

Clasificación de imágenes de mamografías según el tipo de tejido predominante usando redes neuronales artificiales

Samuel Oporto Díaz.

Centro de Sistemas Inteligentes, Instituto Tecnológico de Monterrey
ITESM, Campus Monterrey, Torre CETEC 5to piso.
Av. Eugenio Garza Sada 2501 Sur, Monterrey, N. L. 64849 México
Teléfono: +52 (81) 8158-2045, 8328-4379, Fax: +52 (81) 8328-4189
al977969@mail.myt.itesm.mx
soporto@aurigacorp.com.pe
<http://homepages.mty.itesm.mx/al977969/>

Resumen.

Una red neuronal artificial fue usada para clasificar imágenes digitalizadas de mamografías en función al tipo de tejido predominante. Se usaron dos métodos de extracción de características, el primero calcula parámetros estadísticos sobre pequeñas ventanas en la imagen, 16 ventanas en total, el segundo usa el histograma de cada imagen. Clasificar imágenes de mamografías según el tipo de tejido predominante es un paso previo al proceso de identificación de masas mamográficas sospechosas de ser cancerosas. Es relativamente sencillo identificar masas mamográficas sobre tejido adiposo, pero es extremadamente difícil hacerlo sobre tejido denso, debido a las pequeñas diferencias de densidad. Las masas mamográficas se pueden confundir con tejido denso debido a que también son radio opacas. Se diseñaron dos redes neuronales de tres capas cada una para el proceso de clasificación, el número de neuronas de la capa de entrada fue dependiente del número de características extraídas en cada método, el número de nodos de la capa intermedia fue obtenido por experimentación, y se usó una sola neurona en la capa de salida. Las imágenes fueron clasificadas en tres grupos: adiposo, fibroglandular y denso. Se evaluaron 322 mamografías en total, tomadas de The Mammographic Image Analysis Society (MIAS). Usando parámetros estadísticos se obtiene 57.13% de eficiencia y usando el histograma se obtiene 62.45% de eficiencia.

Cáncer de mamas, red neuronal, clasificación, densidad de la mama, tipo de tejido, histograma.

Abstract

Artificial neural networks have been used to classify mammograms, where this classification is carried out according to the type of predominant tissue. This process is used to detect mammographic cancer in women. This paper presents two different approaches for extracting relevant features in mammograms: the first one computes statistical parameters over a set of small windows in the image, whereas the second one uses the histogram of each image. Classifying images using the type of predominant tissue is a previous step required for the task to identify suspicious mammographic mass. This identification is relatively simple if performed over fatty tissue, but it is extremely difficult when done over dense tissue, because of the small differences in densities. Results show that the first approach obtains a 57.13% rate, while the histogram method performs slightly better with a 62.45% rate.

Breast cancer, neural network, classification, breast densities, tissue type, histogram

1. Introducción.

La detección temprana de cáncer de mama permite reducir la mortalidad por esta enfermedad, los métodos radiológicos apoyados en exámenes clínicos y la experiencia del especialista incrementan la efectividad del diagnóstico. Es difícil interpretar mamografías debido a las pequeñas diferencias de densidad en la imagen. [7]. La dificultad para el diagnóstico es proporcional a la densidad del tejido.

The American College of Radiology (ACR) Breast Imaging Reporting and Data System [8] menciona que la densidad mamaria puede tener valores entre 1 y 4: (1) predominantemente adiposo, (2) fibroglandular, (3) heterogéneamente denso y (4) extremadamente denso, ejemplos de estos tejidos se presentan en la figura 1.




Figura 1. Mamografías según el tipo de tejido: (a) predominantemente adiposo, (b) fibroglandular, (c) heterogéneamente denso y (d) extremadamente denso.

En este trabajo clasificamos imágenes según el tipo de tejido predominante [2], este es un paso previo para identificar masas mamográficas sospechosas. Diseñamos dos experimentos conducentes a identificar un método de clasificación apropiado para este problema, el primero usa parámetros estadísticos (media, varianza, asimetría y curtosis) obtenidos desde pequeñas ventanas en la imagen y el segundo usa directamente el histograma de la imagen.

