

Arquitectura Neuronal Convolutiva para la Detección de Defectos en Productos en Continuo

José A. Calderón Martínez^{1,2} y Pascual Campoy Cervera¹

¹ Departamento de Automática, Ingeniería Electrónica
e Informática Industrial
Universidad Politécnica de Madrid
C/ José Gutiérrez Abascal 2, 28006 Madrid, España
campoy@etsii.upm.es
<http://www.disam.upm.es/vision/>

² Instituto Tecnológico de Aguascalientes
Av. López Mateos 1801 Ote., 20256 Aguascalientes, Ags., México
SEP, CONACYT
acaldero@etsii.upm.es

Abstract. Los sistemas de inspección visual automática suelen ser cruciales en los procesos de fabricación de hoy en día. Aquellos sistemas basados en redes neuronales permiten un compromiso entre resolución y velocidad de procesamiento. Este trabajo presenta el desarrollo de una nueva arquitectura neuronal, denominada *Arquitectura Espiral Descendente Convolutiva* (AEDC), para generar de forma automática filtros digitales aplicables en sistemas de inspección mediante visión artificial. Se presentan los resultados experimentales de ésta arquitectura aplicada en la detección de defectos en pasta de papel de imágenes obtenidas en un medio ambiente de fabricación real.

Palabras clave: Redes neuronales convolutivas, filtros digitales, visión artificial, inspección automática.

1 Introducción

La demanda de los sistemas de inspección automática mediante visión artificial en las industrias de fabricación se incrementa día con día. Debido a sus características de velocidad, flexibilidad y confiabilidad se convierten en uno de los sistemas de inspección más altamente competitivos. Reducen costos de inspección, de producción fuera de calidad y pueden llegar a inspeccionar hasta el 100% de productos fabricados incrementando con ello la confianza de los sistemas de producción.

Varios autores han trabajado en detección de defectos en diferentes tipos de procesos. Conners [1] propuso métodos de análisis de texturas para detectar defectos en laminas de madera automáticamente. Dewaele et al. [2] uso métodos de procesamiento de señales para detectar puntos y líneas de defecto en imágenes de texturas. Lee et al. [3] recientemente ha usado redes neuronales para clasificar defectos mediante características de energía y entropía de imágenes de piezas

de acero. Stojanovic et al. [4] propone una mezcla de técnicas de inspección basada en procesamiento de imágenes binarias, análisis estadístico y clasificación mediante redes neuronales, en un sistema de inspección de productos textiles. Campoy et al. [5] recientemente ha propuesto la aplicación de filtros digitales generados mediante redes neuronales en la inspección de pasta de papel.

2 Reconocimiento de patrones

La figura 1 ilustra como se realiza un *clásico* reconocimiento de patrones. Ha de mencionarse que la etapa de *segmentación* no se realiza en todas las aplicaciones (ejm. inspección de acabado de superficies), por lo que algunos autores la contemplan como parte de la etapa de *preprocesamiento*.

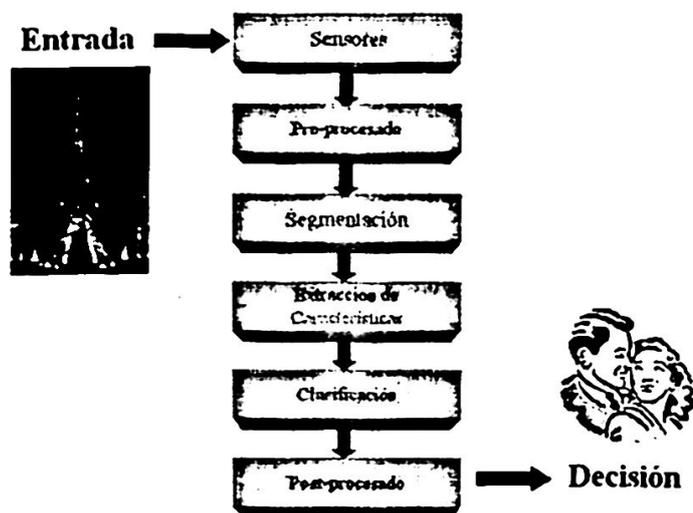


Fig. 1. Sistema de Reconocimiento de Patrones

Un problema de reconocimiento bien definido y suficientemente restringido, conducirá a una representación de patrones compacta y a una estrategia de toma de decisiones simple. Los cuatro enfoques mejor conocidos en el reconocimiento de patrones[6], y no necesariamente independientes, son: 1) template matching (comparación con plantillas), 2) clasificación estadística, 3) comparación estructural o sintáctico, y 4) redes neuronales.

