán utilizados para el análisis, se hace indispensable aplicar alguna o algunas técnicas de preprocesamiento a las imágenes con el fin de reducir los efectos negativos del ruido producido por una iluminación no uniforme. Una revisión de las imágenes utilizadas en este proyecto evidencia una iluminación no uniforme como el ruido que predomina. Además se observa un contraste reducido a partir de análisis del histograma.

Considerando un modelo multiplicativo para el efecto de la iluminación en la imagen final, el modelo de filtro que mejor se ajusta es el homomórfico (Gonzalez y Woods 1996). El filtrado homomórfico implementado utiliza un filtro Butterworth pasa-altos. En la Figura 3 se presenta un ejemplo de la imagen que resulta al aplicar los procesos descritos.



**Figura 3.** Imagen resultante del preprocesamiento de una fotografía de la base de datos.

### Metodología de segmentación

La labor de segmentación en imágenes consiste en agrupar píxeles en regiones donde se comparten ciertas características. A continuación se describen las técnicas de segmentación utilizadas para separar tres elementos de las imágenes de microanatomía de madera: poros, radios, y fibra. La metodología utilizada para llevar a cabo este proceso supone un desarrollo escalonado, empezando por separar los poros de la imagen por considerarse como el elemento más sencillo de distinguir, seguido por la separación de los radios que implica un mayor nivel de complejidad, y por último la fibra, la cual se tomará como el residuo de las segmentaciones anteriores.

### Segmentación de poros

Los poros se distinguen de los demás elementos por tener un interior sin textura y además por tener bordes bien definidos. La metodología propuesta para segmentar los poros utiliza un descriptor de texturas GLCM (*Gray Level Cooccurrence Matrix*), para extraer características que permitan separar las regiones utilizando un algoritmo de agrupamiento no supervisado (k-medias) y finalmente, aproximar mejor el borde de los poros usando una técnica de contornos deformables (Figura 4).



**Figura 4.** Metodología para la segmentación de poros.

Una de las maneras posibles para reconocer diferentes texturas consiste en evaluar la disposición espacial de los valores relativos de los niveles de intensidad de gris. Por ejemplo, la obtención del histograma normalizado de una imagen informa acerca de la probabilidad de tener cierto nivel de intensidad de gris de un píxel. Si en cambio se calcula la probabilidad de cierto grupo de píxeles de tener ciertas intensidades de gris, se habla de una probabilidad conjunta de ocurrencia.

La Matriz de Coocurrencia de Niveles de Gris (GLCM) contiene información acerca de la frecuencia con que se presentan cambios de intensidades de gris entre pares de píxeles, a cierta distancia y con cierto ángulo. La GLCM es una tabulación de los valores de la frecuencia de ocurrencia de diferentes combinaciones de niveles de gris en una imagen. El uso común de la matriz de coocurrencia para reconocer texturas no implica un uso directo de la matriz obtenida, sino el cálculo de ciertas variables estadísticas. Haralick *et al.* 1973, describen 14 características estadísticas derivadas de la GLCM. A continuación se presentan las ecuaciones que definen tres de estas, utilizadas para este estudio:

$$\text{Energía: } f_1 = \sum_i \sum_j p(i, j)^2 \quad (1)$$

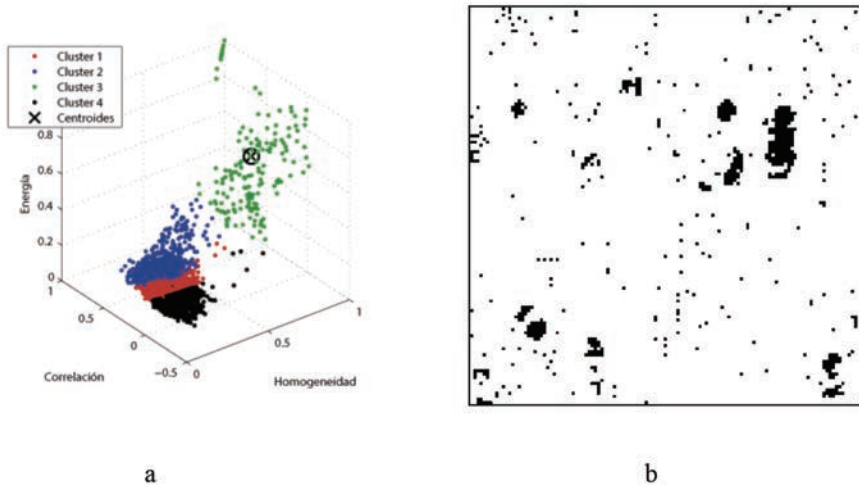
$$\text{Correlación: } f_3 = \frac{\sum_i \sum_j (ij) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2)$$

$$\text{Homogeneidad: } f_5 = \sum_i \sum_j \frac{1}{1 + (i - j)^2} p(i, j) \quad (3)$$

