

Estimación de la Relación Señal Ruido mediante Redes Neuronales Artificiales en resonadores magnéticos Philip Panorama 0.23 T

Luis Ricardo Mento Rubio

Centro de Altas Tecnologías “Manuela Saenz”

Avenida Carabobo, Esquina Chile, Sector Las 40, Parróquia Ambrosio

RESUMEN

Debido al crecimiento acelerado de los equipos de Resonancia Magnética para el diagnóstico médico (MRT), se hace necesario implementar sistemas rigurosos de Aseguramiento y Control de la Calidad (CAC), ya que del buen funcionamiento de los mismos, depende la buena interpretación de las imágenes (MRI), un diagnóstico médico acertado y la mejor conducta a seguir por los especialistas. En la actualidad las distintas asociaciones dedicadas al CAC de estos equipos tienen divergencias en la forma de calcular o estimar algunos descriptores del funcionamiento del MRT como es el caso de la Relación Señal-Ruido (RSR). En el presente trabajo se implementó una herramienta basada en el reconocimiento del comportamiento de este descriptor empleando Redes Neuronales Artificiales (RNA). Los resultados obtenidos demuestran la validez del enfoque empleado y muestran un camino efectivo para dar solución al problema planteado

ABSTRACT

Due to the rapid growth of magnetic resonance equipment for medical diagnosis (MRT), is necessary to implement rigorous systems of Assurance and Quality Control (CAC) because of the proper functioning of the equipment, depends the proper interpretation of imaging (MRI), a successful medical diagnosis and the best action to take by specialists. At the present there are multiple associations dedicated to CAC and they have differences on how to calculate or estimate some of MRT Performance descriptors such as the Signal to Noise Ratio (SNR). In this work we implemented a tool based on the recognition of the behavior of this descriptor using Artificial Neural Networks (RNA), The results demonstrate the validity of this approach and show an effective way to solve the problem.

Palabras Claves: *Redes Neuronales, Resonancia Magnética, Relación Señal-Ruido, Control de calidad en Resonancia Magnética.*

INTRODUCCIÓN

La relación señal ruido (RSR) es un indicador del funcionamiento global de un sistema de resonancia magnética para el diagnóstico médico (MRT). Este indicador está catalogado como el principal parámetro a evaluar para determinar la disponibilidad técnica de un MRT para su desempeño. Su medición es una fuente valiosa de datos cualitativos y cuantitativos para el CAC de rutina y para la comparación de diferentes MRT. También garantiza el conocimiento a priori del sistema para separar la señal generada por el ruido y la producida por la estimulación de alguna de las vías sensoriales. La RSR se define, generalmente, como la capacidad del sistema o de la instalación de producir una señal dependiendo del ruido blanco relacionado con ella, teniendo en cuenta que este

último cumple, generalmente, una distribución de Gauss. Por esto para calcularla, comúnmente, se toma la relación entre la media de una región de interés (ROI) sobre la imagen (M) (figura 1) y su desviación estándar (D_s) [1,2].

Esta variante de cálculo usada por CUTAE-UE [1] tiene el inconveniente de depender mucho de la zona donde se escoja la ROI, pues, además del ruido, la señal está afectada también por las no homogeneidades del campo principal (B_0) y el de excitación (B_{ext}) que afectan el valor de D_s . Existen otras propuestas para calcular la RSR en las

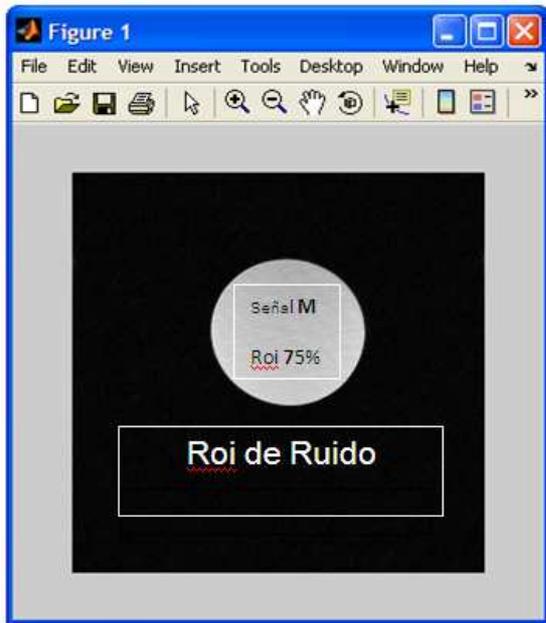


Figura 1. Selección de la ROI para calcular la RSR con una imagen.

