

IDENTIFICACIÓN DEL CILINDRO NUDOSO EN IMÁGENES TC DE TROZAS DE *PINUS RADIATA*: ESTUDIO COMPARATIVO

IDENTIFICATION OF KNOTTY CORE IN *PINUS RADIATA* LOGS FROM CT IMAGES: COMPARATIVE STUDY

Gerson Rojas Espinoza¹, Oscar Ortiz Iribarren²

RESUMEN

El objetivo de este estudio fue comparar la precisión de los algoritmos de máxima verosimilitud (MV) y otro basado en redes neuronales artificiales (RNA), en la identificación del cilindro nudoso a partir de imágenes TC (Tomografía Computarizada) de trozas podadas de pino radiata (*Pinus radiata* D.Don). Para este fin, treinta trozas podadas fueron seleccionadas y luego escaneadas en un escáner médico *multi-slice* de rayos X (Tomografía Computarizada). Del total de imágenes TC obtenidas del escáner, 270 fueron seleccionadas para este estudio. Estas imágenes TC fueron clasificadas utilizando ambos algoritmos y los mapas temáticos obtenidos de este proceso, fueron posteriormente filtrados utilizando un filtro median de 7 x 7. Los resultados de la evaluación cuantitativa indicaron que el cilindro nudoso puede ser identificado con una precisión de 98.5 % y 96.3 % utilizando el clasificador MV y RNA, respectivamente. Aunque ambos algoritmos presentaron elevados valores de precisión para identificar el cilindro nudoso, el análisis estadístico de estos resultados arrojó diferencias significativas entre ambos valores de precisión; por lo tanto se concluye que el algoritmo de máxima verosimilitud presenta un mejor desempeño que el algoritmo basado en redes neuronales artificiales, en la identificación del cilindro nudoso en imágenes TC de trozas de pino radiata (*Pinus radiata* D.Don).

Palabras claves: Cilindro nudoso, tomografía computarizada (TC), pino radiata, máxima verosimilitud, redes neuronales artificiales

ABSTRACT

The aim of this study was to compare the accuracy of both the maximum likelihood classifier (ML) algorithm and another one based on an artificial neural networks classifier (ANN) algorithm for knotty core identification in CT images of pruned radiata pine (*Pinus radiata* D. Don) logs. For this purpose, thirty pruned radiata pine logs were chosen and then scanned in an X-ray *multi-slice* medical scanner (Computed Tomography (CT)). From the total CT images obtained, a sample of 270 CT images was selected for this study. This CT images were classified using both methods and the thematic map obtained afterwards, were filtered by a 7 x 7 median filter. Quantitative assessment results showed that knotty core can be identified with 98.5 % and 96.3 % accuracy by using the ML and ANN classifiers respectively. Although both algorithms showed a high capacity level to detect knotty core statistical analysis showed significant differences among those accuracy values; this is an indication that the maximum likelihood classifier algorithm shows a better performance compared

¹Académico (Ph.D) Departamento de Ingeniería en Maderas, Facultad de Ingeniería, Universidad del Bío-Bío, Concepción, Chile.

²Estudiante Graduado MSc. Departamento de Ingeniería en Maderas, Facultad de Ingeniería, Universidad del Bío-Bío, Concepción, Chile.

Autor para correspondencia: grojas@ubiobio.cl

Recibido: 06.09.2011 Aceptado: 26.12.2011

to the algorithms based on artificial neural networks for knotty core identification in CT images of radiata pine logs.

