

IDENTIFICACION DEL CILINDRO NUDOSO EN IMAGENES TC DE TROZAS PODADAS DE *PINUS RADIATA* UTILIZANDO EL CLASIFICADOR DE MAXIMA VEROSIMILITUD

IDENTIFICATION OF DEFECTIVE CORE IN PRUNED *PINUS RADIATA* LOGS FROM CT IMAGES USING THE MAXIMUM LIKELIHOOD CLASSIFIER

Gerson Rojas Espinoza¹, Oscar Ortiz Iribarren²

RESUMEN

El presente estudio tuvo por objetivo identificar el cilindro nudoso en imágenes de tomografía computarizada (TC) de trozas podadas de *Pinus radiata*, utilizando un algoritmo de clasificación supervisada. El proceso de clasificación fue necesario para identificar y separar el cilindro nudoso de la zona libre de defectos y nudos. Diez trozas podadas de *Pinus radiata* fueron escaneadas en un escáner médico de rayos X, *multi-slice*, de marca *Philips*, donde las imágenes TC resultantes fueron obtenidas cada 5 mm. Un total de 270 imágenes TC fueron clasificadas con el clasificador de máxima verosimilitud, y los mapas temáticos resultantes, fueron filtrados con un filtro median de 7 x 7. Luego, 90 mapas temáticos fueron seleccionados y utilizados para evaluar la precisión del proceso de clasificación. Para ello, la matriz de confusión e índice kappa fueron obtenidas utilizando una muestra de 70 píxeles seleccionados aleatoriamente de cada mapa temático. Un valor de precisión de 98,5 % fue obtenido para la identificación del cilindro nudoso y de 92,5 % para la precisión global de la clasificación. El valor Kappa fue de 0,730, lo cual indica que existe un fuerte grado de conformidad entre los datos de referencia y el procedimiento de clasificación. Estos resultados sugieren que es factible aplicar el procedimiento de clasificación para identificar las características internas de trozas podadas de *Pinus radiata*.

Palabras claves: Cilindro nudoso, rayos X, máxima verosimilitud, matriz de confusión, *Pinus radiata*

ABSTRACT

This study aims to identify the defective core on computed tomography images (CT) of pruned radiata pine logs, using an algorithm of supervised classification. The classification process was required to identify and separate the defective core from the free defect part and knots. Ten pruned radiata pine logs were scanned into a medical X-ray multi-slice Philips scanner and the resulting CT images at 5 mm. were obtained. A total amount of 270 CT images were classified under with the maximum likelihood classifier and the resulting thematic maps were filtered with a median filter of 7 x 7. Then, 90 thematic maps were selected and used to assess the accuracy of the classification process. To accomplish this, the Confusion Matrix and Kappa statistic were obtained using a sample consisting of 70 randomly selected pixels of each thematic map. An accuracy value of 98.5% was obtained for the

¹ Profesor Asistente, Departamento de Ingeniería en Maderas, Facultad de Ingeniería, Universidad del Bío-Bío, Concepción, Chile.

² Alumno del Magíster Ciencia y Tecnología de la Madera, Departamento de Ingeniería en Maderas, Facultad de Ingeniería, Universidad del Bío-Bío, Concepción, Chile.

Autor para correspondencia: grojas@ubiobio.cl

Recibido: 19.11.2008 Aceptado: 25.04.2009

defective core identification and 92.5 % for the overall accuracy of the classification. The Kappa value was 0.730 indicating a strong agreement between the ground truth and the classification procedure. These results suggest that it is feasible to implement the classification procedure for identifying the internal characteristics of pruned radiata pine logs

Keywords: Defective Core, X-ray, Maximum Likelihood, Confusion Matrix, radiata pine.

INTRODUCCION

La industria del aserrío en Chile se sustenta, principalmente, en la utilización de trozas provenientes de bosques cultivados de *Pinus radiata* para su producción. En la actualidad cerca del 90 % del volumen exportado de madera aserrada corresponde a esta especie (Infor 2007). Sin embargo, la eficiencia del proceso de aserrío se ve limitada por la presencia de defectos internos de las trozas, tales como nudos, grietas internas, bolsas de resina, entre otros. La presencia, en mayor o menor grado, de estos defectos en la madera aserrada, determina la calidad y como consecuencia, el precio final del producto.