En este documento los métodos para el pre-procesamiento y extracción de características se expone en la sección 2, en la sección 3 exponemos el método de clasificación de imágenes, en la sección 4 discutimos los resultados, finalmente en la sección 5 presentamos las conclusiones y recomendaciones del trabajo.

2. Pre-procesamiento y Extracción de Características.

2.1. Base de datos de mamografías.

Se evaluaron 322 mamografías tomadas de The Mammographic Image Analysis Society (MIAS) [9]. Muchos trabajos relacionados usaron esta base de datos [1], [4], [6]. Las imágenes fueron clasificadas en 3 grupos: adiposo, fibroglandular y denso, los grupos heterogéneamente y extremadamente densos se clasificaron como densos (ver tabla 1).

Tabla 1. Número de imágenes según el tipo de tejido.

Tipo de Tejido	Densidad	Cantidad
Adiposo	1	106
Fibroglandular	2	104
Denso	3	112
Total		322

2.2. Pre-procesamiento.

La fase de pre-procesamiento elimina los factores que pueden distorsionar el proceso de clasificación. En este caso aplicamos a cada imagen un barrido en ventanas de 8x8 pixels, convirtiéndolos a cero sí el promedio era menor que el umbral, en una segunda pasada se eliminaron todas las ventanas aisladas. Las imágenes originales en escala de grises fueron alineados para que orientasen apuntando el pezón al lado derecho.

2.3. Extracción de características.

Luego de la etapa de pre-procesamiento se extrajeron las características. Cada imagen fue considerada como una transacción en una tabla de datos.

2.3.1. Método basado en parámetros estadísticos.

Cada imagen se dividió en 16 pequeñas ventanas de 256 x 256 pixels. Desde ellas se extrajeron 4 parámetros estadísticos, en total 64 características por imagen:

1. Promedio. Calcula el promedio de los niveles del pixel de la ventana (\bar{x}).
2. Varianza. Calcula la varianza de los niveles de pixel de la ventana (σ).
3. Asimetría. Se calcula mediante la siguiente fórmula: $A = \frac{1}{N} \left(\frac{(x - \bar{x})}{\sigma} \right)^3$
4. Curtosis. Se calcula mediante la siguiente fórmula: $K = \frac{1}{N} \left(\frac{(x - \bar{x})}{\sigma} \right)^4 - 3$

2.3.2. Método basado en el histograma.

Se extrajo el histograma de la imagen en 96 rangos, el histograma nos proporciona el valor de probabilidad de que un determinado rango de niveles de gris (r_k) aparezca, donde la probabilidad es $p(r_k)$. La forma del histograma dependiendo del tipo de tejido es característico [5], esto se puede observar en la figura 2.




Figura 2. Histograma característico de una mamografía.

En la figura 3 presentamos tres ejemplos de histogramas según el tipo de tejido predominante.

Para propósitos de extraer características desde el histograma se eliminaron los 14 primeros rangos (15%), que corresponden preponderantemente a los pixels de fondo, quedando 82 rangos, los cuales fueron usados directamente como características de la imagen.




Figura 3. Ejemplos de histograma según el tipo de tejido: (a) predominantemente adiposo, (b) fibroglandular y (c) denso.

3. Clasificación de Imágenes.

En este trabajo se usó una red neuronal de tres capas con conexión hacia adelante usando un algoritmo de retro-propagación. Las redes neuronales han sido usadas en múltiples problemas de clasificación de patrones [3]. Los nodos están conectados en capas mediante pesos que son adaptados durante el proceso de entrenamiento. La red tiene tantas entradas como características tiene cada transacción, la capa intermedia tiene 48 nodos para el método basado en parámetros estadísticos y 30 nodos para el método basado en el histograma, éstos fueron obtenidos por experimentación, la capa de salida tiene un nodo que indica el tipo de tejido.

La data de entrada y de salida fue normalizada en el rango de $[-1, 1]$ antes de ser usada en el proceso de entrenamiento. Luego del proceso de entrenamiento los resultados obtenidos fueron de-normalizados para obtener los valores en su escala original.

4. Resultados Experimentales

Para el desarrollo de este trabajo se usaron 322 imágenes para ambos métodos, de ellas se seleccionó el 90% para entrenamiento y 10% para prueba. Se formaron 10 grupos de entrenamiento-prueba, cada uno con las 322 transacciones, la asignación del 10% para prueba se preparó seleccionando el primer 10% del primer grupo, el segundo 10% del segundo grupo y así sucesivamente hasta al décimo 10% del último grupo.