Keywords : Computed tomography (CT), radiata pine, knotty core, maximum likelihood, artificial neural networks

INTRODUCCION

En Chile, las principales empresas madereras realizan grandes esfuerzos por mejorar la calidad de sus bosques, principalmente, de la especie pino radiata (*Pinus radiata* D. Don), la cual sustenta la industria maderera debido a su disponibilidad y a las variadas aplicaciones de esta. En esta dirección, la poda es el principal tratamiento silvícola que las empresas están aplicando a los bosques de pino radiata (*Pinus radiata* D. Don) para obtener arboles de mejor calidad. La correcta y oportuna aplicación de la poda tendrá una incidencia directa en la mejora de la producción de madera libre de nudos. En general, este tratamiento, es una actividad que elimina la parte externa de 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 oclusión o cicatrización de la herida generada por el corte de la rama. Así, la parte interna de estas ramas queda confinada en el corazón del fuste, respecto al volumen total, y se denomina cilindro nudoso (CN). La zona externa al cilindro nudoso, corresponde a madera libre de defectos (MLD), y mientras mayor sea el diámetro del CN, menor será la proporción de MLD. En general, el diámetro del CN dependerá de la calidad del sitio, la calidad y número de podas y la edad y diámetro del árbol al momento de la poda.

En este sentido, la identificación del CN antes de iniciar el proceso de aserrío se transforma en uno de los principales problemas de los aserraderos en Chile, ya que no existe aun a nivel industrial una tecnología que permita identificar las características internas de las trozas.

En general, la identificación de las características y defectos internos de las trozas requiere de la utilización de técnicas no destructivas. En esta dirección, el ultrasonido (Birkeland y Han, 1991), la resonancia magnética nuclear (Chang *et al.* 1989; Coates *et al.* 1998) y Radiación gamma (Hagman 1993, Karsulovic *et al.* 2002 y 2005) son algunas de las técnicas utilizadas para este fin. Sin embargo, la Tomografía Computarizada (TC) de rayos X, ha mostrado un gran potencial para identificar defectos y características internas en trozos (Taylor *et al.* 1984, Funt y Bryant 1987, Zhu *et al.* 1991, Li *et al.* 1996, Guddanti y Chang 1998, Bhandarkar *et al.* 1999, Schmoldt *et al.* 1995, 1998, 2000, Oja y Temnerud 1999, 2000, Nordmark 2002, 2003, Longuetaud *et al.* 2004, 2005, 2007 y Rojas *et al.* 2005, 2007). La mayoría de estos autores coinciden en que la variación del contenido de humedad en la troza en algunos casos dificulta la identificación. Además, como el nivel de gris de las imágenes TC esta directamente relacionado con la densidad, éste varía dramáticamente con las diferentes especies y contenido de humedad. De igual manera, la reconstrucción 3D de características internas de trozas a partir de imágenes TC (2D), también ha sido explorada (Brüchert *et al.* 2008, Wei *et al.* 2009).

En otra dirección, varios métodos de clasificación de imágenes TC, basados en el conocimiento *a priori* del nivel de gris asociado a cada característica o defecto interno han sido evaluados, con el fin de mejorar la capacidad de interpretación de este tipo de imágenes. Rojas *et al.* (2006, 2007) presentaron un método de clasificación supervisada basado en el algoritmo de máxima verosimilitud (MV), para identificar y separar la albura del duramen, nudos y pudrición, a partir de imágenes TC de trozos de Arce (*Acer saccharum* Marsh). Los resultados indicaron que la albura puede ser identificada con una precisión de 97.2 %, mientras que la precisión global fue de 82.6 %. Por su parte, para esta especie y utilizando el algoritmo MV y un análisis de textura de las imágenes TC, Wei *et al.* (2008a) reportaron valores de precisión de 85.6 %, 72.1 % y 83 % para la detección de la albura, nudos y corteza, respectivamente.

La utilización de algoritmos de clasificación supervisada basada en redes neuronales artificiales (RNA) también ha sido evaluada para identificar y clasificar nudos, albura y otras características internas a partir de imágenes TC de trozas de diferentes especies (Schmoldt *et al.* 2000, Nordmark 2002, 2003, Wei *et al.* 2008b). En general, valores de precisión entre 90 % y 98.5 % fueron reportados por estos autores para nudos y algunas características internas de trozas de diferentes especies. Sin embargo, algunos de estos autores señalan que, si bien estas características internas fueron identificadas en las distintas especies, existe un cierto grado de superposición del nivel de gris en la zona límite entre los nudos y la madera libre de defectos.