En general, las empresas forestales en Chile realizan grandes esfuerzos para obtener madera de *Pinus radiata* de buena calidad y así satisfacer las exigencias que demanda el mercado internacional. En esta dirección, la poda es el principal tratamiento silvícola que las empresas están aplicando a los bosques de *Pinus radiata* para obtener fustes de mejor calidad. Este tratamiento silvícola, es una actividad que elimina las ramas vivas o muertas del árbol y permite la producción de madera libre de nudos, una vez que el crecimiento en diámetro del fuste cubre la zona de defecto. De esta manera, la parte interna de estas ramas queda confinada en una zona central, respecto al volumen del fuste, la cual se denomina cilindro nudoso (CN). En general, el diámetro del CN depende de la calidad del sitio, el número de podas y edad del árbol al momento de la poda, entre otras variables.

Actualmente, los aserraderos utilizan programas computacionales que permiten optimizar los planes de corte y cuya información de entrada corresponde a características externas del troza, tal como diámetro, largo, conicidad, curvatura, entre otras, las cuales pueden ser determinadas utilizando tecnología disponible en el mercado. Sin embargo, la obtención de información de las características internas del troza, antes de iniciar el proceso de aserrío, requiere de tecnología aun no disponible a nivel industrial. En esta dirección, algunas técnicas no destructivas, tales como el ultrasonido (Birkeland y Han 1991), la resonancia magnética nuclear (Chang *et al.* 1989; Coates *et al.* 1998) y la radiación gamma (Karsulovic *et al.* 2002 y 2005) han sido utilizadas para evaluar internamente las trozas. Sin embargo, la tomografía computarizada de rayos X, método normalmente usado en la ciencia médica, ha sido el método no destructivo más utilizado en este tipo de estudios (Taylor *et al.* 1984; Zhu *et al.* 1991; Björklund y Petersson 1999; Oja 2000; Moberg 2000; Rojas *et al.* 2006 y 2007; Wei *et al.* 2008). Aún así, como la información que se obtiene en una imagen CT (nivel de gris) esta directamente relacionada con la densidad del objeto (Seeram 2001), existen todavía algunas limitaciones para la identificación y separación de algunas características internas de los trozas. La similitud en las densidades presentadas por algunos elementos morfológicos internos en trozas es responsable de la superposición entre el rango espectral (nivel de gris) de estos elementos. Así, el análisis de la información que proviene de una imagen TC, requiere de algoritmos o técnicas que permitan detectar y separar estos elementos con la mayor precisión posible.

Una variedad de métodos de segmentación han sido evaluados con el propósito de clasificar características y defectos internos. Taylor *et al.* (1984) usaron la información derivada del histograma de la imagen CT, como una técnica para identificar y localizar el perímetro y nudos internos de trozas. Funt y Bryant (1987), presentaron un algoritmo para clasificar automáticamente imágenes CT en maderas

sin defectos, nudos, pudrición y grietas, usando técnicas de interpretación en 2-D, forma de objeto y patrones de textura para los anillos de crecimiento. Zhu *et al.* (1991), presentaron un método usando el análisis de histogramas y filtros de convolución y de textura para localizar e identificar los defectos internos. Bhandarkar *et al.* (1999) describieron un sistema de segmentación de la imagen CT para separar regiones con y sin defectos usando la conectividad, forma, orientación y elementos morfológicos.

En esta dirección, Li *et al.* (1996), Schmoldt *et al.* (2000), Sarigul *et al.* (2003) investigaron el uso de redes neuronales (RN) para la identificación y clasificación de defectos internos en imágenes TC de trozas de madera de latifoliadas. Este método de detección requiere inicialmente de la preparación de un conjunto de entrenamiento, el cual es utilizado como información de entrada por el clasificador de RN. El conjunto de entrenamiento está formado por un grupo de clases espectrales (nivel de gris), donde cada clase esta asociada a un defecto o característica en la imagen TC. Luego, la imagen TC es clasificada por el clasificador RN y posteriormente filtrada, aplicando filtros morfológicos. Este procedimiento ha sido también utilizado por Nordmark (2002, 2003) para identificar y segmentar nudos en imágenes TC de trozas de *Pinus sylvestris* y al mismo tiempo para desarrollar modelos geométricos de nudos y trozas. Mas recientemente, Rojas *et al.* (2006 y 2007) utilizaron algoritmos de clasificación supervisada para identificar defectos internos en trozas de *Acer saccharum*. El procedimiento desarrollado por estos autores utiliza el algoritmo de máxima verosimilitud para clasificar las imágenes TC y la aplicación de un filtro median como etapa de post-clasificación. Este método ha sido utilizado por Wei *et al.* (2008), para identificar algunas características internas de trozas de *Acer saccharum*. Estos autores también reportaron un análisis de textura de las imágenes TC evaluadas.