3 Redes Convolucionales

El neocognitron introducido por Fukushima[7] puede ser considerado como la primera implementación de una red convolucional.

Las redes neuronales convolucionales (Convolutional Neural Networks) proveen un método eficiente para restringir la complejidad de redes neuronales unidireccionales (feedforward) mediante la compartición de pesos (weight sharing) y la restricción a conexiones locales. Esta topología ha sido aplicada en particular a clasificación de imágenes cuando se tiene que evitar pre-procesamiento sofisticado y clasificar directamente imágenes brutas o no procesadas.

Existen varias posibilidades para diseñar una arquitectura de red neuronal convolucional (CNN), mediante la combinación de diferentes tipos de neuronas y reglas de aprendizaje. En la figura 2 se ilustra una arquitectura básica de una red neuronal convolucional, en ella se muestran tres capas, una imagen de entrada, tres grupos de imágenes en la capa oculta, y una salida. El número de capas y el número de grupos en cada capa depende de la aplicación.

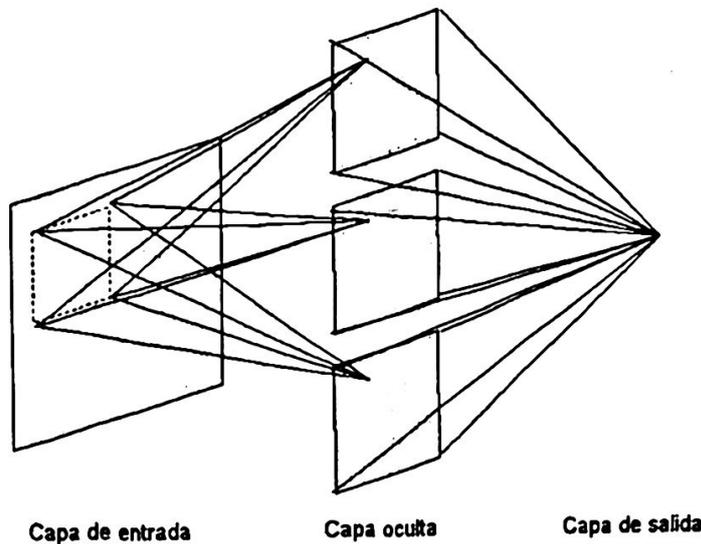


Fig. 2. Arquitectura básica de una CNN

Las redes neuronales convolucionales combinan tres ideas arquitecturales para asegurar algún grado de invarianza en desplazamiento, escala y distorsión: *campos receptivos locales*, *pesos compartidos* (o replicar pesos), y algunas veces *sub-muestreo* espacial o temporal [8, 9]. El uso de pesos compartidos también reduce el número de parámetros en el sistema ayudando a la generalización.

El proceso de aprendizaje de una red convolucional está basado en el algoritmo de retro-propagación, que actualiza los pesos w de las neuronas

$$w(t + 1) = w(t) + \eta\delta(t)x(t) \tag{1}$$

donde η es la tasa de aprendizaje, $x(t)$ es la entrada a la neurona, y $\delta(t)$ es un término de error para la neurona.

Las principales aplicaciones que se han hecho de las redes neuronales convolucionales son el las de LeCun[10] en reconocimiento de caracteres (impresos y manualmente escritos), de rostros por Lawrence[11, 12], y en el análisis de imágenes médicas por Sahiner et al [13].

4 Arquitectura Neuronal Desarrollada

En este apartado se presenta el sistema que se ha desarrollado para llevar a cabo la inspección de pasta de papel. Primeramente se analiza la fase de obtención de los filtros digitales mediante redes neuronales y posteriormente la fase de detección y clasificación de los diferentes tipos de defectos.