imágenes por resonancia magnética (MRI), diferenciándose fundamentalmente, por la forma de estimar el ruido y por el uso de una o dos imágenes para estimarlo [1,2], pero todas siguen estando en función de la selección de la ROI por parte del usuario.

En este trabajo se propone un método de caracterización cualitativo de la RSR mediante el empleo de las Redes Neuronales Artificiales, para el reconocimiento del comportamiento de este descriptor en las MRI de forma automática analizando el histograma de la misma y evitando la dependencia de la selección de la ROI.

La estructura de este trabajo es la siguiente: en la sección 1 se presenta una caracterización de la RSR en las MRI. La sección 2 presenta una panorámica de las redes neuronales artificiales, profundizando en las utilizadas en el desarrollo del trabajo. En la sección 3 se presenta la propuesta de la herramienta para la evaluación de la RSR y en la sección 4 se presentan los resultados obtenidos con el empleo de la herramienta implementada. Finalmente se brindan las conclusiones del trabajo.

1. Caracterización manual de la RSR

Con el objetivo de determinar si el MRT se encuentra en condiciones óptimas para su funcionamiento, se hace necesario aplicar un test de control donde se evalúa diariamente el estado técnico del equipo para su desempeño según las especificaciones establecidas por el fabricante. En los MRT Panorama 0.23 T de la firma Philips, este método se puede realizar de dos formas. En las dos vías se utilizan los “phantoms” [3] (figura 2). Estos dispositivos son objetos emuladores del comportamiento del cuerpo humano cuando se encuentra bajo la influencia de campos magnéticos de valores altos.

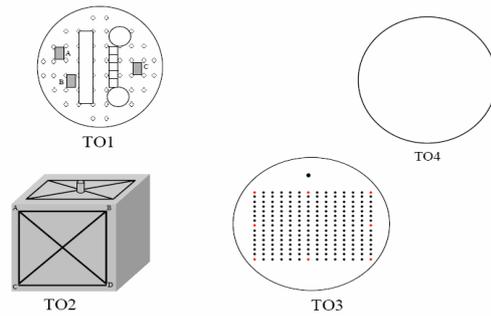


Figura 2. Representación de los Phantoms.

En la figura 2 se observan los Phantoms para el CAC (Test Objeto (TO)). El TO1 es un Phantom de Calidad, TO2 Phantom Cubo, TO3 es el Phantom de arreglo de agujeros y TO4 es el Phantom Homogéneo (F2 para Philips Medical Systems).

La primera forma de realizar el control diario a estos equipos es mediante un protocolo de cráneo y el “phantom” homogéneo F2 (figura 2 TO4). El “phantom” se coloca en el interior de la bobina de cráneo, esta se alinea con el centro magnético del imán principal, luego se ajustan los parámetros del equipo y se pasa a adquirir la imagen. Con la imagen anteriormente obtenida y con las herramientas de dibujo y cálculo del MRT, se seleccionan las ROI [4,5] de forma manual y luego se ejecuta un programa de cálculo basado en las ROI escogidas, con el valor obtenido, se emite un criterio de aceptación técnica del MRT para el trabajo.

La segunda manera de realizar este test, es mediante la aplicación QA Wizards, en la cual el protocolo viene pre definido y se realiza de forma automática. La desventaja de esta forma es que mantiene las divergencias con otras asociaciones dedicadas al CAC en el cálculo del parámetro, además de ser una aplicación que no se puede separar del MRT, lo que implica interrumpir el funcionamiento del equipo para realizar el estudio del descriptor.

