

La función de base radial de rango tipo M para la clasificación de imágenes de mamografía

Francisco-Javier Gallegos-Funes¹
Volodymyr Ponomaryov²
Alexandre Michtchenko¹
José-Augusto Moreno-Escobar¹

National Polytechnic Institute of Mexico
Mechanical and Electrical Engineering Higher School
¹ESIME, UPALM Zacatenco.
Av. IPN s/n, ESIME SEPI Electrónica, Col. Lindavista,
07730, Mexico, DF.
²ESIME UP Culhuacan.
Av. Santa Ana 1000, Col. San Francisco Culhuacan,
04430, Mexico, DF.
MÉXICO.

Tel/Fax: (5255)57296000 ext. 54608.

correo electrónico:

fgallegosf@ipn.mx
vponomar@ipn.mx

Recibido el 23 de febrero de 2007; aceptado el 14 de noviembre de 2007.

1. Resumen

El uso del diagnóstico asistido por computadora para el análisis de pruebas médicas está tomando relevancia en áreas como ECG y EEG, pero también en la detección de cáncer. En este trabajo se propone la red neuronal función de base radial de rango tipo M (RMRBF) para la detección de anomalías que puedan producir cáncer de mama. La red neuronal propuesta usa estimadores RM en el esquema del algoritmo de la red neuronal tipo función de base radial (RBF) para entrenar la red propuesta. La RMRBF es comparada con otros algoritmos relacionados a la RBF encontrados en la literatura. De los resultados de las simulaciones realizadas se observa que la RMRBF tiene mayor capacidad de clasificación y mayor eficiencia que los algoritmos usados como comparativo.

Palabras clave: mamografía, cáncer de mama, funciones de base radial, estimadores RM, redes neuronales.

2. Abstract (Rank M-Type Radial Basis Function (RMRBF) to Mammography Image Analysis)

The use of Computer Aided Diagnosis (CAD) for medical data analysis is taking relevance in areas as ECG and EEG, but also in cancer detection. In this paper we propose the Rank M-Type Radial Basis Function (RMRBF) neural network for the detection of abnormalities that can cause breast cancer. The proposed neural network uses the RM-estimator in the scheme of the Radial Basis Function neural network to train the proposed network. The proposed RMRBF is compared with other RBF based algorithms found in literature. From simulation results we observe that the RMRBF gives better classification capabilities and better efficiency than the algorithms proposed as comparative.

Key words: mammography, breast cancer, radial basis functions, RM-estimators, neural networks.

3. Introducción

Las redes neuronales artificiales (RNA) son sistemas de reconocimiento de patrones que pueden generalizar aprendiendo de ejemplos [1-6]. Son particularmente útiles en problemas donde las reglas para tomar decisiones no son precisas y no hay un conocimiento explícito sobre las funciones de probabilidad que gobiernan la distribución de las muestras. Es por esto que el problema de la detección de cáncer de mama es un candidato idóneo para usar redes neuronales [7-10].

Las RNA tienen el potencial de tener un rendimiento mayor que los algoritmos computacionales tradicionales. Desde el inicio de la década de los 90 se han considerado varias redes neuronales para la detección de cáncer [7,8]. Conforme se tenga mayor acceso a pruebas médicas de calidad se va a tener mejor evidencia del potencial de las RNA para ayudar en el difícil problema de la detección de cáncer de mama.

La arquitectura neuronal que se usa con más frecuencia en los sistemas de diagnóstico asistido por computadora (señales EEC, ECG y análisis de imágenes médicas) es la de multicapa con retroalimentación, como es el caso del perceptrón multicapa (MP) [6,9,11,12] que tiene un aprendizaje supervisado usando reglas de retropropagación.

Es este trabajo, se presenta la clasificación de imágenes de mamografía mediante el uso de la red neuronal RMRBF. La red neuronal propuesta usa estimadores RM en el esquema del algoritmo de la red neuronal función de base radial (RBF) para entrenar a la red propuesta basándose en varios esquemas propuestos en la literatura [9,11,13].

4.1 Cáncer de mama

El cáncer de mama es el segundo cáncer más frecuente en México después del de cuello de la matriz o cáncer cervical [14]. Este tipo de cáncer se extiende a través del sistema linfático, por lo que siempre deben revisarse y en ocasiones extraerse los ganglios de la axila y del cuello para comprobar si el cáncer no se ha extendido [15,16]. La figura 1 presenta los principales tipos de cáncer que afectan a la población de nuestro país [14].

El cáncer de mama suele comenzar con una alteración a nivel celular que puede ser causada por diversos factores: tipo de dieta, tabaquismo, exposición solar, ciertas sustancias, radiaciones, etc. En el desarrollo de este tipo de cáncer influyen directamente familiares directos que hayan sufrido cáncer de mama, uso prolongado de anticonceptivos orales, temprano inicio de la menstruación, obesidad posmenopáusica o ausencia de embarazos [15,16].

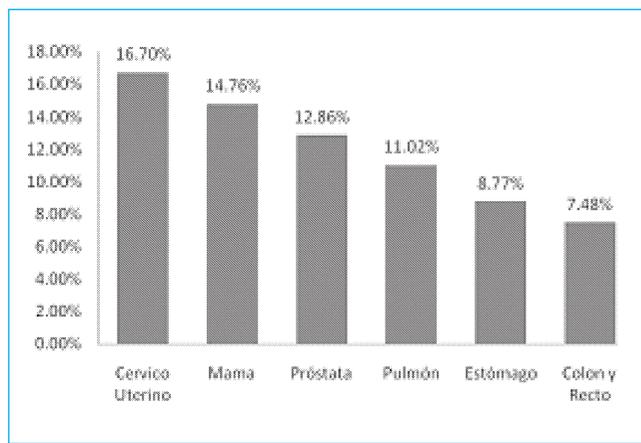


Fig. 1. Principales tipos de cáncer que afectan a la población de nuestro país.