Recientemente, Rojas y Ortiz 2009, 2010, desarrollaron un método de clasificación basado en MV y otro basado en RNA, respectivamente, para identificar el cilindro nudoso en imágenes CT de trozas podadas de pino radiata (*Pinus radiata* D. Don) crecido en Chile. Los resultados indicaron que el CN puede ser identificado y separado con un alto nivel de precisión utilizando ambos algoritmos. El objetivo principal del presente estudio, fue comparar la precisión de los algoritmos de MV y RNA, propuestos por estos autores, en la identificación del CN en imágenes CT de trozas podadas de pino radiata (*Pinus radiata* D. Don) crecido en Chile.

MATERIALES Y METODOS

Material y escaneo de trozas

Treinta árboles podados de pino radiata (*Pinus radiata* D. Don) 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, luego, cada rollizo fue trozado en tres partes de un metro de longitud cada una. Estas trozas así obtenidas fueron marcadas y luego selladas en cada extremo con impermeabilizante *Anchorseal*, para evitar la pérdida de humedad. Un total de noventa trozas fueron obtenidas y utilizadas como material de ensayo.

Las noventa 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. El proceso de escaneo fue realizado a 120 Kvp y 249 mA, donde las imágenes TC resultantes fueron obtenidas cada 5 mm y en formato de 512 x 512 píxeles. Estas imágenes TC fueron 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. Las 200 imágenes TC obtenidas para cada troza fueron analizadas con el objetivo de seleccionar aquellas en las que se observó la presencia del CN. Por cada troza, tres imágenes TC fueron seleccionadas, donde en a lo menos una de ellas se observara la presencia del CN. Finalmente una muestra de 270 imágenes TC fue utilizada en el estudio.

Procedimientos de Clasificación y post Clasificación

El objetivo principal del procedimiento de clasificación de una imagen es identificar o segmentar la imagen en términos de objetos ó áreas de interés. La imagen resultante del proceso de clasificación se denomina mapa temático. La clasificación supervisada de una imagen se basa en el conocimiento previo del número de clases espectrales (áreas de interés) y algunas características asociadas a cada clase espectral presente en una imagen (Mather 1987). En general, las características asociadas son obtenidas a partir de muestras de píxeles, denominadas 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 este estudio, el procedimiento de clasificación de las imágenes se inicio con la generación del conjunto de entrenamiento, obtenido a partir de una muestra de píxeles de las clases espectrales a

identificar, en este caso, el cilindro nudoso (CN), madera libre de defectos (MLD) y nudos (N). Este conjunto de entrenamiento fue utilizado posteriormente como información de entrada por ambos algoritmos de clasificación.

Clasificador de máxima Verosimilitud

En general el clasificador MV utiliza algunos parámetros estadísticos, como el vector medio y la matriz de co-varianza de cada clase espectral 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 espectrales. La descripción del proceso de clasificación y pos clasificación utilizando el algoritmo de clasificación supervisada MV fue presentada en Rojas y Ortiz 2009. A diferencia del estudio anterior, en el presente estudio se consideraron los resultados obtenidos para la muestra total de 30 árboles.

Clasificador basado en redes neuronales artificiales

Las RNA son modelos computacionales que se desarrollaron originalmente, para modelar la forma en que los cerebros humanos desarrollan una determinada tarea y entre sus variadas aplicaciones se encuentra la clasificación y análisis de imágenes. Normalmente, la RNA consta de un determinado número de elementos simples denominados neuronas, las cuales están organizadas en capas. Cada neurona está conectada con otras neuronas mediante enlaces de comunicación, donde cada enlace tiene asociado un peso. En los pesos se encuentra el conocimiento que tiene la RNA respecto de un problema. Normalmente la RNA consta de una capa de entrada, una o más capas ocultas y una capa de salida. En el método propuesto por Rojas y Ortiz 2010 para la identificación del CN, la configuración retro propagación (back-propagation (BP) ANN) fue utilizada. En general, la arquitectura típica de la retro-propagación se ilustra en la Figura 1.