2. Redes Neuronales Artificiales (RNA)

Las redes neuronales artificiales (denominadas habitualmente como RNA o en inglés como: "ANN") son un paradigma de aprendizaje y procesamiento automático inspirado en la forma en que funciona el sistema nervioso de los animales. Se trata de un sistema de interconexión de neuronas en una red que colaboran para producir un estímulo de salida. En la inteligencia artificial es frecuente referirse a ellas como redes de neuronas o redes neuronales [6]. Una representación típica de una red neuronal conformada por una capa de entrada, una capa oculta y su correspondiente salida se presenta en la figura 3 [6].

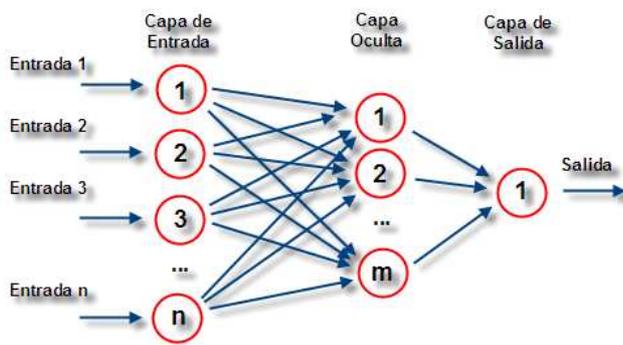


Figura 3. Representación de una Red Neuronal Artificial

Las redes neuronales se han desarrollado como una generalización de los modelos matemáticos existentes del conocimiento humano o de la neurona biológica asumiendo entre otras cosas que [6]:

1. El procesamiento de la información se efectúa en muchos elementos simples llamados comúnmente neuronas.
2. Las señales (estímulos o inhibidores) se propagan entre neuronas a través de enlaces o conexiones.
3. Cada enlace o conexión entre neuronas tiene un peso asociado, que constituye un parámetro interno de la conexión y que en modelos típicos multiplica la señal transmitida o propagada de neurona a neurona.
4. Cada neurona calcula su salida (suma de sus entradas pesadas) aplicándole una función de activación que normalmente es no lineal. De esta forma una red neuronal se caracteriza por:
 - Un patrón de conexiones entre las neuronas (llamada arquitectura).
 - Su método o forma de determinar los pesos de las conexiones (llamado entrenamiento, aprendizaje o algoritmo).
 - Su función de activación.

Existe una gran diversidad de arquitecturas de RNA. En el presente trabajo se utilizan dos arquitecturas de RNA, la red de Hopfield y la red de Base Radial, ambas con buenos resultados en el campo del reconocimiento de patrones [7, 8, 9, 10, 11].

Red de Hopfield

La Red es propuesta por John Hopfield 1982 [7]. La misma es capaz de recuperar patrones almacenados a partir de información incompleta e incluso patrones con ruido; además actúa como memoria asociativa procesando patrones estáticos. En este tipo de red, todas sus neuronas están conectadas entre sí.

Red de Base Radial (RB)

La Red de Base Radial [8] es una red neuronal que utiliza funciones de base radial como funciones de activación. En este tipo de red los nodos ocultos contienen una función base radial, la cual tiene como parámetros a centro y ancho.

Existe un centro para cada función radial involucrada en la capa oculta, que regularmente, definen un vector de la misma dimensión del vector de entrada y hay normalmente un centro diferente por cada nodo de la capa oculta. El ancho es el término empleado para identificar a la amplitud de la campana de gauss originada por la función radial. Es decir, la desviación estándar de la función radial. Algunos autores consideran este parámetro como un valor constante para cada una de las funciones radiales consideradas en la capa oculta y de este modo se contribuye a simplificar los pasos de construcción del modelo de entrenamiento de la red [8, 9, 10].

3. Propuesta de evaluación de la RSR mediante el uso de RNA

Como se analizó en la sección 1, los test de control de calidad diario presentan una alta dependencia de la ROI seleccionada y del tipo de "phantom" utilizado. En esta sección se presenta una propuesta de test de control basado en RNA que no depende de los elementos antes mencionados si no de la distribución de los histogramas de las MRI en estudio. El diagrama en bloques del funcionamiento de la aplicación es mostrado en la figura 4.

