

Sistema de Ayuda para la Detección de Cáncer de Mama

Gustavo A. Ferrero

Centro de Ingeniería de Software e Ingeniería del Conocimiento. Escuela de Postgrado. Instituto Tecnológico de Buenos Aires
gaferrero@yahoo.com

Resumen: Este artículo tiene como objetivo presentar una aplicación experimental para la detección de posibles áreas con lesiones en la mama mediante el uso de redes neuronales en imágenes médicas. Dicha aplicación brinda un ambiente de investigación para la generación de diferentes topologías con el fin de mejorar redes en uso y obtener nuevas arquitecturas que permitan mejorar la detección.

Palabras clave: red neuronal, imágenes médicas, clasificación, mamografías.

Abstract: The goal of this paper is to show an experimental software application for detection of suspicion areas with breast lesions, using neural net in digital images, like mammographics. This application brings an environment to investigate alternative neural nets, it

Key words: Data Mining, Classifiers, Cluster, Data Mining Algorithms.

1. Introducción

Se ha determinado que el cáncer de mamas es la segunda causa de muerte de mujeres con cáncer y la más común de todas, en la República Argentina no existen estadísticas oficiales, pero se estima que 22 de cada 100.000 mujeres poseen dicha enfermedad, similar al observable en otros países occidentales [Abalo, 2003].

La mamografía es el mejor método de diagnóstico por imágenes que se dispone en la actualidad para la detección de lesiones mamarias mínimas, fundamentalmente pequeños carcinomas que se manifiestan solamente por microcalcificaciones o tumores menores a 1 cm. de diámetro, no palpables durante el examen médico [Antonie *et al*, 2001].

Actualmente se están aunando esfuerzos para poder detectar a tiempo anomalías en los tejidos, debido a que no existen métodos para poder prevenir el cáncer de mama [Abalo, 2003]. La detección temprana ha demostrado ser un arma esencial en la detección del cáncer ya que permite extender el período de vida de los pacientes.

Los médicos informantes de los estudios deben tener capacitación diagnóstica basado en mamografía y realizar un número determinado de informes anuales. La doble lectura de los informes aumenta la sensibilidad de la detección de lesiones mínimas en un 7% pero a un alto costo. Con estos informes el médico hará una interpretación y decidirá de acuerdo a su criterio los pasos a seguir para el adecuado diagnóstico y tratamiento del paciente [Abalo, 2003].

Es por ello que físicos, ingenieros y médicos están en la búsqueda de nuevas herramientas para combatir el cáncer y que permitan al médico obtener una segunda opinión [Gokhale *et al*, 2003] [Simoff *et al*, 2002].

Con la autorización de uso de nuevos mamógrafos digitales por el Colegio Americano de Radiografía se ha comenzado a almacenar la fotos digitales en bases de datos conjuntamente con la información del paciente para luego poder ser procesadas a través de diferentes métodos [Selman, 2000].

Dichos métodos constan de la clasificación y detección de anomalías en dichas imágenes médicas para lo cual se utilizan métodos

estadísticos, teoría de fractales y diversas técnicas de estudio de las características de las imágenes digitales conjuntamente con algoritmos presentado en la literatura tales como modelos de Markov, algoritmos de lógica difusa y redes neuronales, obteniendo muy buenos resultados [Selman, 2000].

Diferentes investigaciones sobre minería de datos aplicadas al procesamiento de imágenes médicas han obtenidos muy buenos resultados a través de la aplicación de redes neuronales para tareas de clasificación y agrupamiento [Antonie *et al*, 2001].

Diferentes sistemas han sido desarrollados para el trabajo con radiografías específicamente mamografías, el objetivo de estos sistemas es enfocarse en regiones sospechosas. Dichos sistemas trabajan en tres pasos: digitalización de la mamografía, preprocesamiento de la imagen, clasificación mediante redes neuronales y descubrimiento de áreas de interés [A. Lauria, *et al*, 2001].