El cáncer de mama se clasifica en cinco tipos diferentes [17,18]:

- 1) *El carcinoma ductal in situ* se origina en las células de las paredes de los conductos mamarios. Es un cáncer muy localizado, que no se ha extendido a otras zonas ni ha producido metástasis.
- 2) *El carcinoma ductal infiltrante* (o invasivo) es el que se inicia en el conducto mamario pero logra atravesarlo y pasa al tejido adiposo de la mama y luego puede extenderse a otras partes del cuerpo.
- 3) *El carcinoma lobular in situ* se origina en las glándulas mamarias y, aunque no es un verdadero cáncer, aumenta el riesgo de que la mujer pueda desarrollar un tumor canceroso en el futuro.
- 4) *El carcinoma lobular infiltrante* (o invasivo) comienza en las glándulas mamarias pero se puede extender y destruir otros tejidos del cuerpo.
- 5) *El carcinoma inflamatorio* es un cáncer agresivo y de rápido crecimiento. Hace enrojecer la piel del seno y aumentar su temperatura. La apariencia de la piel se vuelve gruesa y ahuecada, y pueden aparecer arrugas y protuberancias.

Las microcalcificaciones son indicadores favorables de presencia de cáncer de mama. Éstas son pequeñas acumulaciones de calcio de de 0.1 mm a 2 mm de ancho [3,8].

5. Mamografía

La mamografía es un método para examinar los senos o mamas que utiliza pequeñas dosis de radiación. Este simple procedimiento sirve para detectar tumores y quistes muy pequeños, imposibles de descubrir con un examen manual [19]. En algunos casos puede ayudar a determinar la naturaleza del tumor: benigno o maligno, como se muestra en la figura 2.

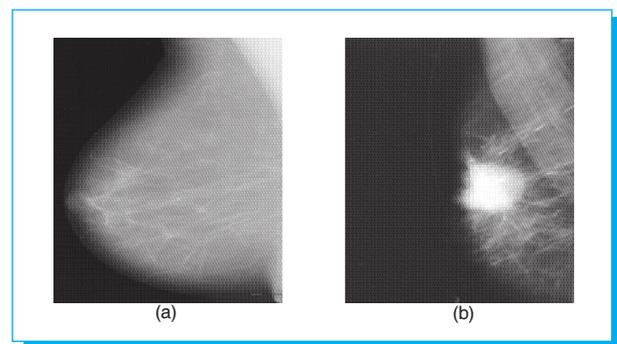


Fig. 2. Ejemplos de mamografías, (a) no presenta anomalías, (b) se aprecia la presencia de un tumor maligno [20].

5.1 Colección de imágenes de mamografía

El tener acceso a imágenes médicas reales para hacer pruebas experimentales no es sencillo debido a políticas médicas y a trámites burocráticos. La colección de imágenes que fue utilizada en nuestros experimentos es resultado de la recopilación de varias fuentes de Internet, siendo la más importante la colección de imágenes MIAS (Mammographic Image Analysis Society) [21]. La colección de imágenes MIAS ha sido utilizada en otros trabajos reportados sobre clasificación automática de mamografías [8]. Esta colección tiene 322 imágenes divididas en tres grandes grupos o categorías: normales, benignas y malignas. Hay 208 imágenes normales, 63 benignas y 51 malignas.

6. Segmentación y extracción de características

El primer paso en el análisis automático de imágenes consiste en la etapa de segmentación. Esto permite dividir la imagen a analizar en regiones de interés.

6.1 Etapa de segmentación

En el caso de este trabajo, para cada mamografía se tienen dos regiones de interés:

- Región 1, que se conforma del seno o mama, y
- Región 2 que se conforma de algún(os) objeto(s), que se pueden entender como anomalías de varios tipos.

Debido a la irregularidad de las formas presentes en las imágenes de mamografía, para obtener las regiones de interés de este trabajo se emplearon técnicas de segmentación morfológica y el criterio de selección de umbral.

6.1.1 Morfología

La morfología ofrece un método poderoso y único de abordar numerosos problemas del procesado de imágenes. Para dos conjuntos A y B , las dos operaciones morfológicas más importantes son [22,23]:

- Dilatación. Consiste en agrandar una región de interés de una imagen, y se define como $A \oplus B$.
- Erosión. Consiste en contraer una región de interés de una imagen, y se define como $A \ominus B$.
Al combinar estas técnicas, se pueden hacer las siguientes operaciones [22,23]:
- Apertura. Generalmente suaviza el contorno de una imagen, rompe istmos estrechos y elimina protuberancias delgadas.

$$A \circ B = (A \ominus B) \oplus B \quad (1)$$

- Cierre. También tiende a suavizar contornos pero generalmente fusiona separaciones estrechas y entrantes delgados y profundos.

$$A \bullet B = (A \oplus B) \ominus B \quad (2)$$

6.1.2 Técnica de selección de umbral

La técnica de selección de umbral es un método que permite distinguir entre píxeles que se encuentran en distintos rangos de niveles de gris (valores de píxeles) y que pueden pertenecer a distintos objetos de una imagen [22]. El valor de umbral se determina de acuerdo a la imagen que se quiere segmentar. Para nuestro caso se usaron dos umbrales: uno para el objeto detectado y otro para la mama. El valor de umbral de cada uno de ellos se calculó de acuerdo al valor máximo de cada región de interés, y se tomó un 20% de ese valor para ambos casos.

Combinando los métodos descritos se dividió la mamografía en dos regiones principales: un objeto detectado (posible tumor o cáncer) y el seno o mama. El fondo no fue tomado en cuenta ya que éste no provee información relevante, y al discriminarlo el tiempo de procesamiento es menor.

6.2 Extracción de características

Existen técnicas de medición geométrica en las imágenes que permiten la evaluación de características asociadas con objetos extraídos de imágenes. En imágenes médicas, estas técnicas permiten evaluar tumores, estructuras celulares, tejidos fetales, entre otros. Estas técnicas permiten darnos una idea de qué tan compacto, brillante y suave es un objeto detectado en una imagen [24]. Dos de estas características son las siguientes:

- Densidad de objeto: es una medida de la distribución de un objeto,

$$\text{densidad de objeto} = \frac{\text{perímetro}^2}{\text{área}} \quad (3)$$

- Contraste: es la diferencia de promedios de gris de dos objetos detectados en una imagen,

$$\text{contraste} = \frac{\text{promedio_objeto} - \text{promedio_mama}}{\text{promedio_objeto} + \text{promedio_mama}} \quad (4)$$

También se utilizaron algunas cantidades estadísticas como las siguientes [24,25]:

- Valor promedio (objeto detectado y mama). Dados los números a_1, a_2, \dots, a_n , el valor promedio será igual a:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n a_i \quad (5)$$

- Desviación estándar (objeto detectado y mama),

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (a_i - \bar{x})^2} \quad (6)$$

- Rango (objeto detectado y mama),

$$\text{Rango} = a_{\max} - a_{\min} \quad (7)$$

Estas cantidades, que suman un total de ocho, constituyen los datos de entrada para las redes neuronales que fueron implementadas.