En la figura 4 se observa el diagrama de funcionamiento de la herramienta implementada para el proceso de caracterización la de RSR mediante RNA. Para la realización de la misma se siguió la siguiente estrategia:

- 1- Obtener las imágenes de Control de Calidad.
- 2- Agrupar las imágenes según el criterio que se va a emitir (buena RSR o mala RSR).
- 3- Obtener y Adecuar los patrones de entrenamiento de las RNA.
- 4- Entrenar la red neuronal
- 5- Validar a aplicación

Obtención de las imágenes de Control de Calidad

Es necesario mencionar que este tipo de test de relación señal a ruido solo se realiza para los estudios de cráneo. Para estos estudios se realizan diferentes protocolos y secuencias, con el objetivo de resaltar o separar visualmente las diferentes aéreas y líquidos del cerebro. En estos protocolos se varían diferentes parámetros como el ángulo de giro, los tiempos de relajación longitudinal y transversal, las dimensiones de las imágenes por solo citar algunos de ellos.

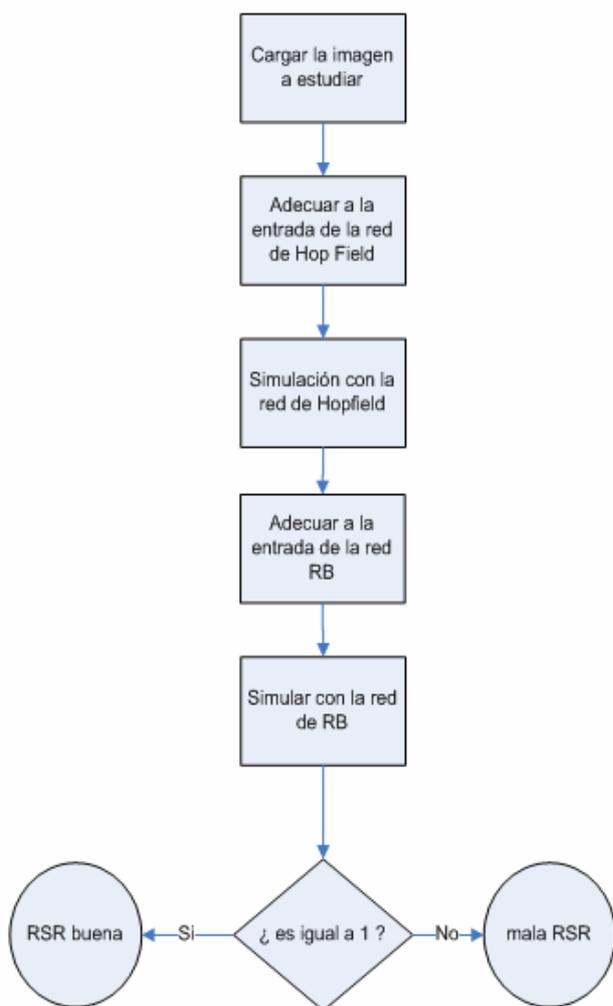


Figura 4. Representación del funcionamiento del conjunto de RNA para la estimación de la RSR.

Con esos protocolos se obtuvieron las imágenes que conformaron los patrones, utilizando el phantom homogéneo F2 de Philips Medical Service [3] (Figura 3).

Es necesario apuntar que las imágenes deben ser obtenidas según los parámetros para el equipo establecidas por el fabricante. En el caso de la tecnología Philips la aplicación de adquisición de imágenes se realiza con los siguientes parámetros [5]:

TE: 40

TR: 400

Espesor de Corte: 5 mm

Ángulo de giro: 90 °

Matriz: 256 x 256

Bobina: Cráneo

Phantoms: Homogéneo

Si las imágenes no se obtienen con estos parámetros el resultado es erróneo.

