

Ra Ximhai

Revista de Sociedad, Cultura y Desarrollo
Sustentable

Ra Ximhai
Universidad Autónoma Indígena de México
ISSN: 1665-0441
México

2005

RECONOCIMIENTO DE DEFECTOS EN MADERAS UTILIZANDO UNA RED NEURO DIFUSA

Graciela María de Jesús Ramírez Alonso y Mario I. Chacón
Ra Ximhai, septiembre-diciembre, año/Vol.1, Número 3
Universidad Autónoma Indígena de México
Mochicahui, El Fuerte, Sinaloa. pp. 577-589

**RECONOCIMIENTO DE DEFECTOS EN MADERAS UTILIZANDO UNA
RED NEURO DIFUSA**
RECOGNITION OF DEFECTS IN WOOD USING A DIFFUSE NETWORK NEURO

Graciela María de Jesús **Ramírez-Alonso**¹ y Mario I. **Chacón**¹

Instituto Tecnológico de Chihuahua. Laboratorio de DSP y Visión. Ave. Tecnológico 2909 CP.31310, Tel. 4-137474 Ext 112 y 114. Chihuahua, Chihuahua. Correo electrónico: gramirez,mchacon@itchihuahua.edu.mx.

RESUMEN

Este artículo, describe un clasificador neuro difuso, que diferencia entre 4 tipos de defectos en maderas conocidos como botones. La inspección visual de estos defectos por humanos, tiene un alto grado de complejidad ya que dentro de una misma clase existen variaciones en forma, tamaño y color. Las características utilizadas por el clasificador se extrajeron de las imágenes de maderas mediante filtros Gabor 2D. Estos filtros son muy utilizados para imágenes, en donde la textura es un factor importante. Para reducir la dimensionalidad del vector de características, se utilizó el Método de Incorporación. La red neurodifusa se diseñó a partir de una red de Funciones de Base Radial, FBR, de dos capas en donde las entradas de la red se fuzifican antes de iniciar el entrenamiento. El reconocimiento que se alcanzó fue del 97.05% siendo un resultado aceptable, teniendo en cuenta que un inspector humano alcanza un reconocimiento entre el 75 y 85%.

Palabras Clave: Neurodifuso, madera, método de incorporación.

Abstract

This article describes to a neuro-difusse sort key that marks a difference between four types of defects in wood known like bellboys. The visual inspection by humans of these defects has a high degree of complexity since within a same class variations in form, size and color exist. The characteristics used by the sort key were extracted of the wood images by means of Gabor filters 2D. These filters very are used for images in where the texture is an important factor. The Method of Incorporation was used In order to reduce the dimensionality of the vector of characteristics. The neuro-difusse network was design from a network of Radial Base Functions, FBR, of two layers in where the entrances of the network are fuzified before initiating the training. The recognition that was reached was of the 97. 05% being an acceptable result considering that a human inspector reaches recognition between 75 and 85%.

Key words: neuro-difusse, wood, method of incorporation.

Recibido. 15 de mayo de 2005. Aceptado: 27 de agosto de 2005.

Publicado como NOTA en Ra Ximhai 1: 577-589. 2005.

INTRODUCCIÓN

La teoría de redes neurales artificiales, RNA, y lógica difusa, LD, se ha aplicado en varios problemas de reconocimiento de patrones teniendo resultados aceptables (Ritter *et al.*, 1998; Bezdek *et al.*, 1992). Conforme se ha ido avanzando en el área de reconocimiento de patrones, se han propuesto nuevas técnicas que incorporan aspectos de las redes neurales, en el sentido de que los sistemas tengan la capacidad de aprender y generalizar, y aspectos de lógica difusa, en la cual el sistema trate de imitar el razonamiento humano y tenga la capacidad de manejar incertidumbre. Esto hace que los modelos computacionales diseñados para reconocimiento de patrones sean más inteligentes y poderosos (Chin y Lee, 1995). A este tipo de sistemas se les conoce con el nombre de redes neuro difusas (Casanova, 2002).