CALMA es un proyecto entre diversas universidades de Italia y el Instituto de Física Nuclear de dicho país; dicho proyecto se basa en un buscador de microcalcificaciones basado en redes neuronales supervisadas y no supervisadas, y un buscador de lesiones basados en un aproximamiento híbrido [A. Lauria, *et al*, 2001].

Los resultados obtenidos por dicho sistema son prometedores de acuerdo con lo reportado, son comparables con similares sistemas comerciales [A. Lauria, *et al*, 2001].

Estos resultados, incentivaron a la creación de una aplicación de código abierto que permitiera clasificar mamografías y generar un espacio de investigación que sirva para la búsqueda de mejores métodos de clasificación mediante el entrenamiento de redes neuronales de diferentes dimensiones y topologías.

2. El método propuesto

Los radiólogos no diagnostican cáncer, básicamente ellos detectan regiones sospechosas y envían un informe con el fin de que se realicen un trabajo adicional sobre dicha región [Alan H. Baydush, *et al*, 2001].

Teniendo en mente el trabajo de los médicos especialistas en imágenes médicas, el sistema trabaja de la siguiente forma: i. toma de la imagen médica, ii. almacenamiento de la misma en la base de datos, iii. lanzamiento del procesamiento, iv. generación del informe, v. validación del informe.

Los primeros pasos y los últimos generan información que permite establecer un ámbito de trabajo que le otorga a los usuarios del sistema la posibilidad de generar nuevas topologías de la red con el fin de poder revalidar los resultados obtenidos.

2.1 Procesamiento de la mamografía

En la figura 1 se muestra el conjunto de etapas que se han dispuesto para el procesamiento de la imagen correspondiente a la mamografía.

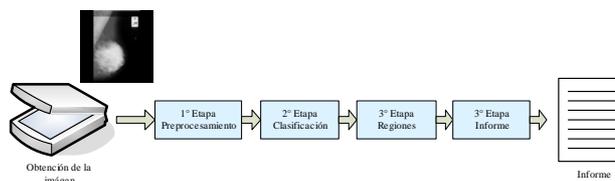


Figura 1. Pasos de procesamiento.

1° Etapa: correspondiente al preprocesamiento de la imagen, dicha etapa comienza con la obtención de la imagen, y entrega a la etapa siguiente una imagen que contiene únicamente el área de interés.

2° Etapa: corresponde a la clasificación de la imagen para determinar si la misma posee o no lesiones malignas que deban ser estudiadas en profundidad por especialistas.

3° Etapa: si el clasificador determina que la imagen contiene lesiones malignas se buscan dichas regiones sospechosas.

4° Etapa: generación de un informe sobre el procesamiento de la mamografía.

2.2 Preprocesamiento de la mamografía

La primera etapa contiene pasos que en conjunto tienen como objetivo eliminar toda aquella información que no es necesaria para la clasificación.

Paso 1. Utilizar filtro de mediana.

Paso 2. Cortar márgenes.

Paso 3. Eliminar regiones aisladas.

Paso 4. Ecuilibrar.

Los filtros de orden están basados en un tratamiento específico de la estadística de la imagen llamado estadísticas de orden. Estos filtros operan en una vecindad de un determinado píxel, denominada ventana y reemplazan el valor del píxel central. La estadística de orden es una técnica que organiza todos los píxeles de la ventana en orden secuencial, basándose en el valor del nivel de gris de los mismos [G. Pajares y J. de la Cruz, 2002].

La mediana M de un conjunto de valores es tal que la mitad de los valores del conjunto son menores que M y la mitad de los valores son mayores que M . Con el objeto de realizar un filtrado de la mediana en el entorno de vecindad, ordenamos las intensidades de la vecindad como se ha explicado anteriormente, determinamos la mediana y asignamos esta última a la intensidad del píxel [G. Pajares y J. de la Cruz, 2002].