Donde  $p(i, j)$  corresponde a la normalización de la matriz de coocurrencia, dividiendo esta por el número total de pares de píxeles considerados. Con el uso de la Matriz de Coocurrencia se obtienen grandes conjuntos de datos que cuantifican características de las texturas. Dependiendo del tipo de textura, un píxel exhibirá ciertos valores en las características calculadas, similar para todos aquellos píxeles que componen una misma región.

Por cada píxel se obtiene un vector de características, así que el número total de píxeles que componen la imagen puede ser considerado como igual número de observaciones para cada una de las características, en este caso las variables. Entonces es posible utilizar algoritmos de agrupamiento para encontrar los conjuntos de datos que comparten propiedades comunes y que finalmente corresponden a elementos similares en la imagen.

El algoritmo de k-medias es uno de los métodos de clasificación más antiguos pero aun así con un uso muy extendido (Jain *et al.* 1999). El criterio de selección que utiliza este método es el error cuadrático, el cual tiende a trabajar bien con grupos de datos separados y compactos. En la Figura 5 se presentan la primera aproximación de segmentación de poros, al procesar la imagen de la Figura 3.




**Figura 5.** Obtención de características derivadas de la GLCM y agrupamiento. a) Espacio de características agrupado, b) píxeles clasificados como poros en negro.

Para obtener una segmentación de los poros más precisa, se utiliza la técnica de contornos activos, con la cual se deforman los bordes ya encontrados para minimizar la distancia a los bordes reales. Estos detectores de contornos se mueven hacia su solución final de forma iterativa, evolucionando curvas alrededor del objeto a ser detectado moviéndose hasta alcanzar los bordes del mismo. El problema de segmentación se reduce a encontrar los contornos deformables  $p_1, p_2, \dots, p_n$  que se ajustan mejor al contorno del objeto minimizando la función de energía (Caselles *et al.* 1997):

$$E = \sum_i^n (\alpha_i E_{cont} + \beta_i E_{curv} + \gamma_i E_{imag}) \quad (4)$$


Donde  $E_{cont}$  corresponde a un término de continuidad,  $E_{curv}$  a la curvatura y  $E_{imag}$  corresponde a la energía asociada a la fuerza externa que atrae el contorno. En la Figura 6 se presenta la segmentación de poros que se obtiene después de aplicar contornos activos.



**Figura 6.** Comparación de la segmentación final de poros, a) obtenida después de aplicar contornos activos, b) obtenida manualmente.


### Segmentación de radios

Las características que diferencian a los radios de los otros elementos en la imagen son su forma interior en forma rectangular, su orientación y una diferencia de intensidad del color. Se propone para la segmentación de estos elementos un método novedoso que empieza resaltando los radios usando estudio de formas con morfología matemática, aprovechando la distribución rectangular interna de este elemento; luego, para destacar los elementos a partir de la información derivada de la orientación, se emplean filtros de Gabor (Movellan 2008), homogeneizando regiones y permitiendo nuevamente utilizar un algoritmo de clasificación para separar en clases los píxeles de la imagen, cuya información está basada en los niveles de intensidad de gris presentes en las regiones, en este caso usando el método de agrupamiento por desplazamiento medio. Una segmentación más fina es conseguida con el uso de una técnica asociada al uso de Campos Aleatorios de Markov (Demirkaya *et al.* 2008), eliminando regiones aisladas de la imagen a través de la evaluación del contexto de los píxeles y finalmente eliminando objetos que no superen un umbral de área. En la Figura 7 se resume el proceso.