7. La función de base radial

Las funciones de base radial (RBF) son redes multicapa con conexiones hacia adelante, y se caracterizan por estar formadas por una capa oculta única, y cada neurona de esta etapa posee un carácter local, en sentido de que cada neurona de la red se activa en una región diferente del espacio de patrones de entrada [26-29]. Este carácter local viene dado por el uso de las llamadas funciones de base radial como funciones de activación.

Uno de los objetivos iniciales de los desarrolladores de esta red era construir una red de neuronas que requiriese menos tiempo que el perceptrón multicapa, y de ese modo disponer de una red de neuronas que pudiera ser apropiada para aplicaciones en tiempo real, como pueden ser la clasificación y el modelado de funciones [9,26,28]. La estructura básica de una RBF se muestra en la figura 3 [10].

Las principales características de las RBF son las siguientes [9,28]:

- Usa un número mínimo de nodos en comparación con otras redes, reduciendo el número de cálculos para el aprendizaje.
- Es de fácil implementación.
La arquitectura es simple (sólo tres capas).
- Es un buen clasificador.

7.1 Funciones de activación

Muchas funciones de activación se han probado en la implementación de las RBF [9,11,30,31], aunque la más utilizada es la función gaussiana,

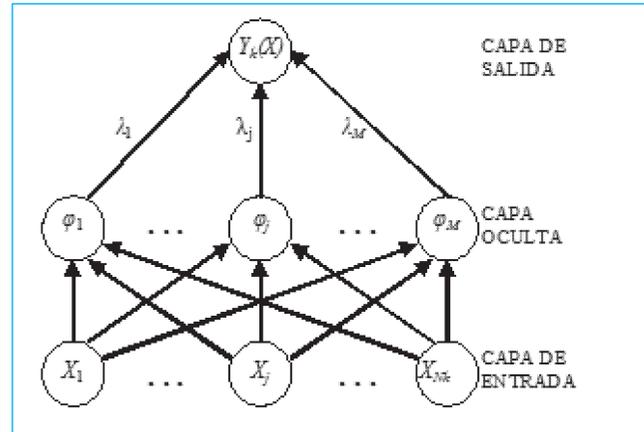


Fig. 3. Esquema tradicional de la función de base radial. Cada uno de los N_k componentes del vector de entrada \mathbf{X} alimenta a las M funciones radiales, cuyas salidas son linealmente combinadas con los pesos $\{\lambda_{j=1}^M\}$ para producir la salida $Y_k(\mathbf{X})$.

$$\phi(X) = \exp\left(\frac{-X^2}{2\sigma^2}\right) \quad \text{para } \sigma > 0 \quad (8)$$

donde X representa a los datos de la entrada, σ^2 representa la desviación de los datos de la muestra y $2\sigma^2$.

La capa de salida realiza una suma ponderada de las salidas de cada una de las funciones radiales de la capa oculta [30]:

$$\psi_k(\mathbf{X}) = \sum_{j=1}^L \lambda_{jk} \phi_j(\mathbf{X}) \quad (9)$$

donde L es el número de funciones radiales, M es el número de salidas con $k = 1, \dots, M$. Los pesos λ_{kj} indican la aportación de cada función radial j para una salida k .

7.2 Entrenamiento de las RBF

El entrenamiento de la red RBF es solamente hacia adelante. De este modo, la salida de una red RBF, en general, está influenciada por una transformación no lineal originada en la capa oculta a través de la función radial y una lineal en la capa de salida a través de la función lineal continua [9,11,13,28]. Para entrenar a la red neuronal RBF se emplea una combinación de entrenamiento supervisado-no supervisado (híbrido).

7.2.1 Fase no supervisada

Para determinar los centros de cada función radial, se empleó el algoritmo de agrupamiento de las k -medias [9,11,32]. Éste

es uno de los algoritmos para clasificación no supervisada más simple, y en la implementación de la RBF es el algoritmo más utilizado [9-11]. Se parte de un número determinado de prototipos y de un conjunto de muestras a agrupar, sin etiquetar. La idea es situar a los prototipos en el espacio, de forma que los datos pertenecientes al mismo prototipo tengan características similares.

El vector de entrada \mathbf{X} se clasifica en k grupos o clases diferentes. Un nuevo vector \mathbf{x} se asigna al grupo o clase k cuyo centro μ_k es el más cercano al vector. El centroide del vector se actualiza de acuerdo a:

$$\mu_k = \mu_k + \frac{1}{N_k} (\mathbf{x} - \mu_k) \quad (10)$$

donde N_k es el número de vectores que ya han sido asignados a la clase k . Los centroides se pueden actualizar al final de varias iteraciones o después de probar con cada vector nuevo.

Los pasos de algoritmo de las k -medias son los siguientes [9,11]:

1. Seleccionar arbitrariamente una partición inicial de la muestra de datos en k clases. Repetir los pasos 2 al 4 hasta que el número de datos de cada clase se estabilice.
2. Generar una nueva partición asignando cada patrón al centroide de clase más cercano.
3. Calcular nuevos centros para cada clase como los centroides de las clases existentes.
4. Repetir los pasos 2 y 3 hasta que se cumpla un criterio establecido o se llegue al valor óptimo esperado.

7.2.2 Fase supervisada

El cálculo de los pesos y umbrales de la red neuronal sirve para ajustar la salida de la red a un valor deseado. En la literatura se puede encontrar que los métodos más utilizados para el ajuste de pesos y umbrales son la matriz pseudoinversa y mínimos cuadrados [11,28]. Para nuestro caso, dada la irregularidad de las imágenes de mamografía, los datos obtenidos son difíciles de ajustar, por lo que se optó por usar una función de transferencia de saturador lineal duro para ajustar la salida de la función radial [31],

$$\text{hardim}(x) = \begin{cases} 1, & x \geq 0 \\ -1, & \text{en cualquier otro caso} \end{cases} \quad (11)$$

8. Función de base radial de rango tipo M (RMRBF)

Aquí se presenta el uso del estimador RM para hacer estimaciones estadísticas en el marco de la arquitectura de la red RBF. La combinación de estimadores R y M permite el uso de distintos estimadores de rango R, como pueden ser la mediana, Wilcoxon o Ansari-Bradley-Siegel-Tukey con distintas funciones de influencia en el estimador M [33-35].