Figura 1. Arquitectura típica de una RNA de retro -propagación.

En este caso, el proceso de clasificación de las imágenes TC se inicia con el entrenamiento de RNA utilizando el conjunto de entrenamiento. En esta etapa se definen los valores de la tasa de aprendizaje y el momento, los cuales controlan el tamaño del cambio de los pesos en cada iteración. La tasa de aprendizaje es el parámetro responsable de acelerar la velocidad de respuesta de la RNA, mientras que el momento se utiliza para controlar las posibles oscilaciones que se generan en la variación de los pesos y reduce la posibilidad que el sistema converja hacia a un mínimo local. La última etapa corresponde al proceso de clasificación utilizando la RNA entrenada. El procedimiento basado en RNA analizado en este estudio fue presentado por Rojas y Ortiz 2010.

Finalmente como etapa de post clasificación, un filtro median de 7 x 7 fue aplicado a los mapas temáticos obtenidos del proceso de clasificación con los algoritmos de máxima verosimilitud y redes neuronales, con el objetivo de remover el ruido generado por el proceso de clasificación.

Evaluación de la precisión de la clasificación

La capacidad de detección del CN, MLD y nudos, de los algoritmos MV y RNA fue evaluada, mediante la determinación de la precisión de la clasificación. 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. 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 de confusión indica el grado de acuerdo entre ambos grupos de datos. La precisión global (expresada en porcentaje) para un mapa temático 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.

Los valores de precisión de detección del CN, MLD y nudos fueron obtenidos a partir de la matriz de confusión determinada para cada mapa temático evaluado (Rojas y Ortiz, 2009 2010). La matriz de confusión asociada a cada mapa temático y mapa temático filtrado fue obtenida de una muestra de 70 píxeles seleccionados aleatoriamente (Richards y Jia 1999) de cada mapa temático. Las matrices de confusión fueron obtenidas utilizando el software PCI (PCI 2005).

RESULTADOS Y DISCUSION

Clasificación de imágenes TC

En la figura 2a, se presenta una imagen digital de una sección transversal típica de una troza podada de pino radiata (*Pinus radiata* D. Don) en la cual se observa una zona central que incluye los nudos y que corresponde al cilindro nudoso y una zona externa al cilindro nudoso, que corresponde a madera libre de defectos. La figura 2b muestra la imagen TC correspondiente a la sección transversal presentada en la figura 2a.




Figura 2. (a) Imágen digital de una sección transversal de una troza de pino radiata (*Pinus radiata* D.Don) mostrando la presencia del cilindro nudoso, madera libre de defectos y nudos. (b) Imágen TC de sección transversal de (a)

Los mapas temáticos obtenidos del proceso de clasificación y pos clasificación de esta imágen TC utilizando el algoritmo MV y RNA se presentan en las figuras 3a, 3b, 3c, 3d, respectivamente. Analizando y comparando visualmente las imágenes de las Figuras 3a y 3c, en general, se observa que ambos algoritmos de clasificación logran identificar y separar el CN (zona central de color azul) de MLD (zona externa de color amarillo). Aunque no se observa una marcada diferencia entre ambos mapas temáticos, si se observa una superposición del nivel de gris (ruido) en la zona de MLD, la cual corresponde a líneas concéntricas de color rojo. Esto, esta asociado principalmente a




Figura 3. (a) Mapa temático obtenido con MV para 2 b. (b) Mapa temático (a) pero filtrado usando un filtro median de 7 x 7. (c) Mapa temático obtenido con RN para 2b. (d) Mapa temático (c) pero filtrado usando un filtro median de 7 x 7.

la diferencia de densidad entre la madera de primavera y de verano que forma parte de los anillos de crecimiento del árbol. De igual manera, se observa un cierto nivel de ruido en la zona periférica de la troza (áreas de color rojo y azul), el cual es atribuido principalmente a la disminución del contenido de humedad debido a la ausencia de corteza. Esto puede ser explicado a partir del principio físico del escáner TC, ya que la información obtenida en las imágenes TC está relacionada con la densidad verde de la troza, la cual es sensible a la variación del contenido de humedad. Taylor *et al.* (1984), Funt y Bryant (1987), Schmoltdt *et al.* (1995), Oja y Temnerud (1999) y Rojas *et al.* (2006, 2007) entre otros autores, señalan que la variación del contenido de humedad de las trozas dificulta en algunos casos la identificación de defectos y características internas de las trozas.