A pesar de las numerosas técnicas y métodos utilizados, solo algunos autores presentan una evaluación cuantitativa de la capacidad de identificación y separación de los defectos internos a partir de imágenes CT. Bhandarkar *et al.* (1999) alcanzaron valores de precisión de 84 % y 80 % para la detección de nudos y grietas en trozas de *Acer saccharum*. Schmoldt *et al.* (2000) obtuvieron, para tres especies de latifoliadas, valores de precisión global y de albura de 90 % y 97 %, respectivamente. Para la detección de madera libre de defectos en trozas de *Pinus sylvestris*, Normark (2003) obtuvo valores de precisión de 90 %. Rojas *et al.* (2006), para trozas de *Acer saccharum*, reportaron valores de precisión global y detección de albura de 82,6 % y 97,8 %, respectivamente. Para esta especie, valores de 79,8 % y 85,6 % fueron presentados por Wei *et al.* (2008), para la precisión global y detección de albura.

En general, la literatura asociada a la utilización de la tomografía computarizada de rayos X en la detección de defectos internos, incluyendo el cilindro nudoso, en trozas de madera de *Pinus radiata*, es muy limitada. Así, el principal objetivo del presente estudio fue evaluar cualitativamente y cuantitativamente un procedimiento para segmentar las imágenes CT de tal manera de identificar el cilindro nudoso en trozas podadas de *Pinus radiata*. Para llevar a cabo este objetivo, el algoritmo de clasificación supervisada de máxima verosimilitud fue utilizado.

MATERIALES Y METODOS

Material

Diez árboles podados de pino radiata, de 23 años de edad, fueron seleccionados y talados en el predio El Espigado, localizado en la zona de Arauco, distante a 100 km. de la ciudad de Concepción. La primera poda de estos árboles fue realizada a los 5 años de edad y a una altura de 2,7 m. De cada árbol se obtuvo un rollizo de la zona podada del árbol, de largo comercial equivalente a 4, 3 m aproximadamente y enviados para su inmediato procesamiento, en el pabellón de tecnología de la madera, de la Universidad del Bío-Bío. Una rodela de 25 mm de espesor fue cortada de cada extremo de los rollizos, para obtener posteriormente un valor de referencia de contenido de humedad (CH). Cada rollizo fue posteriormente trozado en tres partes de un metro de longitud. Las trozas obtenidas fueron marcadas y

luego selladas en cada extremo con impermeabilizante Anchorseal, para evitar la pérdida de humedad. Así, un total de treinta trozas fueron obtenidas y utilizadas como material de ensayo.

Escaneo de trozas

Las trozas fueron escaneadas en un escáner médico de rayos X (Tomografía computarizada (TC)), de marca *Philips, multi-Slice*, perteneciente al laboratorio de imagenología del Hospital del trabajador, en Concepción. Previo al escaneo, un clavo fue insertado en la parte inicial del extremo menor de cada troza, con el objetivo de identificar el punto de inicio del escaneo. El proceso de escaneo fue realizado a 120 Kvp y 249 mA, con una separación entre cada imagen TC de 5 mm. Alrededor de 200 imágenes TC fueron obtenidas por cada troza, en formato de 512 x 512 píxeles y con resolución de 12 bits. Estas imágenes CT, inicialmente en formato Dicom (Digital Imaging and Communication in Medicine), fueron transformadas a formato Bitmap (bmp) utilizando el programa de computador *CT viewer* y utilizadas posteriormente a 8 bits de resolución en la escala de gris. La resolución espacial de un píxel, varió entre 0,7 y 0,9 mm, dependiendo del diámetro de cada troza.