Agrupación de las imágenes según el criterio

Se obtuvieron un total de 55 imágenes de las cuales 14 presentaban buena RSR. En otras 14 el comportamiento del descriptor era deficiente y las últimas 27 tenían un comportamiento aleatorio y se utilizaron para validar la aplicación. Estas imágenes mediante un procesamiento pasaron a conformar los patrones de entrenamientos de las RNA.

Elección de la arquitectura de las redes a emplear.

No existe en la literatura ningún indicador específico que permita utilizar una arquitectura de red determinada para una aplicación específica debido a su naturaleza multiparamétrica. Debido a lo anterior hay que realizar un gran número de pruebas buscando la mejor respuesta a la situación planteada. Luego de un intenso proceso de pruebas, se seleccionó una combinación de dos arquitecturas de RNA, las cuales fueron posteriormente implementadas en Matlab 7.0.

La primera fue una Red de Hopfield [7] de la cual se aprovecha la capacidad de almacenar y recuperar información. Los requisitos de esta RNA es que los valores a su entrada tienen que estar acotado en el intervalo $[1, -1]$, [7, 9, 10, 11]. En la herramienta matemática Matlab esta arquitectura de RNA se crea mediante el comando *newhop* [12], y recibe como único parámetro la matriz de los vectores a almacenar. En este caso la dimensión utilizada fue 200 filas x 28 columnas que representan la cantidad de imágenes o patrones de entrenamiento seleccionadas.

La salida de la simulación de esta red, es enviada a la RNA de Base Radial que es la segunda arquitectura utilizada en la herramienta propuesta.

La Red de base Radial [8], es una red probabilística y su desempeño se basa en el cálculo según los parámetros y configuraciones que tengas sus funciones de activación. Esta RNA también fue implementada con la herramienta matemática Matlab 7.0 y el comando *newrb* [12]. Este comando recibe como parámetros: la matriz de patrones de entrenamientos, la salida deseada, el error a alcanzar, el ancho de la campana y la cantidad de neuronas en la capa oculta. Esta RNA se diseñó con tantas neuronas en la capa oculta como patrones de entrenamiento se seleccionaron (28 en este caso), un valor del ancho de la campana 0.001, un error de 0.000001 y la salida de esta será 0 o 1 perteneciente a los 2 estado que puede presentar la RSR. La matriz de patrones de entrenamiento a su entrada tiene una dimensión de 128 x 40, debido a que la salida de la RNA de Hopfield (200 x 40) es sometida al proceso de eliminación de los datos redundantes. A la salida de esta red se tendrá el código para emitir el criterio final del comportamiento de la RSR en la imagen en estudio.

Obtener y Adecuar los patrones de entrenamiento de las RNA

Una vez finalizada la agrupación de las imágenes, a las mismas se le extraen los histogramas (figura 5) y se pasa a la adecuación de los mismos para formar parte de los patrones de entrenamiento para las RNA.

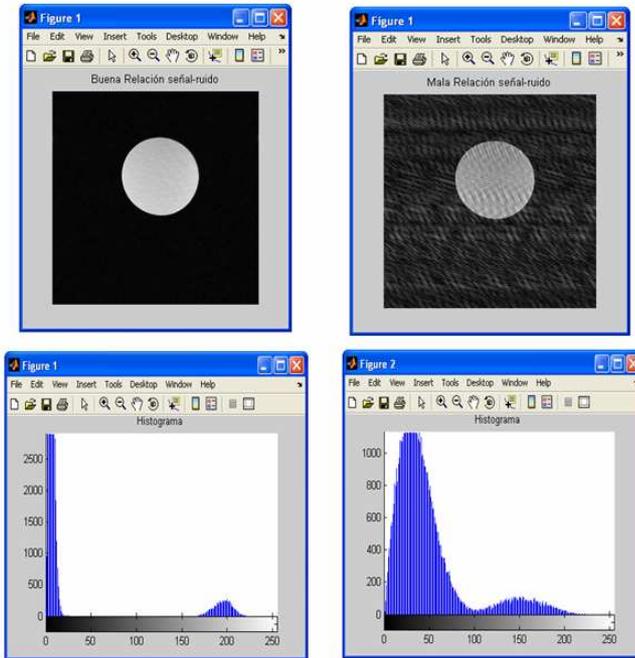


Figura 5. Representación de dos MRI y sus respectivos histogramas.