Sin embargo, después de aplicar un filtro median de 7 x 7 a cada mapa temático, el nivel de ruido asociado a los anillos de crecimiento es eliminado totalmente, excepto algunos puntos aislados (Figura 3b), mientras que el ruido en la zona periférica no presenta mayores cambios (Figura 3b y 3d). Con respecto a los nudos, debido a que estos se localizan al interior del CN (áreas de color rojo y azul) esto no es un problema, ya que ambos son considerados defectos.

En general, los resultados de este análisis cualitativo exploratorio de las imágenes CT indican que es posible identificar y separar el CD de MLD y nudos utilizando ambos algoritmos. Sin embargo esto no es suficiente para obtener conclusiones más robustas. Por esta razón, a partir de la determinación de la *matriz de confusión* de los mapas temáticos es posible obtener valores de precisión de la capacidad de identificación de ambos algoritmos.

La evaluación cuantitativa de la capacidad de identificación de CN, MLD y nudos, obtenida por ambos métodos, fue realizada mediante la determinación y análisis de la *matriz de confusión*. La tabla 1 y 2 presentan las *matrices de confusión* obtenidas por MV para los mapas temáticos y mapas temáticos filtrados, respectivamente. La tabla 1 muestra que el valor de precisión de CN fue de 96.9 %, mientras que un valor de 79.9 % fue obtenido para la precisión global. En general, el resultado obtenido para CN es prometedor, ya que sugiere que este podría ser identificado y separado de las otras clases en imágenes CT utilizando MV. Los errores de omisión en la identificación de CN, están asociados principalmente a la clase nudos, con un 2.9 % (61/2078), mientras que el 0.2 % restante está asociado a MLD. Esto podría ser explicado, por un efecto combinado de densidad y contenido de humedad en algunas zonas de los anillos de crecimiento al interior de CN, lo cual produce una superposición de nivel de gris de algunos píxeles de CN con el nivel de gris de píxeles asociados a los nudos.

Para la clase MLD y nudos, fueron obtenidos valores de precisión de 77.6 % (9376/12085) y 63.6 % (278/437), respectivamente. Estos menores valores de precisión pueden ser explicados analizando los errores de omisión generados durante la clasificación con MV. Para el caso de MLD, el principal error está asociado a la clase nudos con un valor de 19.9 % (2401/12085), seguido por CN con un valor de 2.5 % (308/12085). Esto significa que 2401 píxeles de MLD fueron erróneamente clasificados como nudos y 308 como CN. Para la clase nudos, el error está asociado principalmente con MLD, con un valor de 35 % (155/437). En general, estos errores están en acuerdo con los resultados obtenidos del análisis visual o cualitativo de las imágenes. Después de aplicar un filtro median de 7x7 a los mapas temáticos, los valores de precisión de CN y global aumentaron a 98.5 % y 90.4 %, respectivamente (Tabla 2). En general, la literatura revisada no reporta estudios asociados a la aplicación de MV para la especie pino radiata. Sin embargo, estos resultados podrían ser comparados con los resultados obtenidos por Rojas *et al.* 2006, quienes reportaron valores de precisión para MLD y global de 97.2 % y 82.6 %, para trozas de Arce (*Acer saccharum* Marsh), respectivamente. Para esta especie, Wei *et al.* 2008a reportaron valores de precisión de MLD y global de 85.6 % y 79.8 %, respectivamente.