Selección de imágenes TC

Las imágenes TC obtenidas para cada troza fueron analizadas con el objetivo de seleccionar aquellas zonas en las que se observó la presencia de verticilos (concentración de nudos). Para cada troza se seleccionaron tres zonas, conformadas por seis imágenes TC consecutivas cada una, donde a lo menos, en una de las zonas se observara la presencia de verticilos. De esta manera 90 zonas fueron seleccionadas, correspondientes a un total de 540 imágenes TC. Posteriormente, estas zonas fueron identificadas en la troza real, teniendo como referencia la posición del clavo y el número de la primera imagen TC de cada zona. Luego, estas zonas de la troza fueron cortadas obteniendo rodela de 25 mm de espesor. Una fotografía digital fue tomada de ambos lados de cada rodela. Estas fotografías digitales fueron utilizadas posteriormente como referencia para realizar una evaluación visual cualitativa de las imágenes TC seleccionadas.

Clasificación supervisada de imágenes TC

En general, el objetivo del procedimiento de clasificación de una imagen es identificar o segmentar la imagen en términos de objetos o áreas de interés. El resultado obtenido a partir de la clasificación es denominado mapa temático.

La clasificación supervisada de una imagen se basa en el conocimiento previo del número de clases y algunos parámetros estadísticos asociados a cada clase espectral presente en una imagen (Mather 1987). Estos parámetros estadísticos son obtenidos a partir de muestras de píxeles, llamado conjunto de entrenamiento, el cual es obtenido previamente de las imágenes a clasificar. Las muestras de píxeles del conjunto de entrenamiento son arbitrariamente seleccionadas para obtener una muestra representativa de cada clase espectral. En general, como el principal interés de este estudio fue identificar y segmentar el cilindro nudoso (incluye la presencia de nudos) de la zona libre de defectos, tres clases fueron definidas como áreas de interés a segmentar: cilindro nudoso (CN), nudos y zona libre de defectos. Sin embargo no fue posible obtener clases de tamaños similares (número de píxeles por clase), debido a la variación en la proporción de cada clase presente en la imagen TC. La zona externa a la sección transversal de la troza en cada imagen TC fue separada automáticamente del resto de la imagen.

Luego, el conjunto de entrenamiento fue utilizado como información de entrada por el algoritmo de clasificación supervisada de máxima verosimilitud (CSMV), teniendo como referencia el procedimiento desarrollado por Rojas *et al.* (2006). El algoritmo CSMV, utiliza como estadístico el vector medio y la matriz de co-varianza de cada clase y asume que el nivel de gris asociado a cada clase presenta una distribución normal. Esto permite calcular, para cada píxel de la imagen, una serie de probabilidades de asignación a cada una de las clases. Posteriormente, un filtro median de 7 x 7 fue aplicado a cada mapa temático, con el objetivo de remover el ruido generado por el proceso de clasificación. En el presente estudio 270 imágenes TC (tres por cada zona) mostrando la presencia del CN, nudos y zona libre de

defectos fueron seleccionadas de la muestra inicial de 540 imágenes TC y luego clasificadas. El procedimiento de clasificación fue realizado utilizando el programa de computador PCI (PCI 2005).

Determinación de la precisión de la clasificación.

La capacidad de detección del algoritmo CSMV fue evaluada, mediante la determinación de la precisión de la clasificación. Dos métodos fueron utilizados para este fin. En el primer método, la precisión fue determinada mediante la comparación entre los píxeles de la imagen que fueron correctamente clasificados y los mismos píxeles en la imagen de referencia o imagen real. El resultado de esta comparación es expresado en la forma de una matriz de confusión o de error. En esta matriz, los datos de referencia (representados por las columnas de la matriz) son comparados con los datos clasificados (representados por las filas de la matriz). La diagonal principal de la matriz indica el grado de acuerdo entre ambos grupos de datos. La precisión global (expresada en porcentaje) para una imagen clasificada es calculada dividiendo el número total de píxeles correctamente clasificados (suma de la diagonal principal) por el número total de píxeles en la matriz de confusión (Story y Congalton 1986). Un valor 100 para la precisión global indica un acuerdo perfecto entre los resultados de la clasificación y los datos de referencia. La precisión para cada clase fue también determinada a partir de la matriz de confusión, dividiendo el número de píxeles correctamente clasificados por el número total de píxeles, indicados en la columna de los datos de referencia. Al mismo tiempo, los errores de omisión y comisión pueden ser también determinados a partir de la matriz de confusión (Richards y Jia 1999). Los errores de omisión corresponden a píxeles que pertenecen a una clase de interés y que han sido clasificados erróneamente en otra clase, mientras que los errores de comisión corresponden a píxeles de otras clases y que el clasificador ha asignado a una clase de interés.