Se ha encontrado que la red FBR, es funcionalmente equivalente a un sistema difuso simple bajo ciertas condiciones (Yaochu *et al.*, 2000). Esta equivalencia funcional, permite combinar las características de modelos de RNA y LD, en uno solo tomando ciertas consideraciones. En este trabajo se optó por fusificar las entradas a la red FBR antes de que comience su entrenamiento formando así una red neural difusa.

En la industria maderera, la calidad de las hojas de madera determina su precio en el mercado. La calidad depende del número de defectos y su distribución. Un inspector diferencia los defectos de acuerdo a su apariencia y textura y así determina si la madera es buena o no. Esta labor no es sencilla ya que dentro de una misma clase existen variaciones en la forma, tamaño y color del defecto. El defecto más común que se encuentra en la madera es el llamado “nudo o botón”. En el presente trabajo se clasifican cuatro clases de botones, los cuales se identificarán por sus siglas en inglés, **EN** se refiere al defecto llamado “encased”, **SO** al defecto “sound”, **LE** al defecto “leaf” y **ED** al defecto “edge”.

Se tienen un total de 140 imágenes, las cuales ya han sido clasificadas por expertos. Tanto las imágenes como su clasificación fueron adquiridas de un experimento ya realizado por la Universidad de Oulu, Finlandia (Silven *et al.*, 2003). Anteriormente se han hecho otros trabajos que clasifican estas mismas clases de defectos, pero utilizando diferentes técnicas

para extracción de características o diferentes tipos de RNA (Jouko y Seppo, 1994; Jouko y Seppo, 1996; Jouko *et al.*, 1995; kauppinen *et al.*, 1999).

Lo novedoso en este trabajo es que se utiliza una red neuro difusa para la clasificación de los cuatro defectos en madera. Esta red neuro difusa integra características de una red FBR así como la de un sistema difuso.

MATERIALES Y MÉTODOS

Tipos de botones en la madera

Los cuatro tipos de defectos que se manejan en este trabajo son: *EN*, *LE*, *ED* y *SO*. Los botones *EN* son aquellos que están rodeados por una región oscura. Lo que caracteriza a un defecto *LE* es que tiene forma de hoja. Los botones *ED* se localizan en la orilla de la madera. Los defectos *SO* son aquellos que presentan rasgaduras o poca porosidad en el botón (Jouko y Seppo, 1996; Kauppinen *et al.*, 1999). La Figura 1 muestra cada uno de los defectos antes mencionados.

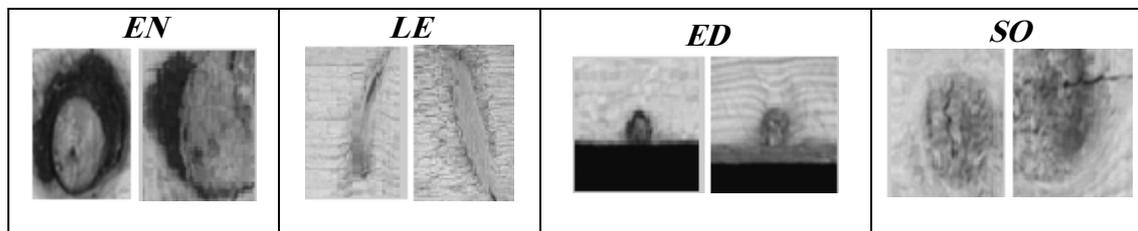


Figura 1. Cuatro tipos de defectos en la superficie de maderas.

