

Detección de Microcalcificaciones en Imágenes de Mamografías Usando Diferencia de Filtros Gaussianos Optimizados

Samuel A. Oporto Díaz

Universidad Nacional de Ingeniería

Facultad de Ingeniería Industrial y de Sistemas

Av. Túpac Amaru 210 Rímac, Lima - Perú

Teléfono: +51(1) 481-1424, +51(1) 460-6246, Fax: +51(1) 332-2696

soporto@aurigacorp.com.pe

al977969@mail.mty.itesm.mx

Abstract

Since the microcalcifications are primary indicators of presence of cancer of breast, its detection is important to prevent and treat the disease. This paper proposes a method for detection of breast microcalcifications in X-ray mammograms using Difference of Gaussian filters (DoG), the microcalcifications are small objects, and they appear as small and bright regions with irregular shape in the breast. Their diversity in their shape, their orientation, their size and localization in a dense mammogram are the cause of the major difficulty for their classification. The DoG filter allows improving the contrast between the regions of interest and the background regions so that the local contrast is evident. In one first stage apply the DoG filter to extract the potential regions and in second stage, these regions are classified using the following features: area, mean gray level, mean background gray level, relative contrast and compactness, the experimental results indicate that the potential regions are right.

Keywords: Microcalcification, DoG Filter, Classification, Mammogram, Feature Extraction.

Resumen

Dado que las microcalcificaciones son indicadores primarios de presencia de cáncer de mama, la detección de ellos es importante para prevenir y tratar la enfermedad. En este documento propongo un método para la detección de microcalcificaciones en imágenes de mamografías usando diferencia de filtros gaussianos (DoG), las microcalcificaciones son pequeños puntos densos rodeados de tejido normal, que aparecen brillantes en la imagen, la detección es particularmente difícil si el tejido circundante también es denso. El filtro DoG permite mejorar el contraste entre las regiones de interés y las regiones del fondo buscando que los máximos locales sean evidentes. En una primera etapa aplico el filtro DoG para extraer las regiones potenciales y en una segunda etapa estas regiones son clasificadas usando características tales como área, promedio de gris, promedio de gris del fondo, contraste relativo y compacidad, los resultados experimentales indican que las regiones potenciales identificadas en la segunda etapa cubren efectivamente las microcalcificaciones detectadas previamente por el especialista.

Palabras claves: Microcalcificación, Filtro DoG, Clasificación, Mamografía, Extracción de Características.

1. INTRODUCTION

El cáncer de mama es una de las mayores causas de mortalidad en mujeres tiene un incidencia de 25 por cada 100,000 personas, el 99 % de los afectados son mujeres, el 30 % de los quistes mamarios son malignos. En ausencia de una efectiva prevención, el diagnóstico precoz es un importante medio para reducir la mortalidad. La tasa de mortalidad va de 10 % en el primer año al 80 % en 5 años luego del diagnóstico (Gordo [16]).

Las mamografías están entre las principales técnicas usadas para el diagnóstico de cáncer de mama (Gordo [16], Almenteros [5], Calero [8]). Las hallazgos que pueden ser observados en una mamografía son: masas, calcificaciones, áreas de densidades asimétricas, distorsiones arquitecturales, conductos lactíferos prominentes o retracción del pezón (De Paredes [10]), este trabajo se enfoca en la detección de microcalcificaciones.

Las microcalcificaciones son pequeñas acumulaciones de calcio de de 0.1 mm a 2 mm de ancho, ellos son indicadores favorables de presencia de cáncer de mama y son usadas frecuentemente para el diagnóstico del carcinoma intraductal o carcinoma ductal in situ, tienen probada capacidad para detectar estadios

tempranos de la enfermedad. Entre el 30 % al 50 % del cáncer de mama en el mundo es diagnosticado debido a las microcalcificaciones (UCHC [28]).