La principal función del filtrado de la mediana es hacer que los puntos con intensidades muy distintas se hagan muy parecidos a sus vecinos, eliminando así los picos de

intensidad que aparezcan aislados en el área de la máscara de filtro [G. Pajares y J. de la Cruz, 2002].

El filtro de mediana es un filtro no lineal, usado para eliminar el ruido de alta frecuencia sin eliminar las características significativas de la imagen, se usa una máscara de 3x3, la cual es centrada en cada píxel de la imagen reemplazando cada píxel central por la mediana de los nueve píxeles que cubren la máscara, el tamaño de la ventana permite que se mantengan las características propias de la imagen y a su vez se eliminan las altas frecuencias [S. Díaz].

Luego se realiza el corte automático, dicha acción tiene como objetivo enfocar el proceso únicamente en la región correspondiente a la mama, con lo cual se reduce los posibles errores de clasificaciones por áreas que no son de interés.

La segmentación de una imagen es un paso importante en el procesamiento en varias aplicaciones de imágenes. Una multitud de técnicas y algoritmos caen en general dentro de esta categoría general como punto de partida para la detección de bordes, etiquetado de regiones y transformaciones. Todas estas técnicas, etiquetados de regiones y análisis son relativamente simples algoritmos que han sido usados por muchos años para aislar, medir e identificar potenciales regiones [M. Jankowski, J. Kuska, 2004].

Para el etiquetado de regiones se utiliza una implementación del tipo pila, ya que es uno de los más rápidos y simples de implementar.

Luego del etiquetado se pasa a la eliminación de aquellas áreas que no son parte del objeto de estudio, se conoce que la superficie ocupada por la mama es superior al 80%, por lo tanto áreas aisladas con superficies inferiores al 1% no pertenece a la mama y son eliminadas mediante la creación de máscaras obtenidas de los píxeles vecinos.

Por último se realiza la equalización uniforme, la cual se puede decir que ayudará a realzar el contraste de la imagen.

$$F(g) = [g_{\max} - g_{\min}] P_p(g) + g_{\min}$$

Donde g_{\max} , y g_{\min} se corresponden con los valores de intensidad máximo y mínimo en el rango de niveles de gris de la imagen.

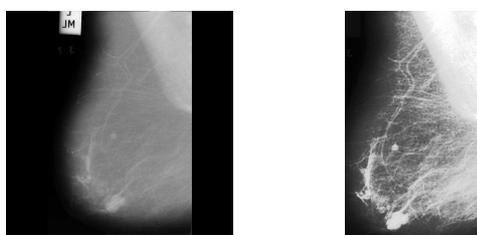


Figura 2. Preprocesamiento automático.

En la figura 2 se muestra resultado de aplicar el preprocesamiento en una imagen.

2.3 Clasificación

Las redes neuronales son modelos que intentan reproducir el comportamiento del cerebro. Como tal modelo, realiza una simplificación, averiguando cuáles son los elementos relevantes del sistema. Una elección adecuada de sus características, más una estructura conveniente, es el procedimiento convencional utilizado para construir redes capaces de realizar una determinada tarea [P. Britos, *et al.*, 2005].

Las redes neuronales artificiales ofrecen un paradigma atractivo para el diseño y el análisis de sistemas adaptativos inteligentes para un amplio rango de aplicaciones en inteligencia artificial [A. Fiszlewey y R. Martínez, 2002].

Las redes neuronales están compuestas de unidades denominadas neuronas, dichas neuronas tienen tres partes: una dentrina que recolecta las entradas desde otras neuronas o de un estímulo externo, un soma o cuerpo que realiza un procesamiento no lineal y finalmente un axón que transmite un señal de salida a otras neuronas. La conexión entre dos neuronas se denomina synapse [W. Gestner, NA].

Las neuronas se agrupan en capas, estas capas conectadas una a otras componen una red neuronal, así cada red neuronal está compuesta de un número n de capas (figura 3). Dependiendo de cómo estos componentes (capas) son conectadas, diferentes arquitecturas pueden ser creadas (feed forward NN, recurrent NN, etc.).