8.1 Función de activación

Existen varias funciones de activación que pueden ser utilizadas en las redes RBF, como la función gaussiana (8), la función cuadrática inversa y la función multicuadrática inversa [11]. En el caso de este trabajo se utilizó la función multicuadrática inversa, pues ésta presentó mejores resultados experimentales:

$$\phi_j(\mathbf{X}) = \frac{1}{\sqrt{\mathbf{X}^2 + \beta_j^2}} \quad (12)$$

donde \mathbf{X} es el vector o dato de entrada y β_j es una constante real. Para nuestro caso, $\beta_j = 1$.

8.2 Estimador de rango tipo M

El estimador combinado RM que es utilizado en la red RBF propuesta es el estimador de mediana tipo M (estimador MM). El estimador MM no iterativo usado para estimar el centro de un grupo está dado por [33]:

$$\mu_k = \text{med} \{ \mathbf{X} \tilde{\psi}(\mathbf{X} - \theta) \} \quad (13)$$

donde \mathbf{X} representa a la muestra de datos de entrada, $\tilde{\psi}$ es la función de influencia normalizada $\psi : \psi(\mathbf{X}) = \mathbf{X} \tilde{\psi}(\mathbf{X})$, $\theta = \text{med} \{ X_k \}$ es la estimación inicial, y $k=1, 2, \dots, N_k$. El estimador (13) es llamado el estimador combinado RM. El estimador R tiene buenas propiedades para la discriminación de datos cuyo valor tiene una gran diferencia con respecto de la media de una muestra de datos, y el estimador M usa diferentes funciones de influencia de acuerdo al esquema de Huber proporcionando mayor robustez. Al hacer la combinación de estimadores R y M en el estimador RM se espera que el rendimiento sea mejor en comparación al de los estimadores R y M por sí solos [33-35].

8.3 Funciones de influencia

En la red neuronal propuesta RMRBF se usaron las siguientes funciones de influencia [33-35]:

- Función de influencia de corte simple,

$$\Psi_{\text{cut}(r)}(X) = X \cdot 1_{[-r,r]}(X) = \begin{cases} X, & |X| \leq r \\ 0, & \text{en cualquier otro caso} \end{cases} \quad (14)$$

- Función de influencia de Tukey,

$$\Psi_{\text{cut}(r)}(X) = \begin{cases} X^2 (r^2 - X^2), & |X| \leq r \\ 0, & \text{en cualquier otro caso} \end{cases} \quad (15)$$

donde X es la muestra de datos y r es una constante real. El parámetro r depende del tipo de datos que se vayan a procesar y su valor puede cambiar para diferentes funciones de influencia.

9. Resultados experimentales

La primera parte de la etapa experimental consistió en hacer pruebas de segmentación y extracción de características para ver si los datos obtenidos permiten diferenciar entre mamografías sanas y mamografías que no lo son. Para esto se trabajó con 32 imágenes, divididas en cinco grupos (véase tabla 1), de las cuales se sabe el diagnóstico médico: ocho imágenes sin anomalías o sanas, ocho imágenes con diversas anomalías cancerígenas, cuatro con microcalcificaciones (μC) benignas y cuatro con μC malignas, todas obtenidas de la referencia [21]. Estas imágenes tienen una resolución de 1024x1024 píxeles.

Se elaboró un programa en Matlab® 7 que utiliza todas las operaciones mencionadas en la sección 6.2, y se creó una base de datos en la que se tienen todas las características extraídas de cada una de las imágenes.

En la gráfica que se obtuvo para la densidad de objeto, mostrada en la figura 4, se aprecia una clara diferenciación entre mamografías sanas, representadas las columnas I y II, y

Tabla 1. Grupos de prueba para la parte de segmentación en la colección de imágenes MIAS.

I	Mamografías sin anomalías
II	Mamografías con anomalías benignas
III	Mamografías con anomalías cancerígenas
IV	Mamografías con C benignas
V	Mamografías con C malignas

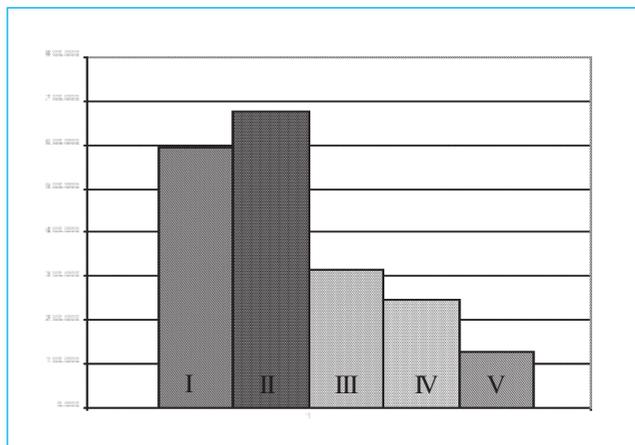


Fig. 4. Densidad de objeto (promedio) obtenida para cada uno de los grupos de prueba.

mamografías con cáncer y con μC , representadas por las columnas III, IV y V.

Con base en que los resultados para las otras características obtenidas fueron similares a las mostradas en la figura 4 para las imágenes de prueba, se propusieron dos grupos de clasificación: el primero (grupo 1) está constituido por imágenes sin anomalías e imágenes con anomalías benignas; el segundo (grupo 2) se constituye de imágenes con anomalías malignas e imágenes con cualquier tipo de microcalcificación, sea ésta benigna o maligna.

Para el entrenamiento de la red se emplearon los datos extraídos de las 32 imágenes usadas en las pruebas de segmentación, y para probar la eficiencia de la red se usaron 125 imágenes (40 normales, 38 con anomalías benignas, 30 con anomalías malignas, ocho con microcalcificaciones benignas y nueve microcalcificaciones malignas).

En la figura 5 se muestra el proceso de obtención de los parámetros de la RBF. Se usó una función de activación para cada una de las características empleadas, que fueron un total de ocho. Estos parámetros se obtuvieron con las 32 imágenes usadas en la fase de prueba. Para la red propuesta se usó (13) para indicar los datos a tomar en cuenta en la estimación de los parámetros, y posteriormente se empleó el algoritmo de las k -medias para saber el centro de la función de activación.