Tabla 1. *Matriz de confusión* obtenida con Máxima Verosimilitud

Clasificados como	Clases verdaderas			Total
	Cilindro Nudoso	Madera sin defectos	Nudos	
Cilindro Nudoso	2014	308	4	2326
Madera sin defectos	3	9376	155	9534
Nudos	61	2401	278	2740
Total píxeles	2078	12085	437	14600
Precisión (%)	96.9	77.6	63.6	79.9

Tabla 2. *Matriz de confusión* obtenida con Máxima Verosimilitud filtrado

Clasificados como	Clases verdaderas			Total
	Cilindro Nudoso	Madera sin defectos	Nudos	
Cilindro Nudoso	2046	498	43	2587
Madera sin defectos	3	10913	154	11070
Nudos	29	674	240	943
Total píxeles	2078	12085	437	14600
Precisión (%)	98.5	90.3	54.9	90.4

Los resultados de la evaluación cuantitativa obtenidos con el clasificador RNA, se muestran en la tabla 3. En esta tabla se observa que los valores de precisión de CN y global fueron de 92.7 % y 85.0 %, respectivamente. Estos resultados indican que con el clasificador RNA, también es posible identificar y separar el CN de la clase MLD y nudos, aunque el valor obtenido es menor que el obtenido con MV. Los errores de omisión en la identificación de CN, mantienen la tendencia observada en el clasificador MV, en el sentido que están principalmente asociados a la clase nudos, con un valor de error de omisión de 7 % (146/2078). En esta dirección, valores de precisión de 84.8 % y 52.8 % fueron obtenidos para MLD y nudos, respectivamente. Para MLD, los principales errores dan cuenta de la existencia de una leve superposición del nivel de gris entre la clase nudos y MLD. Esto puede ser atribuido a que al interior de los nudos existe una leve variación de los valores de nivel de gris, probablemente por una variación del contenido de humedad, lo cual permite que algunos píxeles presentes niveles de gris similares a píxeles que forman parte de la madera temprana o tardía de los anillos de crecimiento de la zona MLD. Para la clase nudos, el principal error está asociado con la clase MLD. Después de filtrar los mapas temáticos, los valores de precisión de CN y global aumentaron a 96.3 % y 92.3 %, tal como se muestra en la tabla 4. Al igual como ocurre con MV, para la especie pino radiata, la literatura no reporta estudios asociados al uso de RNA en la identificación de CN. Sin embargo, estos valores podrían ser comparables con los obtenidos para otras especies de coníferas y latifoliadas (Schmoldt *et al.* 2000, Nordmark 2002, Wei *et al.* 2008b).

Tabla 3. Matriz de confusión obtenida con redes neuronales artificiales

Clasificados como	Clases verdaderas			Total
	Cilindro Nudoso	Madera sin defectos	Nudos	
Cilindro Nudoso	1927	226	3	2156
Madera sin defectos	5	10253	203	10461
Nudos	146	1607	230	1983
Total píxeles	2078	12086	436	14600
Precisión (%)	92.7	84.8	52.8	85.0

Tabla 4. Matriz de confusión obtenida con redes neuronales artificiales filtradas

Clasificados como	Clases verdaderas			Total
	Cilindro Nudoso	Madera sin defectos	Nudos	
Cilindro Nudoso	2002	312	22	2336
Madera sin defectos	3	11262	200	11465
Nudos	73	512	214	799
Total píxeles	2078	12086	436	14600
Precisión (%)	96.3	93.2	49.1	92.3

En general, los valores de precisión CN y global obtenidos por los algoritmos MV y RNA aumentaron cuando se aplicó el filtro mediano de 7 x 7, lo que indica que la etapa de pos clasificación mejora estos valores. Un análisis de varianza fue realizado para establecer si existen diferencias significativas entre los valores de precisión obtenidos para los mapas temáticos y mapas temáticos filtrados. Los resultados del análisis estadístico realizado para los valores de precisión de CN y Global, indicaron que existen diferencias significativas entre los valores de precisión obtenidos del proceso de clasificación y pos clasificación (Tabla 5). Esto indica que efectivamente, el filtrado de las imágenes mejora los valores de precisión de la clasificación utilizando ambos algoritmos.