La topología o arquitectura de la red neuronal consiste en el tipo, organización y disposición de las neuronas en la red, formando capas o agrupaciones de neuronas. La topología de una red neuronal de multicapas depende del número de variables en la capa de entrada, del número de capas ocultas de neuronas, del número de neuronas por cada capa oculta y del número de variables de salida en la última capa. Todos esos factores son importantes a la hora de determinar la configuración de una red [M. Birnbach, I. Hegouaburu, 2002].

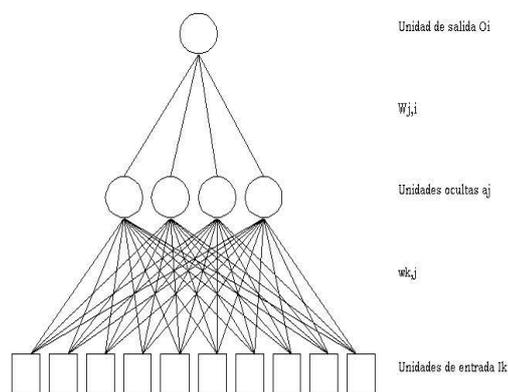


Figura 3. Red neuronal.

Así se puede definir las estructuras de redes neuronales como colecciones de procesadores paralelos conectados entre sí en la forma de grafo dirigido, organizado de tal modo que la estructura de la red sea adecuada para el

problema que se esté considerando [M. Birnbach, I. Hegouaburu, 2002].

Las conexiones que unen a las neuronas que forman una red neuronal tienen asociado un peso, que es el que hace que la red adquiera conocimiento [P. Britos, *et al*, 2005].

El mecanismo más común de entrenamiento usado para redes multicapas es el algoritmo de Backpropagation. Los pesos son actualizados por las capas ocultas que adoptan el mecanismo de retropropagación que corrige la señal desde la capa oculta. Ha sido mostrado que las redes multicapas, dan flexibilidad en las dimensiones de las redes neuronales, ofreciendo una aproximación de capacidades asintóticas. Está demostrado que un perceptrón de dos capas (una oculta) es adecuado como una aproximación universal para funciones no lineales [S. Kung, *et al*, 1998].

Un perceptrón multicapa tiene la siguiente estructura:

- Señal de función: es la señal que se propaga de la entrada hacia la salida.
- Señal de error: son las generadas por las neuronas de salidas y que se retropropagarán en forma de ajuste de las conexiones sinápticas hacia la entrada con el fin de ajustar la salida obtenida lo más fielmente a la salida deseada.

Así cada neurona de salida y de la capa oculta está capacitada para realizar dos tipos de cálculos de acuerdo a la señal que recibe, si es una señal de función hará un cálculo hacia adelante (*forward pass*), si el cálculo es hacia atrás será (*backward pass*). Las neuronas de la capa oculta usan como regla de propagación la suma ponderada de las entradas con pesos sinápticos w_{ji} y sobre esa suma ponderada se aplica una función de transferencia de tipo sigmoide, que es acotada en la respuesta.

Básicamente el algoritmo de retropropagación se basa en la minimización de un error por medio de una técnica clásica de optimización llamada *descenso de gradiente*. Es decir, la idea principal consiste calcular los pesos adecuados de las capas a partir de los errores de las unidades de salida, el secreto consiste en evaluar las consecuencias de un error y dividirlos entre todos los pesos contribuyentes.

El aprendizaje de la red neuronal se puede especificar como una función de aproximación donde el objetivo es aprender una función desconocida $f: \mathbb{R}^N \rightarrow \mathbb{R}$ (o una buena aproximación de la misma) desde un conjunto de pares de entrada/salida $S = \{(x^N, y) \mid x^N \in \mathbb{R}^N, y \in \mathbb{R}\}$ [R. Parekh, *et al*, 2000].