Para complementar la determinación de la precisión, y considerando que la precisión global obtenida de la matriz de confusión solamente incorpora la diagonal principal y excluye los errores de omisión y comisión, un segundo método denominado Análisis Kappa (K) fue utilizado, el cual considera estos errores. Este estadístico mide el grado de ajuste exclusivamente para la predicción de la clasificación y utiliza para el análisis los resultados de la matriz de confusión (Jensen 1996). El estadístico K es calculado como sigue:

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})} \quad 1$$

donde r es el número de filas en la matriz, x_{ii} es el número de píxeles en la fila i y columna, x_{i+} y x_{+i} corresponden al total marginal para la fila y columna i , respectivamente, y N es el número total de píxeles.

Para realizar el análisis cuantitativo de la capacidad de detección del algoritmo, 90 mapas temáticos (uno por cada zona) fueron seleccionados arbitrariamente del grupo de 270 obtenidos del proceso de clasificación. Luego, la matriz de confusión asociada a cada mapa temático fue obtenida a partir de una muestra de 70 píxeles seleccionados aleatoriamente (Richards y Jia 1999) de cada mapa temático. Este análisis también fue realizado para cada mapa temático filtrado.

RESULTADOS Y DISCUSION

Análisis visual de imagen CT

Una imagen TC típica de una sección transversal de una troza podada de *Pinus radiata* y su correspondiente imagen digital real se muestra en las Figuras 1a y 1b, respectivamente. La Fig. 1a muestra claramente la zona del cilindro nudoso (CN) y la zona libre de defectos. En el CN se observa la presencia de nudos, en general de forma ovalada y de una tonalidad más clara (mayor nivel de gris) que el resto del CN, el cual presenta una tonalidad más oscura (menor nivel de gris). Esta heterogeneidad en el nivel de gris del CN se debe principalmente a la diferencia de densidad verde que presentaron las áreas sin nudos y con nudos. La zona libre de defectos presenta, en general, una tonalidad más clara y más homogénea, en términos de nivel de gris, que el CN. Oja (2000), indicó que el nivel de gris en las imágenes TC es afectado por la variación del contenido de humedad del troza. Por su parte, Rojas *et al.* (2005) demostraron que, para trozas de *Acer saccharum*, la densidad verde es la propiedad física que mejor se correlaciona con el nivel de gris de las imágenes TC.

En la Fig. 1a se pueden identificar también los anillos de crecimiento, los cuales presentan un mayor ancho en el CN que en la zona libre de defectos.




Figure 1. (a) Imagen TC típica de una sección transversal de un troza podada de *Pinus radiata* (512 x 512 píxeles) mostrando el cilindro nudoso, nudos y zona libre de defectos. (b) Fotografía digital correspondiente a la imagen TC.

Clasificación Supervisada

Una secuencia de los resultados obtenidos del proceso de clasificación supervisada de imágenes TC de trozas de *Pinus radiata* podado utilizando el algoritmo de CSMV es presentada en las Figuras 2a, 2b y 2c. La Fig. 2a presenta la imagen CT original. El mapa temático obtenido de la clasificación supervisada de máxima verosimilitud se muestra en la Fig. 2b. Esta figura muestra la segmentación de la imagen TC en tres clases. En general, se observa que el CN puede ser identificado y separado de los nudos y de la zona libre de defectos. Sin embargo, en la zona libre de defectos se evidencia un cierto nivel de ruido en el nivel de gris, el cual puede ser asociado principalmente a la menor densidad que presenta la madera temprana que forma parte de los anillos de crecimiento del fuste (Kininmonth y Whitehouse 1991) y también a la pérdida de humedad que ocurre en áreas próximas a la periferia del troza, debido a la ausencia de corteza. En general, los resultados de la clasificación mejoraron con la aplicación del filtro mediano de 7 x 7 (Fig. 2c). En esta figura se observa que, el principal cambio ocurrió en la zona libre de defectos, donde el ruido asociado a los anillos de crecimiento es eliminado casi

completamente. Sin embargo el ruido observado en la zona periférica de la troza se mantiene. En la misma dirección, un leve cambio se observa en las áreas sin nudos del CN. En general, los resultados de este análisis cualitativo indican que es posible identificar las tres clases indicadas anteriormente en imágenes CT de trozas podadas de *Pinus radiata*.