Tabla 5. Resultados del análisis de varianza para valores de precisión de CN y global obtenidos por ambos algoritmos

Fuente de variación	df	Cilindro Nudoso			Global		
		Mean square	F value	Pr > F	Mean square	F value	Pr > F
MV							
Algoritmos	1	0.0268023	7.9	< 0.0052	1.1822521	371.43	< 0.0000
Error	432	0.0033925			0.0031829		
RN							
Algoritmos	1	0.1434423	19.4	< 0.0000	0.598186	200.53	< 0.0000
Error	432	0.007391			0.002983		

Finalmente, como el objetivo principal de este estudio fue comparar la precisión de los algoritmos MV y RNA, en la identificación del cilindro nudoso a partir de imágenes TC de trozas podadas de pino radiata (*Pinus radiata* D. Don), un análisis estadístico fue realizado. Un análisis de varianza de una vía fue realizado para comparar los valores de precisión de CN y global obtenidos por ambos algoritmos para los mapas temáticos filtrados. Los resultados de este análisis indicaron que los valores de precisión obtenidos por ambos algoritmos presentan diferencias significativas (Tabla 6). De acuerdo a estos resultados, se sugiere que el algoritmo de máxima verosimilitud presenta un mejor desempeño en la identificación y separación de cilindro nudoso que el algoritmo basado en redes neuronales, con un valor de precisión de 98.5 %.

Tabla 6. Resultados del análisis de varianza de los valores de precisión CN y global entre ambos algoritmos

Fuente de variación	df	Cilindro nudoso			Global		
		Mean square	F value	Pr > F	Mean square	F value	Pr > F
Algoritmos	1	0.0531894	13.83	< 0.0002	0.0386364	15,55	< 0.0001
Error	432	0.0038464			0.0024845		

CONCLUSIONES

El análisis cualitativo exploratorio de los mapas temáticos obtenidos del proceso de clasificación con ambos algoritmos, indico que en general, el cilindro nudoso puede ser identificado y separado de la madera libre de defectos y de los nudos, debido a la diferencia observada entre los niveles de grises asociados a estas tres clases. Sin embargo, se observó una leve superposición entre el nivel de gris asociado a MLD y nudos, lo cual puede ser asociada a variación de la densidad y contenido de humedad al interior del trozo.

Los resultados de la evaluación cuantitativa indicaron que después de filtrar los mapas temáticos, el cilindro nudoso puede ser identificado con una precisión de 98.5 % y 96.3 % con el clasificador MV y RNA, respectivamente. El resultado del análisis estadístico, realizado para comparar la precisión de ambos clasificadores, indico que existen diferencias significativas entre los valores de precisión. Esto sugiere que el algoritmo de máxima verosimilitud presenta un mejor desempeño (98,5 %) que el algoritmo basado en redes neuronales artificiales, en la identificación y separación del cilindro nudoso en imágenes TC de trozas podadas de pino radiata (*Pinus radiata* D. Don).

AGRADECIMIENTOS

Los autores agradecen al personal del Laboratorio de Imagenología del Hospital del Trabajador por su asistencia durante la etapa de escaneo de las trozas, a la Sra. Linette Salvo, Departamento de Ingeniería en Maderas, de la Universidad del Bío-Bío, por el apoyo logístico durante el desarrollo de la parte experimental. 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.

Brüchert, F.; Baumgartner, R.; Sauter, U.H. 2008. Ring width detection industrial purposes – use of CT and discrete scanning technology on fresh roundwood. Conference COST E53, 29-30 October, Delhi, The Netherlands.

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 Product 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.

Guddanti, S.; Chang S.J. 1998. Detection of internal defects by automatic interpretation of computer tomography. *Forest Product Journal* 37(1):56-62.