La clasificación de patrones es un caso especial de función de aproximación, donde la función de salida y es restringida por una de M ($M \geq 2$) valores discretos (o clases). Una red neuronal para resolver problemas típicos de clasificación tiene N neuronas de entrada, y M

neuronas de salida. La K -ésima neurona de salida ($1 \leq K \leq M$) es entrenada con salida *uno* (mientras todas las otras neuronas de salida son entrenadas con valor *cero*) para patrones pertenecientes a la K -ésima clase. Una única neurona es suficiente para los problemas que involucran dos categorías de clasificación [R. Parekh, *et al*, 2000].

El perceptrón multicapa permite realizar clasificaciones sobre problemas no lineales, mientras más capas ocultas posea la red neuronal el problema será más simple de separar (figura 4).

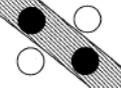
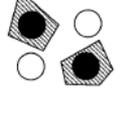
Estructura	XOR	Clases
		
		
		

Figura 4. Interpretación geométrica de los roles de las capas ocultas.

2.4 Características de la imagen

La imagen radiográfica se forma mediante la absorción que experimentan los tejidos al paso de la radiación Roentgen. Según la cantidad de radiación absorbida, un objeto (tejido) puede resultar, radiopaco (RO), radiolucido (RL) o radiotransparente (RT).

- Cuando el objeto haya absorbido una ínfima cantidad de rayos x, llegan a la película casi la totalidad de los rayos, el tono será oscuro y se tratará de un cuerpo radiotransparente (cavidades aéreas).
- Cuando el objeto absorbe una mediana cantidad de rayos y el tono es gris el cuerpo será radiolucido (tejido orgánico no calcificado).
- Cuando el cuerpo absorba la totalidad o gran cantidad de rayos X y el tono sea claro o blanco el cuerpo será radio opaco (tejido inorgánico, tejido calcificado).

El grado de tonalidades está en relación y depende del grado de absorción de rayos X por parte del tejido, cuanto más absorbe el tejido menos radiación llega a la película y el cuerpo será radioopaco, cuanto menos absorbe el tejido más radiación llega a la película y por lo tanto el cuerpo será radiolucido.

Teniendo en cuenta esta característica de la imagen de rayos X, se utilizará la misma para obtener información sobre los tejidos mostrados.

La capa de entrada está compuesta por K neuronas de entrada, dicho valor se obtiene en base a: las regiones definidas para la imagen (subdivisiones de la imagen) por la cantidad de operaciones estadísticas aplicadas a dicha región, más una neurona correspondiente a la posición de la mama (derecha o izquierda) y un conjunto de tres neuronas correspondiente al tipo de tejido (denso, denso glandular y glandular).

Las características de cada una de las subregiones son obtenidas en base a información proporcionada por los tejidos que son representados por los píxeles de la imagen. La extracción de la información de las regiones se realiza mediante medios estadísticos:

- Media: que es el valor medio de los datos.
- Sesgo: es el error sistemático que ocurre con mucha frecuencia.
- Curtosis: mide si los valores de la distribución están más o menos concentrados alrededor de los valores medios de la muestra.
- Varianza: mide la distancia existente entre los valores y la media.

La media está definida por la siguiente función:

$$\bar{X} = \frac{\sum x_i}{n}$$

El sesgo se define:

$$\text{sesgo} = \frac{n}{(n-1)(n-2)} \sum \left(\frac{x_i - \bar{X}}{s} \right)^3$$

La función curtosis está definida por la siguiente expresión:

$$k = \frac{n * (n-1)}{(n-1)(n-2)(n-3)} \sum \left(\frac{x_i - \bar{X}}{s} \right)^4 - \frac{3 * (n-1)^2}{(n-2)(n-3)}$$

Por último la función varianza está dado por:

$$s = \frac{\sum (x_i - \bar{X})^2}{(n-1)}$$

El sistema ofrece la posibilidad de generar diferentes topologías de redes multicapas ($N \geq 3$, donde N es la cantidad de capas), está característica le permite al usuario investigar nuevas arquitecturas.