Figure 2. (a) Imagen TC original de una troza podada de *Pinus radiata*. (b) Mapa temático obtenido de la clasificación usando CSVM. (c) Mapa temático filtrado usando un filtro mediano de 7 x 7.

Por otra parte, para evaluar cuantitativamente la capacidad de detección de este algoritmo, la matriz de confusión asociada a cada mapa temático fue calculada.

La tabla 1 presenta la matriz de confusión obtenida producto de la evaluación de 90 mapas temáticos. Esta tabla muestra los valores de precisión global, precisión por clase y los errores de omisión y comisión. En esta tabla se observa que la precisión global obtenida por CSVM fue de 82 %. Un valor de precisión de 96,7 % se obtuvo para la identificación del CN. Este valor es importante desde el punto de vista práctico, ya que sugiere que el CN podría ser identificado a partir de imágenes obtenidas utilizando la tomografía computarizada. Para la zona libre de defectos (ZLD) y nudos, valores de precisión de 79,6 % y 70,8 % fueron obtenidos, respectivamente. Estos menores valores de precisión son explicados principalmente por los errores de omisión generados durante la clasificación con CSVM. Para el caso de los nudos, un error de omisión de 28,6 % (48/168) fue generado por la clasificación. Esto significa que 48 píxeles de la clase nudos fueron asignados erróneamente a la clase ZLD. Para la ZLD, el error de omisión está asociado principalmente a la clase nudo, con un valor de 18,6 % (916/4915), seguido por la clase CN, con un error de omisión de 1,8 % (88/4915). En general estos errores dan cuenta de una leve superposición del nivel de gris entre la clase nudos y ZLD. Esta situación puede ser atribuida a que al interior de los nudos existe una leve variación del nivel de gris, lo cual permite que algunos píxeles presenten niveles de gris similares a píxeles que forman parte de la madera tardía o temprana de los anillos de crecimiento de la zona ZLD.

Tabla 1. Resultados de la matriz de confusión de mapas temáticos obtenidos por CSVM

obtenidos por CSVM

Clasificados como	Clases verdaderas			Total
	Nudos	CD	ZLD	
Nudos	119	30	916	1065
CD	1	913	88	1002
ZLD	48	1	3911	3960
Total	168	944	4915	6027
Precisión (%)	70,8	96,7	79,6	82,0

Un análisis similar fue realizado a los mapas temáticos filtrados y cuyos resultados se muestran en la Tabla 2. Esta tabla muestra la matriz de confusión obtenida de la evaluación de 90 mapas temáticos. Los resultados obtenidos indicaron que, en general, los valores de precisión mejoraron, excepto para la clase nudos. La precisión global aumentó de 82 % a 92,5 %. Con respecto a la precisión individual, la ZLD presentó el mayor aumento, seguido del CN, con valores de 12,8 % y 1,8 %, respectivamente.

Tabla 2. Resultados de la matriz de confusión obtenida para mapas temáticos filtrados.

Clasificados como	Clases verdaderas			Total
	Nudos	CD	ZLD	
Nudos	103	13	224	340
CD	16	930	148	1094
ZLD	49	1	4543	4593
Total	168	944	4915	6027
Precisión (%)	61,3	98,5	92,4	92,5

Los resultados de precisión de la clasificación, obtenidos a partir de las matrices de confusión (Tabla 1 y 2), sugieren que es necesario filtrar los mapas temáticos obtenidos del proceso de clasificación para obtener mayores valores de precisión global e individual. En general, los valores de precisión de la clasificación obtenidos en el presente estudio para trozas de *Pinus radiata*, están en acuerdo con los resultados obtenidos por Rojas *et al.* (2006) y Wei *et al.* (2008), en trozas de *Acer saccharum*.