4.1 Generación automática de filtros digitales

La fase de obtención de los filtros está compuesta por varias etapas ilustradas en el diagrama de bloques de la figura 3 y que a continuación se describen:

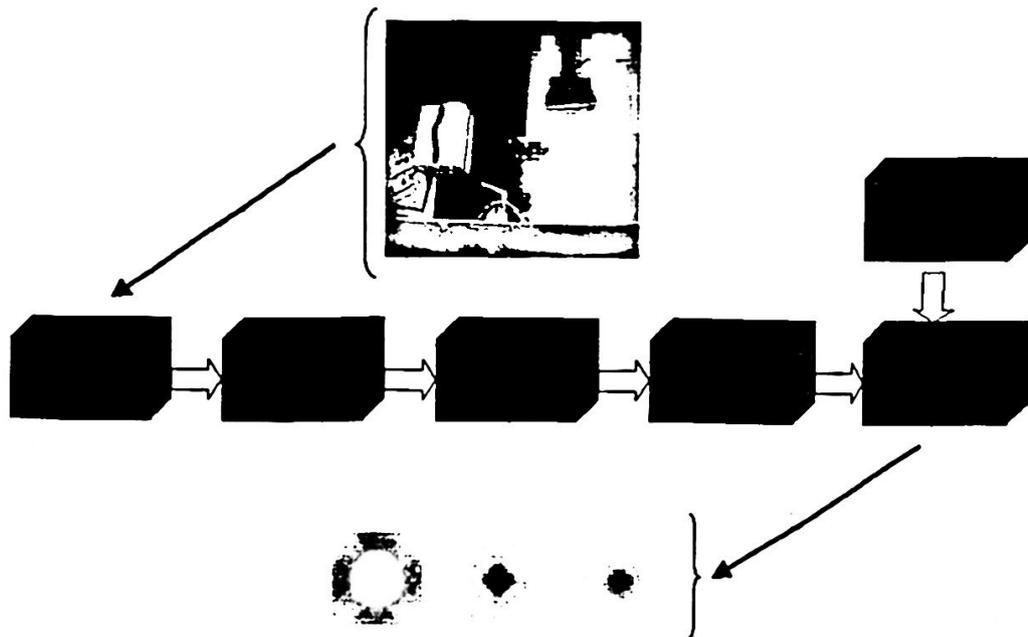


Fig. 3. Actividades en la generación de los filtros digitales.

4.2 Adquisición de imágenes para entrenamiento

Las imágenes se captan en la línea de producción con una cámara TDI de 2048 pixels de resolución horizontal, 96 líneas de acumulación lumínica y 44 Klíneas/s

de velocidad máxima de sincronización, con una óptica de 35 mm f/1:3, y utilizando iluminación a contraluz por fibra óptica con potencia lumínica de 150 W. La resolución de las imágenes es de 15 pixels/mm, obteniendo un área de 3x3 pixels para los defectos de 0.04 mm².

4.3 Clasificación supervisada

Una vez que se han obtenido las imágenes, estas son analizadas por el experto humano que anteriormente realizaba la tarea de inspección, y él (o ella) clasifica los defectos en los diferentes tipos basándose en las normas establecidas y de acuerdo con su experiencia. Los once tipos de defecto a identificar se muestran en la tabla 1.

Table 1. Tipos de defecto

Tipo	Tamaño, mm ²
E	0.08
D	0.20
C	0.45
B	0.80
A1 ... A7	1.0 ... 5.0

4.4 Selección de imágenes

Esta etapa consiste en seleccionar las imágenes más representativas de los diferentes tipos de defectos, así como de imágenes sin defecto.

4.5 Normalización de imágenes

Para minimizar las diferencias entre los niveles de gris de las imágenes obtenidas, estas son normalizadas mediante el ajuste de la distribución de los niveles de gris a una distribución Gaussiana con media igual a 0 y con una desviación de 1.

$$N' = \frac{N - M}{\sigma} \quad (2)$$

4.6 Generación de filtros para cada tipo de defecto

La *Arquitectura Espiral Descendente Convolutiva* (AEDC) mostrada en la figura 4 es la que se ha diseñado y utilizado para generar los filtros digitales que se aplican durante la inspección en línea.

La red neuronal se entrena fuera de línea utilizando muestras con el tipo de defecto para el cual se va a obtener el filtro, así como muestras sin defecto.