Como se ha mencionado la información de la imagen (regiones) es introducida en la red, por ejemplo; para una imagen dividida en 16 regiones se tienen 69 ($16 * 4 + 1 + 3 + 1$) neuronas incluyendo el termino independiente;

para la capa de salida se puede tener una sola neurona o dos neuronas.

2.5 Entrenamiento

El aprendizaje supervisado se caracteriza por un entrenamiento controlado por un agente externo (supervisor o maestro) que determina la respuesta que debería generar la red a partir de una entrada determinada. El supervisor comprueba la salida de la red y en el caso de que ésta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida obtenida se aproxime a la deseada [P. Britos, *et at*, 2005].

El método propuesto para el sistema es el aprendizaje por error, el cual consiste en ajustar los pesos de las conexiones en base a la distribución del error cuadrático entre las respuestas deseadas r_q y las correspondientes respuestas actuales O_q .

$$E_q = \frac{1}{2} \sum_{q=1}^{N_q} \left(r_q - O_q \right)^2$$

Los datos de entrenamiento son mamografías obtenidas por la Asociación de Análisis de Imágenes Mamográficas (MIAS), consiste en 322 imágenes de las cuales 55 deberán ser analizadas para obtener más información, con dicha información se procede a entrenar la red neuronal.

Para el entrenamiento de la red neuronal se deben pasar la siguiente información:

- Error de parada: es el error de salida aceptable para el entrenamiento, por debajo de este error el entrenamiento es detenido y se considera que los pesos convergen.
- Cantidad de ciclos: establece la cantidad de ciclos máximos que la red tiene para aprender.
- Momento: se da a cada conexión alguna inercia o momentum, de tal forma que su tendencia a cambiar de dirección con mas pendiente descendente se vea promediada con las "tendencias" de cambio de dirección obtenidas con anterioridad. El parámetro momentum debe estar entre 0 y 1 [M. Birnbach, I. Hegouaburu, 2002].
- Ratio de aprendizaje: es un valor entre 0 y 1 utilizado en la distribución del error (regla delta).

El proceso de entrenamiento se evalúa cada mil ciclos, obteniendo información sobre los últimos diez mil ciclos, realizando una evaluación sobre la media, de tal forma que se pueda determinar la velocidad de convergencia de la red, permitiendo detener el entrenamiento y comenzar con un nuevo conjunto de pesos.

2.6 Ejecución de la red

El sistema permite generar diferentes arquitecturas, por lo que se evalúan diferentes redes, teniendo en cuenta que ciertos factores al momento de definir una nueva arquitectura.

La performance (y el costo) de una red neuronal sobre problemas particulares es críticamente dependiente, entre otras cosas, de la arquitectura de la red y del algoritmo de aprendizaje utilizado [A. Fiszlelew, R. Martinez, 2002].

Las redes demasiado pequeñas son inadecuadas para aprender el problema, por el contrario las redes demasiado grandes tienden a ajustarse a los datos de entrenamiento y en consecuencia el resultado es una pobre generalización [R. Parekh, *et al*, 2000].

Con diferentes cantidades de capas ocultas, los mejores resultados han sido con una configuración de:

- 69 Neuronas de capa de entrada.
- 16 Neuronas en la capa oculta, esto por cada una de las regiones en la que fue dividida la imagen.
- 4 Neuronas en la siguiente capa oculta, por cada una de las operaciones aplicadas a la región.
- 2 Neuronas de salida que contiene.

Y se han realizado dos redes dependiendo de la ubicación de la mama (derecha o izquierda) se utiliza una u otra, ya que los resultados iniciales obtenidos por una única red han sido muy pobres, con esta modalidad también se han reducido los tiempos de entrenamiento, haciendo que la velocidad de convergencia sea más rápida.