Un inspector, identifica los defectos guiándose por las características de forma, tamaño, estructura y color. Comúnmente en un sistema de inspección visual, la clasificación se basa en características geométricas del defecto, tales como tamaño del defecto, tamaño del mínimo cuadrado que encierra el defecto, diámetro, posición del defecto en la madera y promedio de nivel de gris (Jouko y Seppo, 1996). Si solamente se toman estas características para identificar diferentes clases de defectos el resultado del clasificador será muy deficiente, ya que dentro de una misma clase el tamaño del defecto varía, además de que algunos defectos son muy similares entre sí y es muy difícil separarlos si se cuenta

solamente con esta información. Además, las características geométricas requieren de la segmentación de los defectos, lo cual resulta difícil para algunos tipos de clases (Jouko y Seppo, 1996). Por esta razón es necesario utilizar técnicas que extraigan características de textura en las imágenes. Una opción es emplear filtros Gabor. Estos filtros poseen la cualidad de extraer características en diferentes frecuencias y orientaciones de la imagen, siendo estas características invariantes a rotación, traslación y dimensión del defecto a analizar.

Preprocesamiento de la Imagen

Filtros Gabor

Los filtros Gabor, se pueden describir como un modelo computacional, que pretende simular la forma en la que son analizadas las imágenes, por la población de células de la corteza visual. Lo que se realiza en los filtros Gabor de 2-D es lo siguiente: se diseñan varios filtros, pasa banda (banco de filtros), los cuales responden a diferentes frecuencias y orientaciones definidas por las características de una onda gaussiana (ancho y orientación de la onda), la señal será filtrada con cada uno de estos filtros, resultando en varias imágenes filtradas las cuales guardarán información relacionada a la frecuencia y orientación a la que se encuentra el filtro. Este proceso trata de simular lo que le sucede a las células simples de la corteza visual al analizar imágenes.

El banco de filtros Gabor utilizado en este trabajo se define con la siguiente ecuación:

$$\psi(f, \theta, x, y) = \exp(i(f_x x + f_y y) - \frac{f^2(x^2 + y^2)}{2\sigma^2}) \quad (1)$$

Donde

$$f_x = f \cos \theta, \quad f_y = f \sin \theta \quad y \quad i = \sqrt{-1}$$

x y y son las coordenadas de los píxeles de la imagen en el rango $(-x/2, x/2)$ y $(-y/2, y/2)$. La frecuencia central del pasa banda es f , la orientación espacial es θ , y el parámetro σ determina el ancho de banda del filtro. En este trabajo el valor de σ es e 1.5π .

Teniendo cuidado de que las frecuencias de los filtros no fueran mayor de π se determinaron los siguientes valores para f_k :

$$f_k = \frac{\pi}{\sqrt{2^k}} \quad k = 2,3,4 \text{ y } 5 \quad (2)$$

Y las orientaciones que se utilizaron fueron las siguientes:

$$\theta_t = \frac{\pi t}{8}, \quad t = 0, \dots, 7 \quad (3)$$

Donde k determina la banda de frecuencia (resolución de los detalles extraídos por el filtro) y t enumera las orientaciones.

La representación de la transformada Gabor de una imagen, es la convolución de la imagen con el banco de filtros Gabor de la ecuación 1. Aplicando el teorema de convolución, la salida del filtro Gabor de la imagen por medio de la transformada de Fourier se define de la siguiente manera:

$$\mathfrak{F}\{O_{f,\theta}(x, y)\} = \mathfrak{F}\{I(x, y)\} \mathfrak{F}\{\psi_{f,\theta}(x, y)\} \quad (4)$$

Y

$$O_{f,\theta}(x, y) = \mathfrak{F}^{-1}\{\mathfrak{F}\{I(x, y)\} \mathfrak{F}\{\psi_{f,\theta}(x, y)\}\} \quad (5)$$

Donde $O_{f,\theta}$ es la imagen filtrada, $I(x,y)$ es la imagen original, $\psi_{f,\theta}(x,y)$ es la onduleta Gabor a utilizar donde f y θ indican la frecuencia y la orientación a la que se está trabajando, \mathfrak{F} y \mathfrak{F}^{-1} indica la transformada de Fourier y la transformada inversa de Fourier, respectivamente.