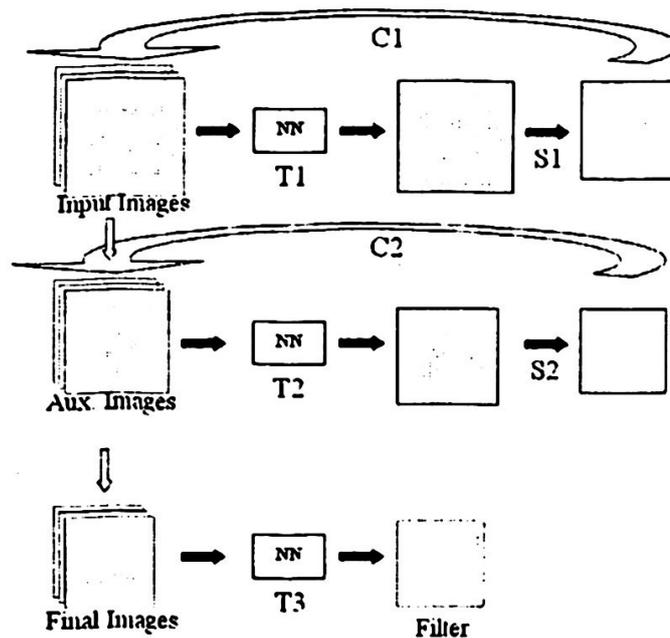


Fig. 4. Arquitectura Espiral Descendente Convolutiva (AEDC).

Como puede observarse en la figura 4 el sistema es alimentado con imágenes de 30x30 pixels, con y sin defecto, con las que se entrena (T1) a una red neuronal mediante retropropagación la cual genera los coeficientes con los que se obtiene un filtro de dimensiones similares, posteriormente se realiza un sub-muestreo (S1) eliminando los píxeles más alejados del centro, obteniendo una imagen de 28x28 pixels las cuales son utilizadas para efectuar una convolución (C1) a las imágenes originales con el objeto de obtener unas imágenes auxiliares mejor centradas que las primeras, para ser utilizadas en la siguiente etapa de entrenamiento. El proceso se repite varias veces en forma de espiral descendente hasta obtener el filtro de tamaño reducido y adecuado, siendo el límite el tamaño del defecto para el cual se está diseñando el filtro.

4.7 Generación de imágenes sintéticas

Este es un módulo auxiliar en el que se aplica un algoritmo para generar imágenes sintéticas utilizando las imágenes originales. La utilidad es que de esta forma se cuenta con un mayor número de imágenes para realizar el entrenamiento de la red neuronal. Se obtienen siete imágenes sintéticas por cada imagen original. Las potenciales aplicaciones de este algoritmo son para los casos en los que se cuenta con pocas imágenes para el entrenamiento, y/o en donde la obtención de muestras es costosa o imposible. En la figura 5 se muestra un ejemplo de imágenes sintéticas generadas por el sistema.

Con esta generación de imágenes sintéticas se garantiza la isotropía de los filtros digitales que se obtienen tras el proceso de aprendizaje. Esta isotropía es

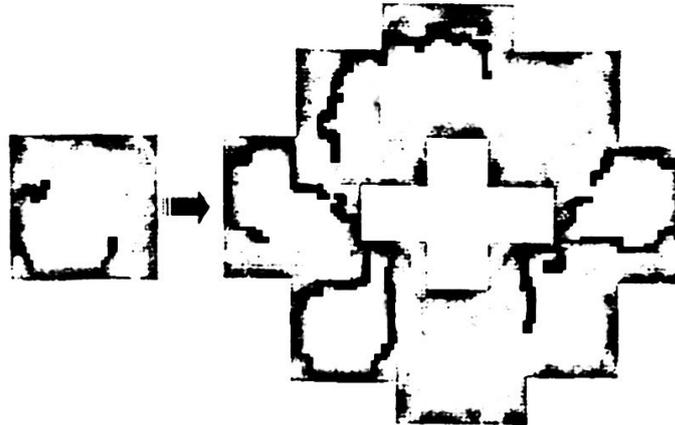


Fig. 5. Ejemplo de imágenes sintéticas.

un conocimiento a priori del problema y su introducción mediante la generación de imágenes sintéticas da lugar a unos resultados similares al mencionado método de las ligaduras de los pesos de la red neuronal.

5 Detección e identificación de defectos

La figura 7 muestra como se lleva a cabo la inspección de las imágenes de pasta de papel.

5.1 Adquisición de imágenes

Se adquieren imágenes de 682x2024 pixels de la pasta de papel, con la cámara TDI mencionada anteriormente, en la línea de producción a la velocidad con que se esté efectuando el proceso.

5.2 Detección de regiones de interés

A las imágenes captadas se les aplica el algoritmo de detección de defectos basado en etiquetado de regiones de interés, siendo estas regiones las posibles zonas que contengan los defectos.

El algoritmo incluye una binarización y una escaneo de la imagen completa, obteniendo como salida una imagen auxiliar con las regiones de interés perfectamente delimitadas.