La misma red entrenada para ambas direcciones ha logrado clasificar correctamente un 30% de éxito, mientras que la red entrenada para una determinada ubicación lo ha hecho en un 60%, por otro lado la primera ha tardado más de 4 horas en converger, la segunda lo ha hecho en menos de 60 minutos.

4. Conclusiones

Con el trabajo realizado se ha pretendido entregar un ambiente que permite seguir investigando nuevos modelos de redes neuronales que logren obtener mejores resultados en la clasificación de imágenes médicas.

El proyecto es open source permitiendo acceder al código fuente para que otros puedan estudiarlo, mejorarlo, ampliarlo y distribuirlo, con lo cual instituciones de salud puedan acceder a herramientas que permitan mejorar la detección del cáncer de mama.

El proyecto busca mejorar la detección de áreas sospechadas de contener algún tipo de lesión, los resultados obtenidos difieren mucho de las expectativas iniciales, pero los resultados iniciales obtenidos son prometedores, para el futuro quedará la mejora de dicha

aplicación y la posibilidad de introducir nueva información estadística que mejore la lectura de las imágenes.

5. Bibliografía.

Abalo, E. (2003). Información para el público en general. www.samas.org.ar Pagina veinte al 17/08/2003.

Antonie M., Zăiene O., Coman A. (2001). Application of data mining techniques for medical image classification. Proceedings of the Second International Workshop on Multimedia Data Mining.

Baydush A., Cararius D., Lo J., Abbey C., Floyd C. (2001). Computerized classification of suspicious regions in chest radiographs using subregion hotelling observers. American Association of Physicists in Medicine. Vol 28 (12).

Birnbach M., Hegouaburu I. (2001). Redes neuronales con entrenamiento mixto. Revista Instituto Tecnológico Buenos Aires; Número 26. Páginas 105-128. EMEDE S.A.

Britos P., Hossian A., García-Martínez R., Sierra E. (2005). Minería de datos basada en sistemas inteligentes. Capítulo 7 "Redes Neuronales Artificiales"; Nueva Librería, Buenos Aires, Argentina.

Diaz, S. Detección de microcalcificaciones en imágenes de mamografías usando diferencias de filtro gaussianos optimizados.

Egmont-Petersen M., de Ridder D., Handels H. (2002). Imagen processing with neural networks. The Journal of the pattern recognition society. Vol. 35 (10).

Fiszlelew A., García-Martínez R. (2001). Generación automática de redes neuronales con ajuste de parámetros basado en algoritmos genéticos. Revista Instituto Tecnológico Buenos Aires; Número 26. Páginas 76-101. EMEDE S.A.

Gerstner W. Supervised learning for neural networks: A tutorial with Java Exercises.

Jankowski M., Kuska J. (2004). Connected components labeling – algorithms in Mathematica, Java, C++ and C#. IMS2004.

Kung S., Hwang J. (1998). Neural network for intelligent multimedia processing. Proceedings of the IEEE. Vol 86 (6).

Lauria A., Palmiero R., Forni G., Cerello P., Golosio B., Fauci F., Magro R., Raso G, Tangaro S., Indovina P. The CALMA system: an artificial neural

network for detecting masses and microcalcifications in digitalized mammograms.

Pajares G., De la Cruz J. (2002) *Visión por computador*. Ra-Ma. Madrid, España.

Parekh R., Yang J., Honavar V. (2000) Constructive neural-network learning algorithms for pattern classification. *IEEE Transactions on neural networks*. Vol. 11 (2).

Selman, S. (2000). Data Mining of Digital Mammograms Will Aid in War against Cancer. www.gatech.edu Página vigente al 17/08/2003.

Simoff, S., Djeraba, C., y Zaïane, O. Multimedia Data Mining between Promise and Problems. 3rd Edition of the International Workshop on Multimedia Data Mining. Páginas 118-121. SIGKDD Explorations.