Como complemento a la evaluación cuantitativa, el estadístico Kappa fue también determinado, para los mapas temáticos y mapas temáticos filtrados, a partir de la matriz de confusión correspondiente. Los valores Kappa obtenidos fueron de 0,556 y 0,730, para los mapas temáticos y mapas temáticos filtrados, respectivamente. De acuerdo a la escala establecida por Landis y Koch (1977), estos valores Kappa indican que existe un fuerte grado de conformidad entre los datos de referencia y los resultados del proceso de clasificación usando el clasificador de máxima verosimilitud.

CONCLUSIONES

La evaluación cualitativa de las imágenes TC de trozas podadas de *Pinus radiata* indicó que el CN puede ser identificado y separado de la zona libre de defectos, esto debido a la marcada diferencia de nivel de gris observada entre ambas zonas. Los nudos se identifican fácilmente al interior del CN por su forma ovalada y su tonalidad más clara. En esta dirección, los resultados de la evaluación cuantitativa indicaron que el CN puede ser identificado con una precisión de 96,7 %, mientras que la precisión global fue de 82 %. En general, la precisión de la clasificación mejoró después de filtrar los mapas temáticos, pasando a 98,5 % y 92,5 % para el CN y la precisión global, respectivamente. Por otra parte, los errores de omisión obtenidos a partir de la matriz de confusión indicaron la existencia de una leve superposición entre el nivel de gris asociado a los nudos y a la zona libre de defectos. Los valores kappa indicaron la existencia de un fuerte grado de conformidad entre los datos de referencia y el proceso de clasificación supervisada.

Finalmente, los resultados obtenidos del presente estudio dejan de manifiesto que el algoritmo de clasificación de máxima verosimilitud presenta un gran potencial para la identificación y segmentación del CN en imágenes TC de trozas podadas de *Pinus radiata*.

AGRADECIMIENTOS

Los autores agradecen al personal del laboratorio de imagenología del Hospital del Trabajador (Concepción, Chile), por su asistencia durante la etapa de escaneo de las trozas, al personal del Pabellón de Tecnología de la Madera, de la Universidad del Bío-Bío, por el soporte durante el análisis experimental destructivo, a la Sra. Linette Salvo, por el apoyo logístico durante el desarrollo de la parte experimental y a los estudiantes de pregrado Graciela Muñoz y Álvaro Torres, del Departamento de Ingeniería en Maderas de la Universidad del Bío-Bío. Esta investigación fue financiada por el Fondo Nacional de Desarrollo Científico y Tecnológico de Chile, a través del proyecto de iniciación Fondecyt N° 11060390.

BIBLIOGRAFIA

- Bhandarkar, S.M.; Faust, T.D.; Tang, M. 1999.** CATALOG: a system for detection and rendering of internal log defects using computer tomography. *Machine Vision and Application* 1999(3):171-190.
- Birkeland, R.; Han, W. 1991.** Ultrasonic scanning for internal log defects. 4th International Conference on Scanning Technology in the Wood Industry. Burlingame, CA, U.S.A., October 28-29, 1991.
- Björklund, L.; Petersson, H. 1999.** Predicting knot diameter of *Pinus sylvestris* in Sweden. *Scandinavian Journal Forest Research* 14:376-412.
- Chang, S. J.; Olson, J. R.; Wang, P.C. 1989.** NMR imaging of internal features in wood. *Forest Products Journal* 39(6):43-49.
- Coates, E. R.; Chang, S. J.; Laio, T.W. 1998.** A quick defect detection algorithm for magnetic resonance images of hardwood logs. *Forest Products Journal* 48(10):68-74.
- Funt, B. V.; Bryant, E.C. 1987.** Detection of internal log defects by automatic interpretation of computer tomography images. *Forest Products Journal* 37(1):56-62.

INFOR, 2007. La industria del aserrío, Chile 2007. Boletín Estadístico 118, Instituto Forestal.

Jensen, J. R. 1996. *Introductory digital image processing: a remote sensing perspective*. Prentice Hall, Upper Saddle River, NJ, U.S.A.

Karsulovic, J. T.; Dinator, M. I.; Morales, R. 2002. Nondestructive gamma radiation methods for detection of central rot in logs of Lenga (*Nothofagus pumilio*). *Forest Products Journal* 52(2):87-93.