5.3 Obtención de características

En ésta etapa se obtienen características de las regiones detectadas en cada una de las imágenes analizadas, como *área* de la región detectada, *reflexiones en x,y*, y *centroide*, que son utilizadas para la extracción o aislamiento de la zona de defecto (imagen de 30x30 pixels) para su análisis y clasificación.

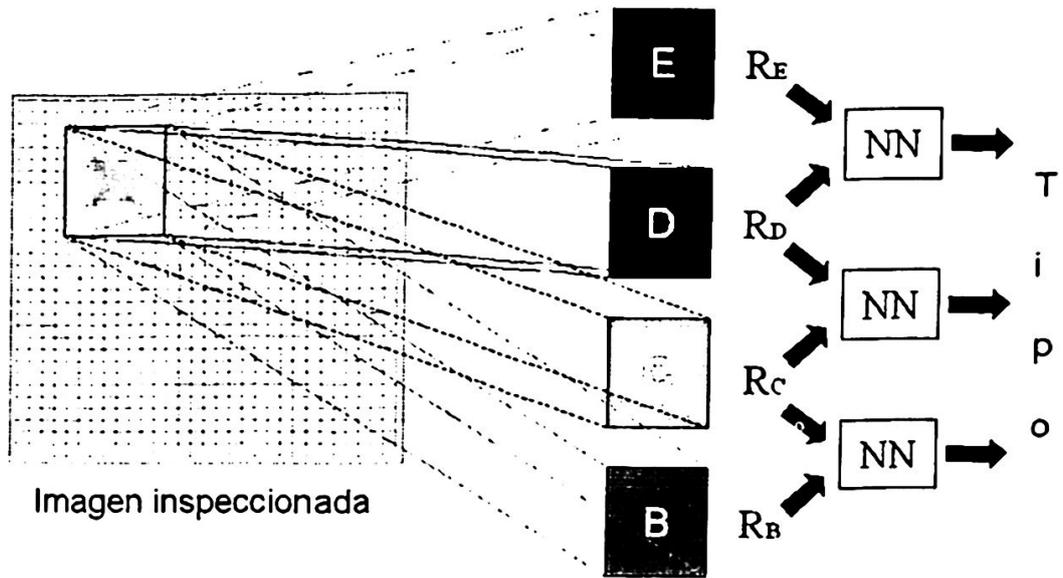


Fig. 6. Arquitectura utilizada para realizar la inspección.

5.4 Identificación de tipos de defecto

Los filtros obtenidos en la primera fase del sistema desarrollado se aplican de acuerdo con la técnica de redes convolucionales, como se muestra en la figura 7, obteniendo como respuesta a los filtros la identificación del tipo de defecto en cuestión. Los casos en los que el defecto analizado responda a la aplicación de dos filtros "vecinos" de forma similar, su tipo se define mediante la utilización de una red neuronal posteriormente a los filtros.

6 Resultados experimentales

El tamaño del filtro es importante por cuestiones de tiempo de ejecución durante la fase de identificación de los defectos, así como por el área de la imagen cubierta durante la convolución. Al generar los filtros digitales mediante la *Arquitectura Espiral Descendente Convolutional* (AEDC) se observa un rápido descenso en su tamaño, a 87% en el primer submuestreo, 75% en el segundo, 64% en el tercero, y así sucesivamente. La figura 7 ilustra los diferentes tamaños de filtros que se generan para la identificación de defectos de tipo E, D, y C.

En la tabla 2 puede observarse una mayor capacidad de muestro del método automático respecto al método manual, tomando en cuenta la Norma ENCE 404 [14] que establece que debe inspeccionarse un área de $500 \times 500 \text{ mm}^2$ de una muestra de una hoja de pasta de papel de $800 \times 800 \text{ mm}^2$, tomada de uno de cada 7 lotes, de 8 balas, de 410 hojas.

Los resultados obtenidos en una de las pruebas en la etapa de identificación de diferentes tipos de defectos se muestran en la tabla 3.

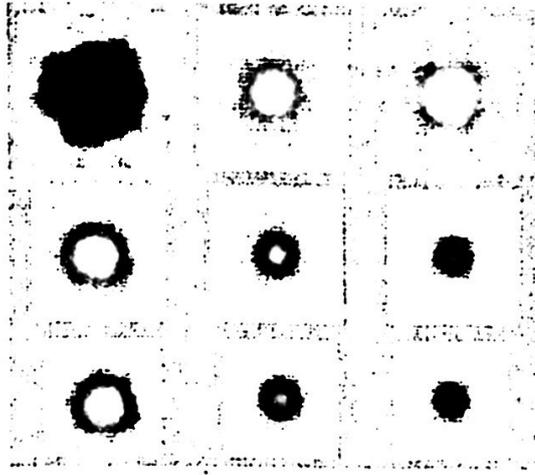


Fig. 7. Filtros generados para identificar defectos tipo C, D y E.