Para evaluar el desempeño de la red neuronal propuesta RMRBF se calcularon los siguientes parámetros:

eficiencia,

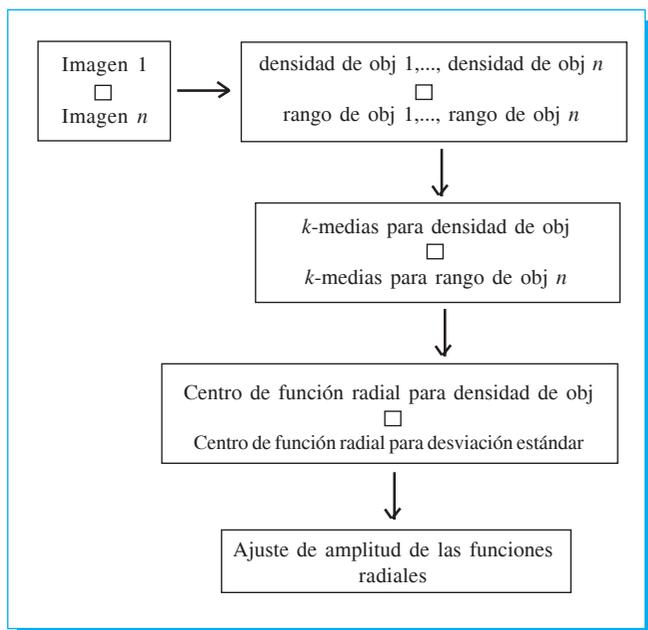


Fig. 5. Proceso de entrenamiento de las RBF implementadas.

$$eficiencia = \frac{\text{número de aciertos}}{\text{número total de imágenes}} \times 100\% \quad (16)$$

error,

$$error = \frac{\text{número de errores}}{\text{número total de imágenes}} \times 100\% \quad (17)$$

e incertidumbre como

$$incertidumbre = 100\% - eficiencia - error \quad (18)$$

Aparte se calcularon algunas cantidades empleadas para evaluar los sistemas de detección de alguna enfermedad, que son las siguientes [36]:

- Sensitividad. Es la probabilidad de que un examen médico entregue un resultado positivo cuando se tiene un grupo de pacientes con cierta enfermedad que se está estudiando, y se calcula de la manera siguiente:

$$S_n = TP / (TP + FN) \quad (19)$$

donde S_n es la sensitividad, TP es el número de resultados positivos correctos y FN es el número de falsos negativos, esto es, de resultados negativos que no son correctos.

- Especificidad. Es la probabilidad de que un examen médico entregue un resultado negativo cuando se tiene un grupo

de pacientes que no presentan la enfermedad que se está estudiando. La fórmula para calcular la especificidad es:

$$S_p = TN / (TN + FP) \quad (20)$$

donde S_p representa la especificidad, TN el número de resultados negativos correctos y FP el número de falsos positivos, esto es, de resultados positivos incorrectos.

La red neuronal propuesta RMRBF se evaluó usando diferentes funciones de influencia, y su rendimiento se comparó con el de las redes neuronales RBF básica, mediana RBF y α -Trimmed Mean RBF, las cuales fueron implementadas de acuerdo a sus referencias bibliográficas [28,37-39].

El proceso de clasificación completo se muestra en la figura 6.

En la tabla 2 se muestran los resultados experimentales en términos de eficiencia, incertidumbre y error para la colección de imágenes para los cinco casos principales: normales (NORMAL), anomalías benignas (AN_BEN), anomalías malignas (AN_MAL), microcalcificaciones benignas (uC_BEN), y microcalcificaciones malignas (uC_MAL) para el caso de las redes neuronales: RBF básica,

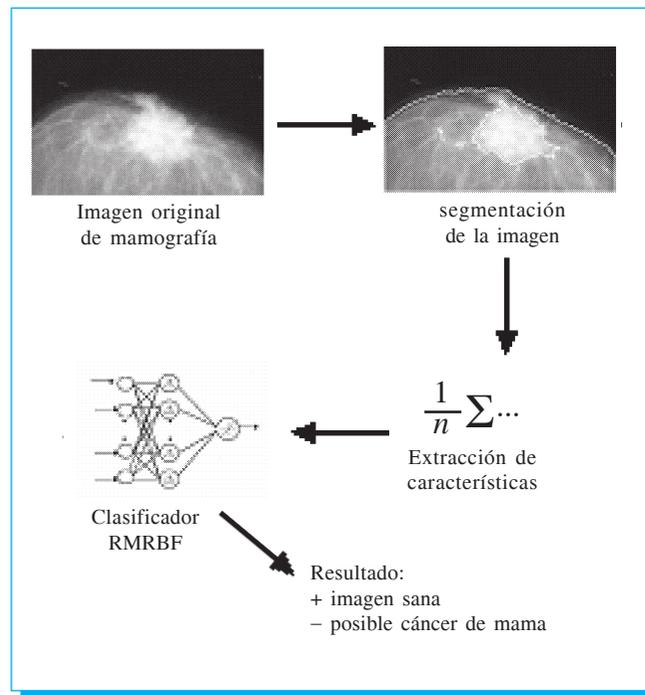


Fig. 6. Proceso de clasificación de las RBF implementadas.

Tabla 2. Resultados de rendimiento en la colección de imágenes MIAS mediante el uso de diferentes redes neuronales.

Redes Neuronales		NORMAL	AN_BEN	AN_MAL	uC_BEN	uC_MAL	TOTAL
BÁSICA RBF	Eficiencia	52.50%	47.37%	30.00%	12.50%	55.56%	39.59%
	Incertidumbre	1.33%	0.00%	0.00%	0.00%	0.00%	0.27%
	Error	46.17%	52.63%	70.00%	87.50%	44.44%	60.15%
MEDIANA RBF	Eficiencia	65.00%	60.53%	26.67%	12.50%	66.67%	46.27%
	Incertidumbre	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
	Error	35.00%	39.47%	73.33%	87.50%	33.33%	53.73%
α -TRIMMED MEAN EBF	Eficiencia	47.50%	57.89%	50.00%	87.50%	55.56%	59.69%
	Incertidumbre	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
	Error	52.50%	42.11%	50.00%	12.50%	44.44%	40.31%
RMRBF corte simple	Eficiencia	70.00%	71.05%	30.00%	62.50%	88.89%	64.49%
	Incertidumbre	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
	Error	30.00%	28.95%	70.00%	37.50%	11.11%	35.51%
RMRBF Tukey	Eficiencia	70.00%	57.89%	36.67%	37.50%	77.78%	55.97%
	Incertidumbre	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
	Error	30.00%	42.11%	63.33%	62.50%	22.22%	44.03%

mediana RBF, α -trimmed mean RBF, y la red propuesta RMRBF usando las funciones de influencia de corte simple y Tukey.