**Figura 7.** Metodología para la segmentación de radios.

Para destacar en la imagen las figuras rectangulares, correspondientes al interior de los radios, se utiliza una operación básica de la morfología matemática conocida como dilatación. La dilatación de una imagen  $L$  mediante un elemento estructurante  $E$  se define como el conjunto de todos los elementos que al desplazar  $E$  por dichos puntos, toca a  $L$ . La dilatación es extensiva, haciendo crecer o engrosar las formas (Gonzalez y Woods 1996). Para dejar regiones más homogéneas, se realiza un estudio de la orientación de los elementos que componen la imagen aplicando un Filtro de Gabor. Las funciones de Gabor permiten representar señales en tiempo y frecuencia simultáneamente. Este tipo de comportamiento de las funciones de Gabor se relaciona con el modelamiento de los campos receptivos de las neuronas de la corteza visual. Este tipo de células responden selectivamente a diferentes atributos en la escena visual tales como el contraste, el color, orientación, dirección del movimiento, entre otras, lo cual permite diferenciar los objetos. Así que el uso de las funciones de Gabor en diferentes direcciones permite obtener información relevante de las texturas que componen una imagen. En la Figura 8 se presentan las imágenes resultantes de aplicar estas técnicas.




**Figura 8.** Procesamiento para resaltar radios,

a) dilatación con elemento estructurante rectangular, b) aplicación de filtro de Gabor orientado a 90°.

La imagen obtenida hasta este momento permite aplicar métodos de segmentación por agrupamiento de acuerdo al nivel de intensidad de color. Se utiliza en esta propuesta el método de Agrupamiento *mean-shift* que corresponde a un procedimiento general y no paramétrico de agrupamiento, encontrando modos en el conjunto de datos a analizar (Comaniciu y Meer 2002). Este método de agrupamiento considera los puntos en el espacio de características como una función de densidad de probabilidad donde las regiones más densas en este espacio corresponden a los máximos locales o modos de la distribución. Para cada punto en el espacio de características se calcula un gradiente en la densidad local estimada hasta que el algoritmo converja, momento en el cual estos valores representan los modos de la distribución. Para segmentar imágenes en niveles de gris usando esta técnica, se buscan máximos significativos en las funciones de densidad estimadas para los valores de gris que componen la imagen, agrupando todos los píxeles cuyo valor se encuentra en el radio dado.


Con una segmentación inicial con una gran cantidad de pequeñas regiones erróneamente seleccionadas en la misma clase de los radios, se aplica un segundo proceso de segmentación, utilizando un modelamiento con Campos Aleatorios de Markov (MRF por sus siglas en inglés). La información relacionada con el contexto de los píxeles permite un modelamiento con MRF, así que es posible combinar la información proporcionada por los niveles de intensidad de la imagen y la información contextual de estos para obtener un método más robusto para clasificar un píxel en una clase determinada. Para conseguir esto se utiliza el teorema Bayesiano, el cual indica que se puede combinar el conocimiento a priori con la verosimilitud para obtener el resultado posterior. Aplicar este algoritmo a una segmentación inicial permite obtener una segmentación posterior que incluye información del contexto de los píxeles, lo cual permite eliminar regiones clasificadas erróneamente al inicio. Utilizando el muestreador de Gibbs como esquema de implementación, se obtienen regiones más uniformes basadas en la información de contexto de los píxeles (Demirkaya et al. 2008). En la Figura 9 se presentan las dos etapas de segmentación correspondientes a la segmentación por *mean-shift* y usando el muestreador de Gibbs.





**Figura 9.** Segmentación de radios,  
a) usando agrupamiento *mean-shift*, b) aplicación de muestreador de Gibbs.

Por último las pequeñas regiones que no pertenecen a radios pero aun así se clasifican como estos, son eliminadas a partir de la información de sus áreas, utilizando como herramienta la apertura de área. Con esta técnica, aquellas regiones que no superen un valor de área determinado, son descartadas de la segmentación final. En la Figura 10 se presenta la segmentación final de radios.



**Figura 10.** Comparación de la segmentación final de radios,  
a) obtenida después de aplicar contornos activos, b) obtenida manualmente.

#### Metodología de evaluación de la segmentación

Para evaluar el desempeño de la metodología de segmentación propuesta, se utilizan como referencia segmentaciones manuales realizadas por un experto en anatomía de la madera para las 18 muestras bajo estudio. El experto seleccionó las regiones correspondientes a cada elemento en todas las fotografías usando un programa de edición de imágenes, dando a cada región una etiqueta de clase, correspondiendo a la segmentación manual de poros (color negro), radios (color gris) y fibra (color blanco). Este proceso se realizó una sola vez por cada fotografía.