En este trabajo se utilizaron cuatro frecuencias y ocho orientaciones formando un banco de 32 filtros. Sólo se trabajó con la magnitud de la salida de los filtros, $|O_{f,\theta}|$, ya que ésta es robusta y tolerante a distorsiones para tareas de reconocimiento de patrones. Para acelerar la etapa de preprocesamiento todas las imágenes fueron normalizadas a un tamaño de 64x64 y se utilizaron imágenes en escala de grises. Para agrupar en una sola matriz toda la información de las 32 imágenes filtradas se realizó lo siguiente:

Desde $\theta=1$ hasta 8 (indica número de orientaciones que se manejan)

Desde $f=1$ hasta 4 (número de frecuencias)

Se toma la magnitud de la salida $|O_{f,\theta}|$ a frecuencia f orientación θ , la cual tiene un tamaño de 64×64

Se concatenan las columnas de $|O_{f,\theta}|$ formando una matriz de 4096×1

Se submuestra la matriz de 4096×1 por un factor de 4 formando ahora una matriz de 1024×1

Se guarda ese resultado

$f=f+1$

$\theta = \theta + 1.$

Extracción de Características

Una vez que se realizó todo lo anterior, por cada imagen a analizar se tiene ahora una matriz de 1024×32 , la cual guarda diferentes características a cuatro frecuencias y ocho orientaciones. Buscando características fáciles de entender y calcular se decidió utilizar la media y desviación estándar de cada una de las 32 columnas formando ahora una matriz de 2×32 . Esta matriz se reajustó a un tamaño de 1×64 en donde los primeros 32 elementos indican la desviación estándar y los siguientes 32 la media. Además se añadieron dos características más, la desviación estándar y media de la imagen original, formando ahora un vector de características de tamaño 1×66 . La Figura 2 muestra un esquema de lo que se explicó anteriormente.

Buscando reducir la dimensionalidad del vector de características se decidió utilizar el Método de Incorporación. En este método se realiza lo siguiente: primero evalúa a cada una de las N variables características, escogiéndose la que produzca el mejor rendimiento del clasificador. Luego se forman todos los subconjuntos posibles de dos características formados por la óptima y otra cualquiera escogiéndose la pareja que dé lugar al rendimiento más elevado. Después, se forman todos los subconjuntos posibles de tres características formados por las dos óptimas más una cualquiera del resto, eligiéndose aquel subconjunto que produzca el rendimiento más alto. Este procedimiento continúa hasta el rendimiento del clasificador llegue a un máximo, lo cual se determina de manera experimental.

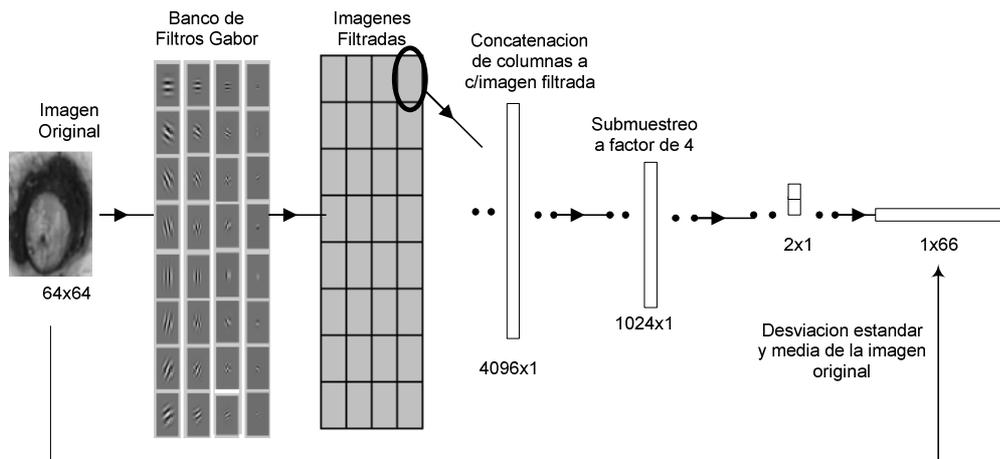


Figura 2. Diagrama a bloques de la etapa de extracción de características de la imagen.