Karsulovic, J. T.; Dinator, M. I.; Morales, J.; Gaete, V.; Barrios, A. 2005. Determinación del diámetro del cilindro nudoso en trozas podadas de pino radiata (*Pinus radiata*) mediante atenuación de radiación gamma. *Bosque* 26(1):109-122.

Kininmonth, J.A.; Whitehouse, L. J. 1991. *Properties and uses of New Zealand radiata pine. Volume one-Wood properties*. Ian Bryce Printers Ltd., Roturoa, New Zealand.

Landis, J.R.; Koch, G.C. 1977. The measurement of observer agreement of categorical data. *Biometrics* 33:159-174.

Li, P.; Abbot, A. L.; Schmoldt, D. L. 1996. Automated analysis of CT images for the inspection of hardwood logs. Pages 1744-1749 in *Proceeding of the IEEE International Conference on Neural Networks*, Washington, DC, U.S.A.

Mather, P. M. 1987. *Computer processing of remotely sensed images, an introduction*. Bury St Edmunds, Suffolk.

Moberg, L. 2000. Models of internal knot diameter for *Pinus sylvestris*. *Scandinavian Journal Forest Research* 15:177-187.

Nordmark, U. 2002. Knot identification from CT images of young *Pinus sylvestris* saw logs using artificial neural networks. *Scandinavian Journal Forest Research* 17:72-78.

Nordmark, U. 2003. Models of knot and log geometry of young *Pinus sylvestris* sawlogs extracted from computed tomographic images. *Scandinavian Journal Forest Research* 18:168-175.

Oja, J. 2000. Evaluation of knot parameters measured automatically in CT-images of Norway spruce (*Picea abies* (L.) Karst.). *Holz als Roh-und Werkstoff* 58:375-379.

PCI 2005. PCI Geomatics, user guide. Volume I. Version 10.1. Richmond Hill, ON, Canada.

Rojas, G.; Hernández, R.E.; Condal, A.; Verret, D.; Beauregard, R. 2005. Exploration of the physical properties of internal characteristics of sugar maple logs and relationships with CT images. *Wood and Fiber Science* 37(4):591-603.

Rojas, G.; Condal, A.; Beauregard, R.; Hernández, R.E.; Verret, D. 2006. Identification of internal defects of sugar maple logs from CT Images using supervised classification methods. *Holz als Roh-und Werkstoff* 64 (4): 295-303.

Rojas, G.; Beauregard, R.; Hernández, R.E.; Verret, D.; Condal, A. 2007. Effect of moisture content variation on CT image classification to identify internal defects of sugar maple logs. *Forest Products Journal* 57(4):38-43.

Richards, J.A.; Jia, X. 1999. *Remote Sensing Digital Image Analysis – An Introduction*. Springer Verlag Berlin Heidelberg.

Sarigul, E.; Abbott, A.L.; D.L. Schmoldt, D.L. 2003. Rule-driven defects detection in CT images of hardwood logs. *Computers and electronics in agriculture* 41:101-119.

Schmoldt, D.L.; He, J.; Abbot, A.L. 2000. Automated labeling of log features in CT imagery of multiple hardwood species. *Wood and Fiber Science* 32(3):287-300.

Seeram, E. 2001. *Computed tomography: physical principles, clinical applications, and quality control*. Second edition, W.B. Saunders Company. Philadelphia, PA, U.S.A.

Story, M.; Congalton, R.G.. 1986. Accuracy assessment: a user's perspective. *Photogrammetric Engineering and remote sensing*. 54(3):397-399.

Taylor, F.W.; Wagner, Jr., F.G.; McMillin, C.W. 1984. Locating knots by industrial tomography-A feasibility study. *Forest Products Journal* 34(5):42-46.

Wei, Q.; Leblon, B.; Chui, Y. C.; Zhang, S.Y. 2008. Identification of selected log characteristics from computed tomography images of sugar maple logs using maximum likelihood classifier and textural analysis. *Holzforschung* 62:441-447.

Zhu, D.; Connors, R.W.; Lamb, F.; Araman, P.A. 1991. A computer vision system for locating and identifying internal log defects using CT imagery. Pages 1-13 in Proc. Fourth International Conference on Scanning Technology in the Wood Industry, Burlingame, CA, U.S.A.