Considerando el problema de segmentación como una labor de clasificación, es factible medir el desempeño construyendo una matriz de confusión. Esta matriz representa la distribución de instancias clasificadas respecto a las clases estimadas (columnas) y reales (filas). Las imágenes fueron separadas en tres regiones, así que la matriz a construir por cada muestra es como la mostrada en la Figura 11.

	$\widehat{C1}$	$\widehat{C2}$	$\widehat{C3}$
C1	$n_{11}$	$n_{12}$	$n_{13}$
C2	$n_{21}$	$n_{22}$	$n_{23}$
C3	$n_{31}$	$n_{32}$	$n_{33}$

**Figura 11.** Matriz de confusión.

De esta matriz se derivan una amplia variedad de mediciones, de tipo global y específico por clase. La medida más popular para medir la precisión de la clasificación a nivel global es la tasa de acierto total (OSR por sus siglas en inglés), descrita por:

$$OSR = \frac{1}{n} \sum_{i=1}^k n_{i,i} \quad (5)$$

Donde  $n$  corresponde al número total de instancias clasificadas (clasificación de cada píxel) y  $k$  al número de clases (poros, radios y fibras). Esta medida se encuentra en el rango de 0 a 1, donde 1 representa una clasificación perfecta. Si se considera solo una clase en particular, se derivan una serie de mediciones relacionadas con la cantidad de verdaderos positivos  $n_{TP}$  y falsos positivos  $n_{FP}$ , que son instancias clasificadas correcta e incorrectamente como  $\widehat{C}_i$ , y la cantidad de verdaderos negativos  $n_{NP}$  y falsos negativos  $n_{FN}$ , que corresponden a las instancias correcta e incorrectamente no clasificadas como  $\widehat{C}_i$ . La tasa de verdaderos positivos (TPR) y la tasa de verdaderos negativos (TNR) se calculan como:

$$TPR_i = \frac{n_{TP}}{n_{TP} + n_{FN}} \quad (6)$$

$$TNR_i = \frac{n_{TN}}{n_{TN} + n_{FP}} \quad (7)$$

También se conocen como sensibilidad y especificidad respectivamente, ambas mediciones orientadas a la referencia. Un tipo de medición orientada a la estimación corresponde al Valor predictivo positivo (PPV), también conocido como exactitud:

$$PPV_i = \frac{n_{TP}}{n_{TP} + n_{FP}} \quad (8)$$

Por último, existen dos mediciones específicas por clase y además simétricas: la medida  $F$  y el coeficiente de Jaccard (JCC):

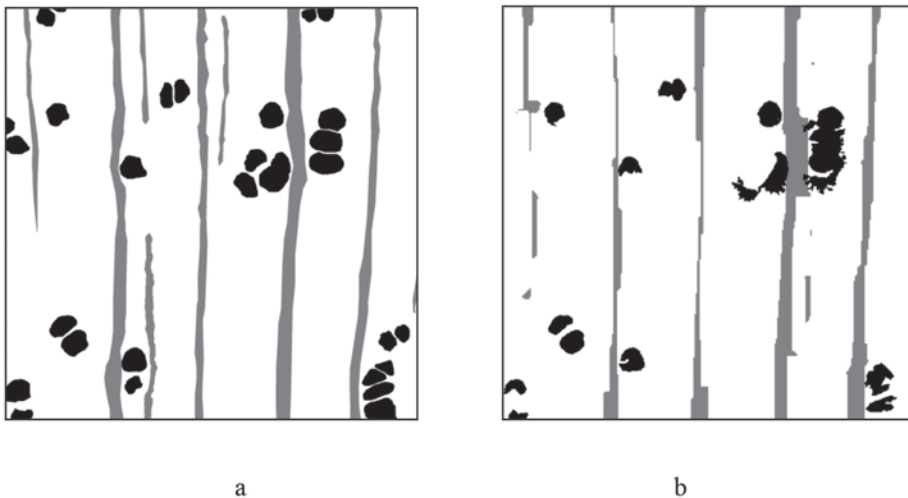
$$F_i = \frac{2n_{TP}}{2n_{TP} + n_{FN} + n_{FP}} \quad (9)$$

$$JCC_i = \frac{n_{TP}}{n_{TP} + n_{FP} + n_{FN}} \quad (10)$$

Todas estas mediciones específicas por clase se encuentran en el rango de 0 a 1, donde un valor más cercano a 1 indica un mejor desempeño del algoritmo de clasificación.