Red Neural Difusa

Estudios realizados han demostrado que las redes FBR son funcionalmente equivalentes a un sistema difuso bajo ciertas condiciones (Yaochu *et al.*, 2000). Esta equivalencia funcional hace posible combinar las características de estos dos modelos en uno solo, conocido como sistema neuro difuso.

Tomando esto en consideración se diseñó una red neuro difusa a partir de una red FBR. A continuación se explicará el funcionamiento de la red.

La red que se utilizó es una FBR probabilística de dos capas. Cuando una entrada se presenta a la red, la primera capa calcula la distancia entre el vector de entrada y los vectores de entrenamiento y produce un vector cuyos elementos indican que tan cerca está la entrada de los vectores de entrenamiento. La segunda capa suma la contribución a cada clase y produce un vector de probabilidades, la clase que se encuentre más cercana al vector de entrada tendrá la probabilidad más alta de representarla. Finalmente la salida de la segunda capa escoge la clase que tuvo el valor más alto de probabilidad y produce un 1 para esa clase y un 0 para todas las demás, es decir en esta capa se realiza una competencia entre las clases para representar a la entrada (Math Works Inc., 2002). La función de activación de la primera capa, es una función gaussiana, la cual producirá un máximo de 1 cuando la distancia entre la entrada y el vector de prueba sea 0. Conforme la distancia entre

la entrada y el vector de prueba se incrementa la salida de la función disminuirá. En el entrenamiento cada neurona de la primera capa, representará a cada una de las muestras de entrenamiento con cierta tolerancia, de acuerdo al ancho de la función gaussiana, de tal manera que el número de neuronas en la primera capa, es igual al número de muestras que se utilizaron en el entrenamiento, y el número de neuronas de la capa de salida, es igual al número de clases que se quieren clasificar.

Una red neural difusa, cuenta con las propiedades básicas y arquitectura de una red neural artificial, en ellas simplemente se fusifican algunos de sus elementos (Chin y Lee, 1995). Algunas de las maneras de fusificar una red neural son:

- Utilizar algún tipo de algoritmo difuso en el entrenamiento de la red
- Fusificar las neuronas de la red
- Fusificar las entradas o salidas (o ambas) en la red neural

En este trabajo se fusificaron las entradas de la red FBR para formar la red neurodifusa.

DISEÑO DEL CLASIFICADOR

Filtros Gabor

Lo primero que se debe de realizar; es el diseño del banco de filtros Gabor utilizando las ecuaciones 1, 2 y 3. Como se manejan cuatro frecuencias y ocho orientaciones el banco es de 32 filtros, en donde cada filtro extrae características de la imagen a diferente frecuencia y orientación. Lo siguiente es convolucionar cada imagen con este banco de filtros utilizando las ecuaciones 4 y 5. Una vez que se obtiene la salida del filtro $O_{f,\theta}$, se calcula su magnitud, $|O_{f,\theta}|$, y se agrupa en una sola matriz la información de las 32 imágenes filtradas. El proceso de agrupar esta información en una matriz ya se especificó anteriormente y se muestra en el diagrama de la Figura 2.