Hagman, P.O.G. 1993. Automatic quality sorting of *Picea abies* logs with a gamma ray log scanner. *Scandinavian journal of Forests Research* 8 (1-4):583-590.

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.

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.

Longuetaud, F.; Leban, J.M.; Mothe, F.; Kerrien, E.; Berger, M.O. 2004. Automatic detection of pith on CT images of spruce logs. *Computers and Electronics in Agriculture* 44 (2):107-119.

Longuetaud, F.; Saint-André, L.; Leban, J.M. 2005. Automatic detection of annual growth units on *Picea abies* logs using optical and X-ray techniques. *Journal of Nondestructive evaluation* 24(1):29-43.

Longuetaud, F.; Mothe, F.; Leban, J.M. 2007. Automatic detection of the heartwood/sapwood boundary within Norway spruce (*Picea abies* (L.) Karst.) logs by means of CT images. *Computers and Electronics in Agriculture* 58(2):100-111.

- Mather, P. M. 1987.** *Computer processing of remotely sensed images, an introduction*. Bury St Edmunds, Suffolk.
- Nordmark, U. 2002.** Knot identification from CT images of young *Pinus sylvestris* saw logs using artificial neural networks. *Scandinavian Journal Forest Research* 17(1):72-78.
- Nordmark, U. 2003.** Models of knot and log geometry of young *Pinus sylvestris* sawlogs extracted from computed tomographic images. *Scandinavian Journal of Forest Research* 18(2):168-175.
- Oja, J.; Temnerud. 1999.** The appearance of resin pocket in CT images of Norway spruce (*Picea abies* (L.) Karst.). *Holz als Roh-und Werkstoff* 57(5):400-406.
- 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(5): 375-379.
- PCI. 2005.** PCI Geomatics, user guide. Volume I. Version 10.1. 50 West Wilmot street, Richmond Hill, Ontario, 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.
- Rojas, G.; Ortiz, O. 2009.** Identificación del cilindro nudoso en imágenes TC de trozas podadas de *Pinus Radiata* utilizando el clasificador de máxima verosimilitud. *Maderas. Ciencia y tecnología* 11(2): 117-127.
- Rojas, G.; Ortiz, O. 2010.** Identificación del cilindro nudoso en imágenes TC de trozas podadas de *Pinus Radiata* utilizando redes neuronales artificiales. *Maderas. Ciencia y tecnología* 12(3): 229-239.
- Richards, J.A.; Jia, X. 1999.** *Remote Sensing Digital Image Analysis – An Introduction*. Springer Verlag Berlin Heidelberg. Germany. 363p.
- Schmoltdt, D.L.; Li, P.; Abbott, A.L. 1995.** Log defect recognition using CT-images and neural net classifiers. 2nd International Workshop/Seminar on Scanning Technology and Image Processing on Wood. Skellefteå Sweden, Aug 14-16. pp 77-97.
- Schmoltdt, D.L.; He, J.; Abbott, A.L. 1998** A comparison of several artificial neural network classifiers for CT images of hardwood logs. Machine vision applications in industrial inspection VI. The International Society for Optical Engineering (SPIE), vol. 3306. Pp 34-43.
- Schmoltdt, 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.

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. 2008a. Identification of selected log characteristics from computed tomography images of sugar maple logs using maximum likelihood classifier and textural analysis. *Holzforschung* 62(4): 441-447.

Wei, Q.; Chui, Y.C.; Leblon, B.; Zhang, S.Y. 2008b. Identification of log characteristics in tomography images using back-propagation neural networks with the resilient back- propagation training algorithm and textural analysis: preliminary results. *Wood Fiber Science* 40(4): 620-633.

Wei, Q.; Zhang, S.Y.; Chui, Y.H.; Leblon, B. 2009. Reconstruction of 3D images of internal log characteristics by means of successive 2D log computed tomography images. *Holzforschung* 63(5): 575-580.

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. *in Proc. Fourth International Conference on Scanning Technology in the Wood Industry*, Burlingame, CA, U.S.A. Pp 1-13.