## RESULTADOS Y DISCUSIÓN

En la Figura 12 se presenta una comparación entre la segmentación manual y la obtenida con el sistema.



**Figura 12.** Segmentaciones obtenidas a) por un experto, b) con el sistema desarrollado.

En la Tabla 1 se presenta el promedio sobre las 18 muestras de las 5 mediciones específicas por clase, además de la medición global. Se obtiene una tasa de acierto global del 89,1%, la cual representa una segmentación adecuada de los elementos. Los valores por clase demuestran una precisión más alta para la segmentación de poros comparada con radios, debido a que la complejidad para separar los radios es más alta y además hay una afectación de la orientación de las muestras en la fotografía, existiendo algunas que no se encontraban con los radios orientados verticalmente, disminuyendo el efecto que tiene el uso de los filtros de Gabor.

En cuanto a la precisión general, la desviación estándar de los datos es inferior al 2%, indicando que el sistema mantuvo un desempeño similar para la totalidad de las muestras evaluadas. Los radios fueron el elemento que mayor variabilidad presentó, relacionado con la complejidad de separar este elemento en las imágenes, donde la variación en la orientación de estos elementos en las fotografías afectó la precisión de la segmentación.

**Tabla 1.** Estadísticas de la evaluación de segmentación sobre 18 muestras.

Elemento	Estadística	Promedio (%)	Desviación estándar (%)
Poros	TPR	46,7	10,6
	TNR	99,1	0,6
	PPV	77,1	11,1
	F	57,0	8,6
	JCC	40,4	8,5
Radios	TPR	61,2	11,9
	TNR	95,6	1,3
	PPV	60,5	10,6
	F	60,6	10,6
	JCC	44,2	10,4
Fibra	TPR	94,8	1,4
	TNR	59,6	9,0
	PPV	92,9	1,2
	F	93,9	0,9
	JCC	88,4	1,6
Total	OSR	89,1	1,6

Dado que se utilizaron técnicas de optimización y métodos estocásticos en el proceso de segmentación, hay variaciones en el resultado si se aplica el algoritmo a la misma muestra múltiples veces. Para evaluar la reproducibilidad de los experimentos realizados, se realizó la repetición de la segmentación de una de las 18 muestras, 5 veces, obteniendo cada vez los parámetros de desempeño del proceso. En la Tabla 2 se presentan los valores promedio de estos parámetros después de realizar esta experiencia, así como también el valor de desviación estándar. Se observa como las técnicas utilizadas en la segmentación de los radios presentan pequeñas variaciones cuando se repite el experimento, con un máximo de variación del 3% en la medición de la exactitud (PPV). El promedio de precisión general (OSR) mostró variaciones inferiores al 1%, por lo tanto se puede considerar que el sistema es capaz de reproducir los resultados con alta regularidad al repetir un experimento.

**Tabla 2.** Estadísticas de la repetición sobre la misma muestra del método de segmentación.

Elemento	Estadística	Promedio (%)	Desviación estándar (%)
Poros	TPR	58,0	0
	TNR	99,4	0
	PPV	86,2	0
	F	69,3	0
	JCC	53,1	0
Radios	TPR	60,2	1,3
	TNR	97,3	0,5
	PPV	75,2	3,0
	F	66,8	1,6
	JCC	50,2	1,8
Fibra	TPR	96,5	0,5
	TNR	59,9	0,8
	PPV	91,5	0,2
	F	93,9	0,3
	JCC	88,5	0,4
Total	OSR	89,7	0,4

## CONCLUSIONES

En este artículo, se propone una nueva metodología para la segmentación de poros, radios y fibras en imágenes microscópicas de madera. Se evaluó sobre 18 muestras de la especie *Gaiadendron punctatum*, donde los resultados experimentales muestran un acierto global alto (89,1%); equivalente a una buena segmentación. Se midieron estadísticas por cada clase, que muestran como la precisión en la segmentación de poros es más alta que la obtenida para radios, esto debido a que los radios son estructuras más complejas de distinguir y además la orientación de la muestra disminuyó la precisión en algunos casos, ya que se esperan radios totalmente verticales, enfatizando esto con el uso de los filtros de Gabor.

Las segmentaciones obtenidas constituyen un primer paso en el proceso de identificación de especies, ya que proveen una separación válida de los elementos en el corte transversal con lo cual se pueden obtener automáticamente características como las propuestas por el IAWA.