Reducción del Vector de Características

Hasta este paso el tamaño del vector de características de la imagen es de 1x66. Contrario a lo que se piensa, el utilizar varias características puede resultar en dificultades para la capacidad de interpretabilidad del clasificador. Es por eso que se debe de utilizar algún método que disminuya la dimensionalidad del vector de características. En este trabajo se utilizó el Método de Incorporación explicado anteriormente. De acuerdo a este método se definió que las características a tomar en cuenta para el clasificador serían las siguientes:

- Desviación estándar de la imagen original
- Media de la imagen original
- Desviación estándar de las siguientes imágenes del Banco de Filtros Gabor:

Frecuencia 4 orientación 1

Frecuencia 4 orientación 2

Frecuencia 3 orientación 5

Frecuencia 4 orientación 5

Frecuencia 4 orientación 7

Frecuencia 2 orientación 8

Frecuencia 4 orientación 8

Por lo tanto, el vector de características se redujo a una dimensión de 1x9.

Red Neuro Difusa

Lo siguiente es diseñar la red. Como ya se mencionó la red que se utilizará es una FBR Probabilística de 2 capas. El número de neuronas que se tiene en la primera capa, es igual al número de muestras que se tienen para su entrenamiento, en este caso fue de 72 muestras por lo que la primera capa consta de 72 neuronas. Las funciones de activación de la primera capa son funciones gaussianas. El número de neuronas de la última capa es igual al número de clases que se van a clasificar, en este experimento se clasifican 4 tipos de defectos por lo que la última capa cuenta con 4 neuronas, una para cada clase.

La forma en que se fusifican las entradas a la red es la siguiente: en cada una de las nueve características del vector de entrada se diseñan funciones de pertenencia. Estas funciones se

forman de acuerdo a la distribución de las clases en cada característica. Después se evalúa cada vector de entrada en las funciones de pertenencia formadas.

Para entender mejor esto se tiene el siguiente ejemplo: supongamos que x_1 es un vector de tamaño 1×9 de la forma:

$$x_1 = [0.27 \ 0.80 \ 0.21 \ 0.25 \ 0.08 \ 0.07 \ 0.20 \ 0.48 \ 0.19]$$

Para fuzificar el primer valor de x_1 éste se evalúa en las siguientes funciones de pertenencia:

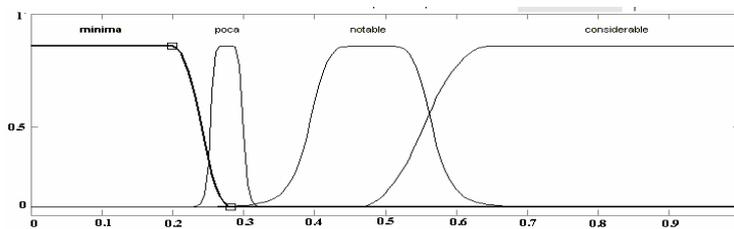


Figura 3. Funciones de pertenencia utilizadas para evaluar el primer elemento del vector de entrada.

Una vez que se evalúa el primer elemento de x_1 se tendría lo siguiente:

Antes de Evaluarse	Después de Evaluarse
$x_{11}=[0.27]$	$x_1=[0 \ 0.3 \ 0 \ 0 \ \dots]$

Esto se realiza en cada uno de los nueve componentes del vector. El número de funciones de pertenencia que se utilizan para evaluar cada elemento del vector de entrada son: 4, 4, 2, 2, 1, 2, 1, 1 y 1 con lo que ahora el tamaño del vector es de 1×18 . Este vector es la entrada a la red FBR Probabilística.

Se cuenta con 140 muestras para clasificar, de las cuales 72 se utilizan para el diseño de la red y las otras 68 para entrenamiento.

RESULTADOS Y DISCUSIÓN

El Cuadro 1 muestra la matriz de confusión de las 72 muestras que se utilizaron para el diseño de la red FBR. La primera columna indica el defecto que se está analizando. La primera fila señala hacia donde fue clasificado el defecto, el número de muestras que se utilizaron y los errores que se obtuvieron en cada clase.

Cuadro 1. Resultados utilizando las 72 muestras para diseño de la red neurodifusa.