Table 2. Comparación de métodos

Método	Área (mm^2)	% Inspeccionado	Tiempo (seg)
Manual	500x500	0.0017%	n.a.
Automático	136.5x136.5	0.118%	2.5

Table 3. Identificación de defectos

Tipo	N Muestras	% Identificados
E	300	86%
D	250	92%
C	300	93%

7 Conclusiones

Se ha presentado una arquitectura que puede ser aplicable en procesos de inspección automática en diversos entornos de fabricación, la cual hace uso de redes neuronales convolucionales para generar filtros digitales. Los filtros generados mediante la arquitectura AEDC han sido probados con imágenes de defectos obtenidas en una fábrica de pasta de papel a velocidad normal de producción, con resultados satisfactorios.

References

1. Connors, R. *Identifying and locating surface defects in wood*, IEEE Transactions PAMI 5 (6) (1983), pp 573-583.
2. Dewaele, P., Van Gool, L., and Oosterlinck, A. *Texture Inspection with self-adaptive convolution filters*, Proceedings of the Ninth International Conference on Pattern Recognition, 1, 1988, pp 14-17.
3. Lee, C.S., Choi, C.H., Choi, J.Y., Kim, Y.K. and Choi, S.H., *Feature extraction algorithm based on adaptive wavelet packet for surface defect classification*, IEEE International Conference on Image Processing, 1996, pp. 673-675.
4. Stojanovic, R., Mitropulos, P., Koulamas, C., Karayiannis, Y., Koubias, S., and Papadopoulos, G., *Real-Time Vision-Based System for Textile Fabric Inspection*, Real-Time Imaging 7, Academic Press, pp. 507-518, 2001.
5. Campoy-Cervera, P., Munoz-Garcia, D.F., Pena, D., and Calderon-Martinez, J.A., *Automatic Generation of Digital Filters by NN Based Learning: An application on Paper Pulp Inspection*, IWANN'2001 6th International Work-Conference on Artificial and Natural Neural Networks, June 2001, Proceedings, Part II, pp. 235-245
6. Jain, A.K., Duin, R.P.W., and Mao, J., *Statistical Pattern Recognition: A Review*, IEEE Transactions on Pattern Analysis and Machine Intelligence, January 2000, vol. 22, n 1, pp. 4-37.
7. Fukushima, K., *Neocognitron: A self organizing neural-network model for a mechanism of pattern recognition unaffected by shift in position*, Biological Cybernetics, vol. 36, pp. 193-202, 1980.
8. LeCun, Y., and Bengio, Y., *Convolutional networks for images, speech and time-series*, In M. A. Arbib, editor, The Handbook of Brain Theory and Neural Networks. MIT Press, 1995.
9. Li, B-Q., and Li, B., *Building Pattern Classifiers Using Convolutional Neural Networks*, IEEE International Joint Conference on Neural Networks, 1999. Vol. 5, pp. 3081-3085.
10. LeCun, Y., Bottou L., Bengio Y., and Haffner P., *Gradient-Based learning applied to document recognition*, Proceedings of the IEEE, Nov. 1998, pp. 1-45.
11. Lawrence, S., Lee, Giles C., and Chung Tsoi, A., *Convolutional neural networks for face recognition*, 1996. Proc. CVPR '96 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp. 217-222, 1996.
12. Lawrence, S., Lee, Giles C., Chung Tsoi, A., and Back, A.D., *Face recognition: A convolutional neural-network approach*, IEEE Transactions on Neural Networks, vol. 8, n 1, pages 98-113, 1997.

13. Sahiner, B., Chan, H.P., Petrick, N., Wei, D., Helvie, M.A., Adler, D.D., and Good-sitt, M.M., *Classification of Mass and Normal Breast Tissue: A Convolution Neural Network Classifier with Spatial Domain and Texture Images*, IEEE Transactions on Medical Imaging, Vol. 5, pp. 598-610, Oct. 1996.
14. Normas ENCE: *Technical Specification of the Product*, Empresa Nacional de Celulosas, S.A., 1994.