En la tabla 3 se presenta la eficiencia de clasificación para el grupo 1 (imágenes normales y anomalías benignas) y el grupo 2 (cualquier clase de microcalcificación y anomalías malignas) mediante el uso de diferentes redes neuronales. De las tablas 2 y 3 se puede ver que los mejores resultados en términos de eficiencia se obtienen con el uso de la red neuronal propuesta RMRBF.

De las tablas 2 y 3 se puede ver que la RBF simple tiene una eficiencia pobre cercana al 40%, lo que lleva a la conclusión de que el algoritmo simple de esta red neuronal no es bueno por sí solo para clasificar los datos obtenidos en la segmentación. La median RBF presenta mejores capacidades

de clasificación que la red anterior, pues tienen una eficiencia cercana al 46%, pero menores a las que se obtienen con la red α -Trimmed Mean RBF, que tiene una eficiencia de clasificación cercana al 60%.

En las mismas tablas se muestran los resultados obtenidos con la RMRBF. Usando la función de influencia de corte simple muestran que ésta tiene un rendimiento cercano al 65%, que es mayor al rendimiento obtenido con los métodos encontrados en la literatura, mientras que con la función de influencia Tukey se tiene una eficiencia cercana al 56%.

En la tabla 4 se presentan la sensibilidad y especificidad de cada una de las redes implementadas. La que presenta mayor sensibilidad es la α -Trimmed Mean RBF, y la que presenta la mayor especificidad es la RMRBF con la función de influencia de corte simple.

Tabla 3. Resultados de rendimiento en el grupo 1 (imágenes normales y anomalías benignas) y en el grupo 2 (cualquier clase de microcalcificación y anomalías malignas) mediante el uso de la colección de imágenes MIAS y diferentes redes neuronales.

Redes neuronales	Grupo 1			Grupo 2		
	Eficiencia	Incertidumbre	Error	Eficiencia	Incertidumbre	Error
SIMPLE RBF	49.93%	0.67%	49.40%	32.69%	0.00%	67.31%
MEDIANA RBF	62.77%	0.00%	37.23%	35.28%	0.00%	64.72%
α -TRIMMED MEAN EBF	52.70%	0.00%	47.30%	64.35%	0.00%	35.65%
RMRBF corte simple	70.53%	0.00%	29.47%	60.46%	0.00%	39.54%
RMRBF Tukey	63.95%	0.00%	36.05%	50.65%	0.00%	49.35%

Tabla 4. Sensitividad y especificidad de las redes neuronales implementadas.

Redes neuronales	Sensitividad	Especificidad
SIMPLE RBF	34.04%	50.00%
MEDIANA RBF	31.91%	62.82%
α -TRIMMED MEAN EBF	57.45%	52.56%
RMRBF corte simple	48.93%	70.51%
RMRBF Tukey	44.68%	64.10%

La figura 7 presenta los resultados visuales de la segmentación de imágenes de mamografía para los cinco casos de imágenes mostrados en la tablas 2 y 3.

La mayoría de las aplicaciones de análisis digital de mamografías se ha enfocado en la detección de microcalcificaciones, pues éstas son técnicamente más sencillas de detectar que otras masas con diversas distorsiones [40,41].

El método propuesto en este trabajo no sólo clasifica microcalcificaciones, sino que también, en los dos grupos propuestos, considera la clasificación de tumores cancerosos.

Comparando el resultado obtenido con otras referencias que usan la misma colección de imágenes se tiene lo siguiente:

La referencia [8] reporta una eficiencia en la fase de entrenamiento de 62.45% en clasificación de microcalcificaciones usando una red neuronal de retropropagación. El número de imágenes usado fue de 50.

La segmentación propuesta entrega buenos resultados para las imágenes de distintas resoluciones usadas en la etapa de prueba, aunque se puede apreciar que la segmentación por sí sola no proporciona datos suficientes para poder clasificar una imagen de mamografía.

Un problema importante a considerar es que las imágenes de mamografía presentan formas muy irregulares y que pueden causar resultados erróneos: falsos positivos, que es cuando se tiene como resultado que en una imagen existe un tumor canceroso o una microcalcificación cuando en realidad es una imagen sana o con anomalías benignas; y falsos negativos, que es cuando se tiene como resultado que una imagen es sana cuando en realidad en ella existen tumores cancerosos o microcalcificaciones. En la figura 8 se muestra una mamografía que la red propuesta clasificó correctamente, y la figura 9 muestra una mamografía que no fue clasificada adecuadamente.