En la figura 5, se muestran dos MRI de control de la calidad con phantom homogéneo, y sus respectivos histogramas. La imagen superior izquierda pertenece a una imagen con buena RSR y la superior derecha corresponde a una imagen con mala RSR. Debajo se pueden observar la distribución de sus respectivos histogramas, aspecto a ser evaluado por el conjunto de RNA.

El trabajo con el histograma reduce la cantidad de información a la entrada de las RNA, así como el proceso de segmentación y extracción de las características o contornos para el caso de aplicaciones que seleccionan las ROI de forma automática como es el caso del test QA Wizards.

Los histogramas obtenidos, son ecualizados [13] para disminuir la correlación entre los píxeles de entradas y luego mediante una función se eliminan los datos o valores redundantes ya que no aportan ninguna información útil a las RNA.

La dimensión de la matriz original de las imágenes fue de 256 x 256. Al aplicar el proceso de eliminación de datos redundante el tamaño de sus respectivos histogramas se reduce, trayendo consigo la disminución del tamaño de la entrada de las RNA.

Entrenar y validar a aplicación

El proceso de entrenamiento se realizó con 28 patrones de entrenamientos, 14 de ellos con un criterio de RSR baja y el otro grupo con RSR alta. El proceso de validación se realizó con 15 patrones y sus resultados se muestran en la tabla 1.

4. Discusión de los Resultados

En la tabla 1 se muestran 7 resultados de la simulación de la aplicación ante 27 imágenes de entrada desconocidas para las arquitecturas de RNA que conforman la herramienta.

Numero del Patrón	Criterio de RSR según Philips	Criterio de RSR según las RNA
1	Buena	Buena
2	Buena	Buena
3	Mala	Mala
4	Mala	Mala
5	Mala	Mala
6	Buena	Buena
7	Mala	Mala

Como se aprecia en la tabla 1, el resultado a la salida de las RNA es igual al resultado QA Wizards realizado por Philips Medical Systems para el total de imágenes del set de validación.

La herramienta se instala junto con el compilador del Matlab en cualquier PC. Al ejecutarla muestra un Open Dialog de Windows para darle el camino o ubicación de la imagen a analizar, a su salida brinda la imagen en estudio y el criterio de RSR según las RNA.

En la figura 6 se muestra la salida de la aplicación ante dos imágenes de control de calidad cargadas por el usuario. La imagen de la izquierda presenta una relación señal-ruido buena (alta), en la parte inferior de la misma se puede observar el criterio emitido por la aplicación. La imagen de la derecha es una imagen con mala (baja) relación señal-ruido, al igual que la anterior, en la parte inferior se puede observar el criterio emitido por la aplicación en letras de color rojo, resaltando el estado del descriptor en la misma.

Ventajas de la herramienta propuesta

1- Se puede utilizar cualquier simulador o Phantom homogéneo, ya que las RNA solo evalúan el comportamiento del histograma de la imagen y además no dependen de la ROI.

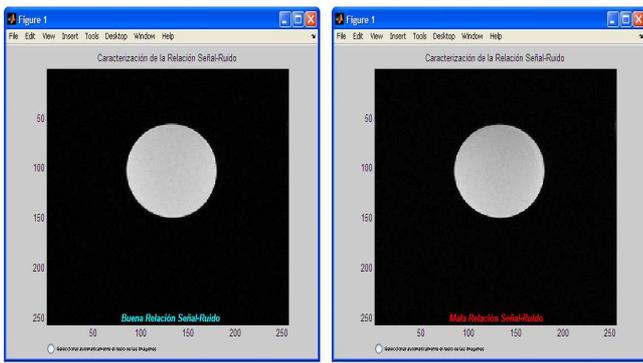


Figura 6. Representación de la salida del analizador de la RSR

- 2- Se mantiene la estimación de la RSR de forma automática.
- 3- Una vez creadas, simuladas y guardadas las RNA, la aplicación se reduce a simular el conjunto ante la imagen a estudiar.
- 4- La herramienta es sencilla y fácil de usar.
- 5- No requiere de un gran conocimiento en el campo del CAC.
- 6- Se evita el procesamiento de las MRI para seleccionar las ROI de forma automática, reduciendo la carga computacional al CPU.