## BIBLIOGRAFÍA

- Brunel, G.; Borianne, P.; Subsol, G.; Jaeger, M.; Caraglio, Y. 2012.** Automatic characterization of the cell organization in light microscopic images of wood: Application to the identification of the cell file. *Proceedings of the IEEE Fourth International Symposium on Plant Growth Modeling, Simulation, Visualization and Applications (PMA)*: 58-65
- Caselles, V.; Kimmel, R.; Sapiro, G. 1997.** Geodesic Active Contours. *Int J Comput Vision* 22 (1): 61-79.
- Chen, F.; Evans, R. 2010.** Automated measurement of vessel properties in birch and poplar wood. *Holzforschung* 64(3): 369-374.
- Comaniciu, D.; Meer, P. 2002.** Mean shift: a robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 24 (5): 603-619.
- Demirkaya, O.; Asyali, M.H.; Sahoo, P.K. 2008.** *Image Processing with MATLAB: Applications in Medicine and Biology*. CRC Press.
- Espinoza, N.; Miller R.B. 1991.** Adapting the IAWA list of microscopic features for hardwood identification to DELTA. *IAWA Bulletin* 12 (1): 34-50.
- Gonzalez, R.C.; Woods, R.E. 1996.** *Tratamiento digital de imágenes*. Editorial Díaz de Santos, S.A.
- Hermanson, J. C.; Wiedenhoeft, A. C. 2011.** A brief review of machine vision in the context of automated wood identification systems. *IAWA Journal* 32 (2): 233-250.
- Haralick, R.M.; Shanmugam, K.; Dinstein, I. 1973.** Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics* 3 (6): 610-621.
- Jain, A.K.; Murty, M.N.; Flynn, P.J. 1999.** Data clustering: a review. *ACM Comput Surv* 31 (3): 264-323.
- Koch, G.; Richter, G.; Schmitt, U. 2011.** Design and application of CITESwoodID – Computer-aided identification and description of CITES-protected timbers. *IAWA Journal* 32 (2): 213-220.
- Martins, J.; Oliveira, L.S.; Nisgoski, S.; Sabourin, R. 2013.** A database for automatic classification of forest species. *Machine Vision and Applications* 24 (3): 567-578.

**Movellan, J.R. 2008.** Tutorial on Gabor Filters. Tutorial paper <http://mplab.ucsd.edu/tutorials/pdfs/gabor.pdf>.

**Pan, S.; Kudo, M. 2011.** Segmentation of pores in wood microscopic images based on mathematical morphology with a variable structuring element. *Computers and Electronics in Agriculture* 75 (2): 250-260.

**Pereira-Goncalves, T.A.; Wagner-Ballarín, A.; Nisgoski, S.; Bolzon de Muniz, G.I. 2014.** A contribution to the identification of charcoal origin in Brazil: I- anatomical characterization of corymbia and eucalyptus. *Maderas-Cienc Tecnol* 16 (3): 323-336.

**Rallo, M.; Gonzalez, J.P.; Ulloa, I.; Orell, M. 2007.** Características macro y microscópicas del Guayacán. *Maderas-Cienc Tecnol* 9 (1): 71-78.

**Roncancio, H.A.; Velasco, H.F.; Herrera, R.J. 2003.** Segmentation of wood microanatomy images using multiscale classification. Proceedings of the 3rd IEEE International Symposium on Signal Processing and Information Technology. ISSPIT 2003. 692-695.

**Sarmiento, S.; Détienne, P.; Heinz, C.; Molino, J.F; Grard, P.; Bonnet, P. 2011.** Pl@ntwood: A computer-assisted identification tool for 110 species of Amazon trees based on wood anatomical features. *IAWA Journal* 32 (2): 221-232.

**Wang, H.; QI, H; LI, W.; Zhang, G.; Wang, P. 2009.** A GA-based Automatic Pore Segmentation Algorithm. Proceedings of the First ACM/SIGEVO Summit on Genetic and Evolutionary Computation. GEC '09: 985-988.

**Wegner, L.; Von Arx G.; Sass-Klaassen U.; Eilmann, B. 2013.** ROXAS – an efficient and accurate tool to detect vessels in diffuse-porous species. *IAWA Journal* 34 (4): 425-432.

**Wheeler, E.A.; Baas, P.; Gasson, P.E. 1989.** List of microscopic features for hardwood identification. *IAWA Bulletin* 10: 219-332.