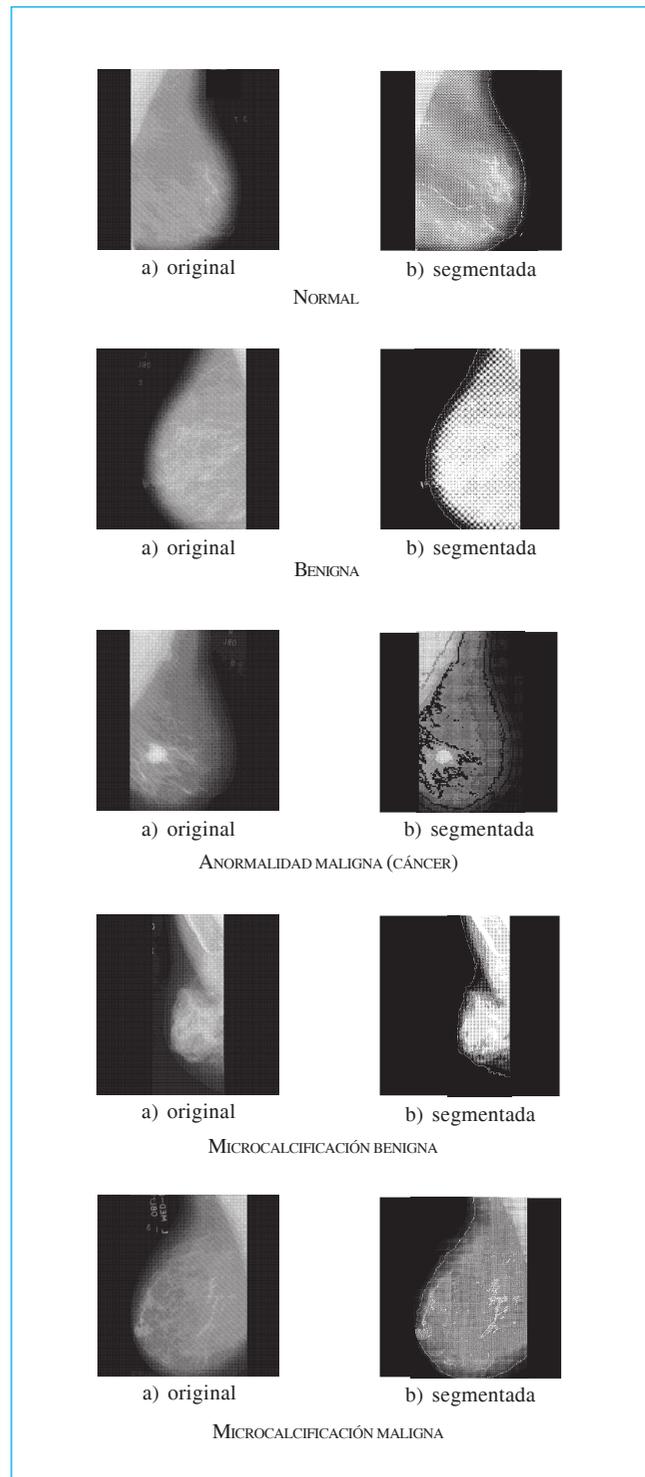


Fig. 7. Resultados visuales de la segmentación de imágenes de mamografía.

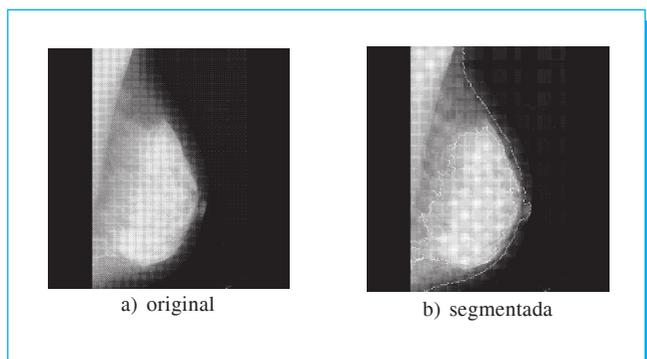


Fig. 8. Imagen de mamografía con un resultado correcto.

10. Conclusiones

Se propuso un nuevo tipo de red neuronal llamada función de base radial de rango tipo M (RMRBF) para la clasificación de imágenes de mamografía. Los resultados obtenidos con RMRBF propuesta son mejores que los resultados obtenidos mediante el uso de los algoritmos consultados, como se puede apreciar en la tabla 5. Desafortunadamente el error de clasificación se encuentra alrededor de un 35%, que es un porcentaje pensando en el propósito médico que se tiene. Para tratar de mejorar la eficiencia del sistema se debe de probar con otro método de segmentación de imágenes para obtener datos más precisos acerca de las regiones donde se pueden encontrar tumores cancerígenos o microcalcificaciones.

Agradecimientos

Los autores dan gracias al Instituto Politécnico Nacional por su apoyo para la realización de este trabajo.

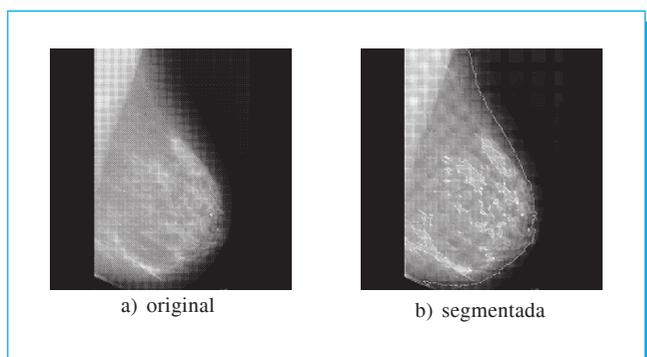


Fig. 9. Imagen de mamografía con un resultado incorrecto.

Tabla 5. Porcentaje de mejora en la eficiencia de la RMRBF con las funciones de influencia utilizadas con respecto a los algoritmos de la RBF consultados en la literatura.

Redes neuronales	SIMPLE RBF	MEDIANA RBF	α -TRIMMED MEAN RBF
RMRBF corte simple	24.90%	18.22%	4.80%
RMRBF Tukey	16.38%	9.70%	-3.72%

11. Referencias

- [1] M. Egmont-Petersen, D. de Ridder, H. Handels, Image processing with neural networks - a review, *Pattern Recognition*, vol. 35, 2279-2301, 2002.
- [2] G. Webb, *Introduction to Biomedical Imaging*, Wiley-IEEE Press, Hoboken, New Jersey, 2002.
- [3] J. S. Suri, R. M. Rangayyan, *Recent Advances in Breast Imaging, Mammography, and Computer-Aided Diagnosis of Breast Cancer*, SPIE Press, Bellingham, 2006.
- [4] M. Akay, *Nonlinear Biomedical Signal Processing, Volume 1: Fuzzy Logic, Neural Networks, and New Algorithms*, Wiley-IEEE Press, Hoboken, New Jersey, 2000.
- [5] D. L. Hudson, M. E. Cohen, *Neural Networks and Artificial Intelligence for Biomedical Engineering*, Wiley-IEEE Press, Hoboken, New Jersey, 1999.
- [6] R. Silipo, C. Marchesi, Artificial neural networks for automatic ECG analysis, *IEEE Trans. Signal Process.*, 46, 1417-1425, 1998.
- [7] P. Sajda, C. Spence, J. Pearson, Learning contextual relationships in mammograms using a hierarchical pyramid neural network, *IEEE Trans. Medical Imag.*, 21(3), 239-250, 2002.
- [8] S. Oporto-Díaz, R. Hernández-Cisneros, H. Terashima, *Detección de microcalcificaciones en imágenes de mamografías usando diferencia de filtros gaussianos optimizados*, XXX Conferencia Latinoamericana de Informática CLEI, 2004.
- [9] S. Haykin, *Neural Networks, a Comprehensive Foundation*, Prentice Hall, Upper Saddle River, NJ, 1994.
- [10] R. Rojas, *Neural Networks: A Systematic Introduction*, Springer-Verlag, Berlin, 1996.
- [11] P. Isasi-Viñuela, I. M. Galván-León, *Redes Neuronales Artificiales, un enfoque práctico*, Pearson-Prentice Hall, 2004.