6. Conclusiones

En este trabajo se desarrolló una herramienta para la estimación de la RSR en las imágenes de control de calidad diarias obtenidas en los MRT Panorama de 0.23T mediante el empleo de RNA y el reconocimiento de patrones. A diferencia de otros métodos, esta herramienta analiza el comportamiento o la distribución del histograma y no el de las ROI, con lo que se evitan los errores de selección de las mismas y además no se necesita un alto grado de conocimiento por parte del encargado de realizar el test. Este estudio abre un nuevo campo de investigación con el objetivo de crear una estandarización en los parámetros de CAC basados en MRI y así evitar las divergencias actuales en las formas de calcular o estimar los mismos.

Bibliografía

1. E Gonzales. Descriptores cuantitativos de calidad para tomógrafos de Resonancia Magnéticas. Tesis doctoral, Centro de Biofísica Médica Santiago de Cuba, 2003.
2. W. Myers, D. Slichter, M. Hatridge, S. Busch, M. Moble, R. McDermott, A. Trabesinger, J. Clarke. "Calculated signal-to-noise ratio of MRI detected with

SQUIDS and Faraday detectors in fields from 10 T to 1.5 T" .Journal of Magnetic Resonance, 182-192, www.sciencedirect.com, Febrero 2007.

3. Philips Medical Systems. Panorama 0.23T Opcional Accessories, 2005.
4. Philips Medical Systems. Panorama 0.23T Applications guide, 2005.
5. Philips Medical Systems. Magnetic Resonance Imaging Manual, 2009.
6. A. Serrano, E. Soria, J.. Martín. "Redes Neuronales Artificiales". Libro, curso 2009-2010, http://ocw.uv.es/ingenieria-y-arquitectura/1-2/libro_ocw_libro_de_redes.pdf, Universidad de Valencia, España, 2009.
7. M. Atencia. "Estabilidad en Sistemas Neuronales Realimentados". Tesis doctoral, <http://riuma.uma.es/xmlui/bitstream/handle/10630/2632/16701367.pdf?sequence=1>. Universidad de Málaga, España 2004.
8. M. Zorrilla. "Procesamiento Paralelo y Distribuido aplicado al Almacenamiento y Recuperación de Información Documental". Tesis doctoral, http://www.tesisenred.net/TESIS_UC/AVAILABLE/DR-0927110-130601//TesisMZP.pdf. Universidad de Cantabria Santander, España 2001.
9. J. Montaña. "Redes Neuronales Artificiales aplicadas al análisis de datos", Tesis doctoral, <http://www.tdr.cesca.es/TESIS UIB/AVAILABLE/TD-X-0713104-100204//tjmm1de1.pdf>, Palma de Mallorca, 2002.
10. F. Arteaga, D. Sevilla, P. Franco N, R. Méndez, G. Beale. "Redes neuronales para la estabilización simultánea con múltiples dominios acotados de estabilidad en control de procesos". Revista Ingeniería UC. Vol. 10, No 2, 30-42, Universidad de Carabobo, Venezuela, 2003.
11. S. Roa. Determinación de Masas en Imágenes Radiológicas de Tórax Usando Técnicas de Reconocimiento de Patrones. Enlace Informático, Vol. 4, No 1, 35-42 .Universidad del Cauca. Colombia, 2005.
12. The MathWorks Inc. Manual del usuario de MATLAB, 2006.
13. M. Aguilar. Desarrollo de una etapa de pre-procesamiento para reducción de ruido, mejoramiento de contraste y de nitidez en imágenes digitalizadas de geles de electroforesis. Tesis de ingeniería. <http://bibliodigital.itcr.ac.cr:8080/dspace/bitstream/2238/405/1/Informe+Final.pdf> Instituto Tecnología de Costa Rica, 2007.