La sensibilidad de las mamografías (la fracción de cáncer de mama que es detectada mediante una mamografía) es del 85 % al 95 %, pero su valor predictivo comparado con la biopsia (la fracción de lesiones biopsiadas que probaron ser malignas) está en el rango de 15 % al 30 %. Del 2 % al 22 % de los resultados positivos obtenidos mediante una mamografía a la primera vez, requirieron nuevas evaluaciones para confirmar los resultados y del 12 % al 78 % requirieron una biopsia (Mushlin [21], Shen [25]). Las causas de esta baja sensibilidad (Ganott [15]) se deben al bajo contraste entre el tejido canceroso comparado con el tejido parenquimal normal, a su pequeño tamaño, a su variada morfología y a posibles deficiencias en el proceso de digitalización de la imagen

El doble diagnóstico ha mostrado que mejora la sensibilidad en a los más 15 % (Ciatto [7], Elmore [14]), pero como cada mamografía debe de ser revisado por dos radiólogos, este procedimiento es ineficiente dado que se reduce la productividad individual del especialista, una alternativa viable es que el otro radiólogo sea un computador actuando como la segunda opinión, así los resultados obtenidos por el computador pueden ser confirmados o rechazados (Anttinen [2], Thurfjell [27]).

Diferentes técnicas de procesamiento digital de imágenes han sido usadas para resolver el problema Norhayati [18], Bazzani [1], Bocchi [3], Campanini [4], Cheng [6], Yu [29], El-naqa [13].

En este trabajo intento demostrar que una técnica de detección automática de microcalcificaciones incrementa la probabilidad de encontrar casos de carcinomas malignos, al desempeñar el sistema una segunda opinión sobre el mismo caso. Con esta intención propongo un métodos para detectar microcalcificaciones (ver figura 1). El método está conformado por cuatro etapas: primero, el pre-procesamiento, permite eliminar aquellos elementos en la imagen que puede distorsionar el proceso de identificación de las microcalcificaciones, segundo, la detección de potenciales microcalcificaciones (señales), para este propósito se usa el filtro DoG, tercero, la extracción de características, permite extraer un conjunto de características desde cada señal y cuarto la etapa de clasificación, permite identificar si una señal obtenida corresponde o no a una microcalcificación individual, se usa una red neuronal para este propósito, obteniéndose finalmente las regiones con alta probabilidad de ser microcalcificaciones.




Figura 1: Esquema general del trabajo

Las imágenes de mamografías para este proyecto fueron tomadas de The Mammographic Image Analysis Society (MIAS [20]), la base de datos contiene 322 imágenes de las cuales 25 contienen microcalcificaciones, 13 son malignas y 12 son benignas, todas las imágenes son de 1024x1024 pixeles digitalizadas a 8 bits. Varios trabajos relacionados usaron esta base de datos: (Egan [12], Hayken [17], Karssemeijer [19], Rangarayanan [23]).

El problema que se pretende abordar en este trabajo de investigación es: Dado una base de datos de imágenes de mamografías, conteniendo algunas de ellas microcalcificaciones, cómo procesar las imágenes de tal forma que el conjunto de características a extraer maximice la eficacia en detectar las microcalcificaciones malignas. Para estimar el indicador de la eficacia del procedimiento propuesto, se aplica el estimador por validación cruzada de K conjuntos (Efron [11], Stone [26]), usado frecuentemente para probar esquemas de clasificación.

El resto del documento está organizado de la siguiente manera: en la sección 2 de este documento detallaremos la etapa de pre-procesamiento de la imagen, en la sección 3 exponemos el procedimiento usado para detectar, segmentar y selección de regiones consideradas como potenciales microcalcificaciones (señales), en la sección 4 veremos el procedimiento para extraer características desde cada señal identificada. sección 5 veremos el procedimiento de clasificación, en la sección 6 detallamos los resultados experimentales y en la sección 7 presentamos las conclusiones y recomendaciones del proyecto.

2. PRE-PROCESAMIENTO

Esta etapa tiene como finalidad eliminar aquellos elementos en la imagen que pueden distorsionar el proceso de identificar microcalcificaciones así como reducir el área de trabajo sólo a la región de la mama, para ello se aplica dos procedimientos: el filtro mediana y el corte automático, al procedimiento ingresa la

imagen original y se obtiene como resultados la imagen pre-procesada y una imagen espejo binarizada. Tiene tres parámetros: tamaño del filtro, tamaño de la ventana y umbral mínimo.