	SO	EN	ED	LE	muestras	Error
SO	20	0	0	0	20	0
EN	0	10	0	0	10	0
ED	0	0	22	0	22	0
LE	0	0	0	19	19	0
					Error total	0

Los resultados que se obtienen con las 68 muestras de entrenamiento se muestran en la matriz de confusión del Cuadro 2.

Cuadro 2. Resultado de la clasificación utilizando las 68 muestras de prueba de la red neuro difusa.

	SO	EN	ED	LE	muestras	Error
SO	19	0	0	1	20	1
EN	0	8	0	0	8	0
ED	0	0	20	1	21	1
LE	0	0	0	19	19	0
					Error total	2

Con lo que se tiene que el reconocimiento, que se logra utilizando la red neuro difusa propuesta en este trabajo, es del 97.05% siendo éste un resultado bastante aceptable, tomando en cuenta de que un inspector humano alcanza un reconocimiento entre el 75 y 85% (Jouko *et al.*, 1995).

CONCLUSIONES

El utilizar los beneficios de la lógica difusa y las redes neurales artificiales en un solo sistema, como se hace en una red neurodifusa, se obtienen resultados muy buenos en comparación con aquellos que se obtienen utilizando solamente redes neurales o lógica difusa de manera independiente. Esto se comprueba en este trabajo ya que anteriormente se

han realizado otros dos experimentos, en uno de ellos se utiliza solamente redes neurales para la clasificación de estos mismos defectos y el otro utiliza lógica difusa, pero el sistema que se presenta en este trabajo es el que mejores resultados ha obtenido.

Actualmente se está trabajando en la clasificación de siete defectos en madera utilizando algoritmos de agrupamiento difuso para su clasificación. Esto es con el fin de que a partir de los datos agrupados se formen las funciones de pertenencia de un sistema difuso y éste realizara la clasificación de las siete clases de defectos.

AGRADECIMIENTOS

Los autores agradecen a CONACYT por el financiamiento de este trabajo bajo el convenio PFPN-03-29-05.

LITERATURA CITADA

- Bezdek C. James, L. y Pal K.
1992 **“Fuzzy models for pattern recognition”**. IEEE PRESS. 232 p.
- Casanova J. A.
2002 **“Multiorientación de imágenes mediante un banco de filtros de Gabor-2D”**
Revista Cognitiva. 12 (2): 223-246.
- Chin, T. y G. Lee.
1995 **“Neural Fuzzy Systems: A Neuro Fuzzy Synergism To Intelligent Systems”**.
Editorial Prentice Hall. 354 p.
- Kauppinen, H., O. Silven y T. Piirainen.
1999 **“Self Organizing Map based user interface for visual surface inspection”**. Proc.
11th Scandinavian cofernce on image analysis, Kangerlussuaq, Greenland. pp. 801-
808.
- Jouko, L. y Seppo, S.
1994 **“Word defect recognition: A comparative study”**. Proc. of workshop on Machine
vision in advanced production, Oulu, Finland. 112 p.
1996 **“Self organizing feature extraction in recognition of wood surface defects and
color images”**. International Journal of Pattern Recognition and Artificial
intelligence. 10 (2): 97-118.
- Jouko L. Seppo S. y Markku K.
1995 **“Word surface inspection system based on generic visual features”**.
International Conference on artificial neural networks ICANN'95 Paris. pp.9-13.

Silven, O., M. Niskanen y H. Kauppinen.

2003 **“Electrical engineering”** University of Oulu. Department of electrical engineering.
(En Línea) disponible en <http://www.oulu.fi/research/imag/gsom/>

The Math Works Inc.

2000 **“Neural Network Toolbox User’s Guide”**. Ver.2. 74 p.

Yaochu, J. Werner, Von S. y Bernhard, S.

2000 **“Extracting Interpretable fuzzy rules from RBR neural networks”**. Institut Fur Neuroenformaski. Ruhr-Universitat Bochum, Internal Report, January 34 p.