El detalle de los resultados para ambos experimentos se muestra en las tablas 2 y 3. Ellos corresponden a los mejores resultados en promedio obtenidos luego de sucesivas pruebas con el clasificador. Para el método basado en parámetros estadísticos se obtuvo un promedio de 57.13% de eficiencia en la clasificación, el máximo fue del 78.13% y el mínimo del 50%, la desviación estándar fue del 10.03%. Para el método basado en el histograma se obtuvo un promedio de 62.45% de eficiencia en la clasificación, el máximo fue del 75.76% y el mínimo del 42.42%, la desviación estándar fue del 7.99%.

Los resultados más estables y con el mayor promedio fueron obtenidos para el método basado en el histograma.

5. Conclusiones y Recomendaciones.

El método basado en histogramas obtiene mejores resultados en promedio que el método basado en parámetros, sin embargo el mejor resultado entre los grupos de entrenamiento-prueba fue obtenido para el método basado en parámetros (78.13%) y el peor resultado fue obtenido para el método basado en el histograma (42.42%). Los resultados se pueden

mejorar en la medida que se disponga de mayor cantidad de casos de entrenamiento, 322 imágenes es una cantidad relativamente pequeña para entrenar una red.

Considero recomendable hacer uso de otros métodos de clasificación para mejorar los ratios de éxito. Durante la etapa de pre-procesamiento se realizaron pruebas aplicando técnicas de “cropping” y mejoramiento de imágenes, pero no aportaron significativamente en el ratio de éxito.

Tabla 2.
Ratios obtenidos según el método basado en parámetros estadísticos.

Grupo	Porcentaje de Éxito
1	68.75
2	50.00
3	56.25
4	65.63
5	57.58
6	68.75
7	59.38
8	78.13
9	59.38
10	60.61
Promedio	57.13
STD	10.03

Tabla 3.
Ratios obtenidos según el método basado en el histograma.

Grupo	Porcentaje de Éxito
1	50.00
2	59.38
3	56.25
4	56.25
5	75.76
6	50.00
7	71.88
8	53.13
9	56.25
10	42.42
Promedio	62.45
STD	7.99

6. Reconocimientos.

El autor agradece al Dr. Hugo Terashima y al MSc. Rolando Hernández por sus aportes y sugerencias en el desarrollo de este proyecto.

Referencias

- [1] Antonie, M., Zaiane, O, Coman A. Application of data mining techniques for medical image classification. In In Proc. Of Second Intl. Workshop on Multimedia Data Minino (MDM/KDD'2001) in conjunction with Seventh ACM SIGKDD, pages 94–101, San Francisco, USA, 2001.
- [2] Egan R. Breast Imaging: Diagnosis and Morphology of Breast Diseases. Philadelphia. W.B. Saunders Company.; 1988.
- [3] Hayken, S. Neural networks: A comprehensive foundation. Nueva York: Macmillan; 1994.
- [4] Karssemeijer N, Brake G. Detection od Stellate Distortions in Mammograms. IEEE Transactions on Medical Imaging. Vol 15, No. 5, October 1996, Pp 611.
- [5] Pisano E., Cole E., et al. Image Processing Algorithms for Digital Mammography: A Pictorial Essay. Imaging & Therapeutic Technology. RadioGraphics 2000; 20: Pp.1479.
- [6] Rangayyan R.M, El-Faramawy N.M, Leo Desautels J.E, Alim O.A. Measures of Acutance and Shape for Classification of Breast Tumors. IEEE Transactions on Medical Imaging. vol. 16, no. 6, December 1997. Pp. 799.
- [7] Shepherd JA, Kerlikowske KM, Smith-Bindman R, Genant HK, Cummings SR. Compositional Breast Density as a Risk Factor. Breast Cancer Research. University of California, San Francisco; 2002, Vol 223, Nro. 2, Pp. 554.
- [8] http://www.acr.org/departments/stand_accred/birads-a.html
- [9] <http://www.wiau.man.ac.uk/services/MIAS/MIAScom.html>