- [12] C. Juárez, *Almacenamiento de señales de EEG y reconstrucción de sus características usando redes neuronales*, Tesis de Maestría, SEPI-ESIME-Culhuacán. 2003.
- [13] M.T. Musavi, W. Ahmed, K.H. Chan, K.B. Faris, D.M. Hummels, On the training of radial basis function classifiers, *Neural Networks*, vol. 5, 595-603, 1992.
- [14] Globocan 2002, Cancer incidence, mortality and prevalence worldwide, www.globocan.com.
- [15] www.tuotromedico.com/tema/cancer_de_mama.php#1.
- [16] www.educacionmedica.com.mx.
- [17] <http://www.maypo.com.mx/especial/oncologia/service/patol.html>.
- [18] <http://www.elmundo.es/elmundosalud/especiales/cancer>.
- [19] <http://www.tusalud.com.mx/130106.htm>.
- [20] Clínica virtual ginecológica de Buenos Aires, Argentina, www.members.tripod.com/~gineco.
- [21] <http://www.wiau.man.ac.uk/services/MIAS/MIAScom.html>.
- [22] R. C. González, R. E. Woods, *Tratamiento Digital de Imágenes*, Addison Wesley/Díaz de Santos, 1996.
- [23] G. Ritter, *Handbook of Computer Vision Algorithms in Image Algebra*, CRC Press, Boca Raton-New York, 2001.
- [24] H. R. Myler, A. R. Weeks, *The Pocket Handbook of Image Processing Algorithms in C*, Prentice Hall, 1993.
- [25] Matlab 7.0 Statistics Toolbox.
- [26] M. D. Buhmann, *Radial Basis Functions: Theory and Implementations*, Cambridge Monographs on Applied and Computational Mathematics, 2003.
- [27] J. Park, J.W. Sandberg, Universal approximation using radial basis functions network, *Neural Computation*, vol. 3, 246-257, 1991.
- [28] N. B. Karayiannis, G. Weiqun Mi, Growing radial basis neural networks: merging supervised and unsupervised learning with network growth techniques, *IEEE Trans. Neural Networks*, 8(6), 1492-1506, 1997.
- [29] N. B. Karayiannis, M. M. Randolph-Gips, On the construction and training of reformulated radial basis function neural networks, *IEEE Trans. Neural Networks*, 14(4), 835-846, 2003.
- [30] A.G. Bors, M. Gabbouj, Minimal topology for a radial basis function neural network for pattern classification, *Digital Signal Processing: a Review Journal*, vol. 4, 173-188, 1994.
- [31] M. Gómez-Martínez, *Teoría y simulación de redes neuronales artificiales*, Universidad Politécnica de Valencia, 1999.
- [32] I. Pitas, C. Kotropoulos, N. Nikolaidis, R. Yang, M. Gabbouj, Order statistics learning vector quantizer, *IEEE Trans. Image Process.*, 5(6), 1048-1053, 1996.
- [33] F. Gallegos, V. Ponomaryov, Real-time image filtering scheme based on robust estimators in presence of impulsive noise, *Real Time Imaging*, 8(2), 78-90, 2004.
- [34] F. Gallegos-Funes, V. Ponomaryov, J. De-La Rosa, ABST M-type K-nearest neighbor (ABSTM-KNN) for image denoising, *IEICE Trans. Fundam. Electron. Commun. Comput. Sci.*, E88-A(3), 798-799, 2005.
- [35] F. J. Gallegos-Funes, J. L. Varela-Benitez, V. I. Ponomaryov, Real-time image processing based on robust linear combinations of order statistics, *Proc. SPIE 6063, Real-Time Image Processing 2006*, 177-187, San Jose, USA, 2006.
- [36] <http://www.cmh.edu/stats/definitions/>.
- [37] A.G. Bors, I. Pitas, Median radial basis function neural network, *IEEE Trans. Neural Networks*, 7(6) 1351-1364, 1996.
- [38] A.G. Bors, I. Pitas, Optical flow estimation and moving object segmentation based on median radial basis function network, *IEEE Trans. Image Process.*, 7(5), 693-702, 1998.
- [39] A.G. Bors, I. Pitas, Object classification in 3-D images using alpha-trimmed mean radial basis function network, *IEEE Trans. Image Process.*, 8(12), 1744-1756, 1999.
- [40] P. R. Bakie, D. P. Brzakovic, Application of Neural Networks in Computer Aided Diagnosis of Breast Cancer, **IEEE Trans. Medical Imag.**, 2002.
- [41] J. A. Moreno-Escobar, F. J. Gallegos-Funes, V. I. Ponomaryov, Rank M-type radial basis functions network for medical image processing applications, *Proc. SPIE 6497, Image Processing: Algorithms and Systems V*, 6497-46, San Jose, USA, 2007, in press.

REDALYC: Red de revistas científicas de América Latina y el Caribe, España y Portugal

(UAEM)

www.redalyc.org

**El Instituto Politécnico Nacional
y la Escuela Superior de Ingeniería
Mecánica y Eléctrica
publican**

Científica

LA REVISTA MEXICANA DE INGENIERÍA ELECTROMECAÁNICA

Suscripciones y venta de ejemplares:

**Edificio 5, primer piso, Oficina de la
revista *Científica*, Sección de Posgrado
e Investigación de la ESIME Zacatenco,
Unidad Profesional Adolfo López Mateos,
Col. Lindavista, CP 07738, México, DF.**

Tel. 5729 6000

ext. 54518

correo electrónico:

revistacientifipn@yahoo.com.mx

revistaesimez@ipn.mx