Figura 2: Diagrama de flujo. Etapa de Pre-Procesamiento

2.1. Filtro Mediana

El filtro 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 3×3 , la cual es centrada en cada pixel de la imagen reemplazando el pixel central por la mediana de los nueve pixeles que cubre la máscara, el tamaño de la ventana permite que se mantenga las características propias de la imagen y a la vez se eliminan las altas frecuencias. El filtro es superior a un filtro promediador, también usado para eliminar las altas frecuencias.

2.2. Corte Automático

La imagen es recortada para incluir sólo la región de interés, enfocando el proceso a la región que contiene a la mama y por lo tanto reduciendo el tiempo total de procesamiento, en el 90 % de las imágenes de la base de datos del MIAS la mama ocupa menos del 49 %.

El procedimiento se inicia generando un espejo de la imagen filtrada I , como si fuese una imagen binaria B , donde cada pixel representa una ventana de 16×16 en la imagen I , las dimensiones de esta imagen espejo son: $[filas_imagen/lado_ventana, columnas_imagen/lado_ventana]$

Luego, se calcula el promedio de niveles de gris de cada ventana y si este es mayor que cierto *umbral* se coloca 1 en B en caso contrario 0, el umbral se ha elegido mediante el desarrollo de experimentos ($umbral = 10$).

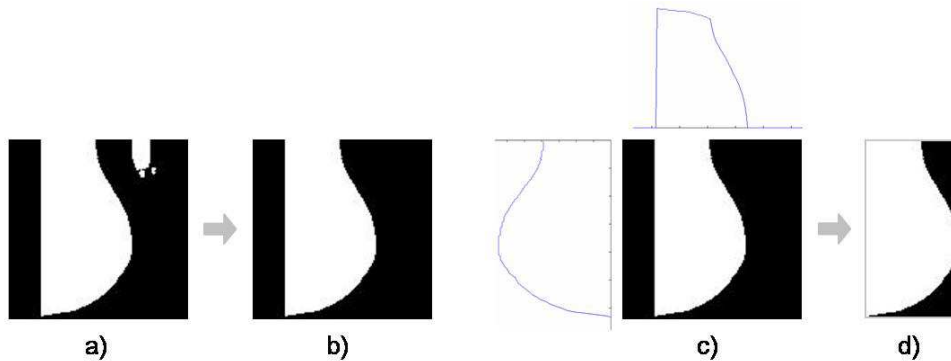


Figura 3: Resultados del corte automático. a). Imagen binaria (espejo), b). Imagen binaria sin regiones aisladas, c). Determinación de los extremos para ejecutar los cortes y d). Imagen binaria luego del corte horizontal y vertical

Para eliminar los elementos aislados en B , se calcula su centro de masa, bajo el supuesto que la mama contiene a su centro de masa (la mama es un objeto convexo). A partir del centro de masa se busca todos los pixeles conectados en vecindad V_4 , Este último procedimiento nos permite extraer solo la región conectada que contiene a la mama B' (ver la figura 3 b).

Para regenerar la imagen de la mama I' , se recorre la imagen binaria B' , si el pixel visitado es 1, se copia la ventana correspondiente de I a I' , el resto de regiones quedan en cero.

Finalmente para ejecutar el corte vertical se procede de la siguiente manera, se acumula verticalmente todos los pixels en B' , cada posición del vector indica el número de pixeles que existe en la columna, luego se hace una búsqueda desde los extremos y se extrae la posición donde se ubica el primer pixel con valor diferente de cero tanto a la izquierda como a la derecha (figura 3 c). A continuación se ejecuta el corte

considerando las regiones entre estas dos posiciones, la misma operación se sigue para el corte horizontal. Este último procedimiento se aplica tanto a la imagen binaria como a la imagen original.

3. DETECCIÓN DE MICROCALCIFICACIONES

Esta etapa tiene como propósito detectar las potenciales calcificaciones en la imagen y extraerlas en pequeñas ventanas de 9x9 píxeles. Dos métodos de selección son usados para descartar aquellas que pueden corresponder a ruido o a máximos locales no relacionados con calcificaciones.

El diagrama de flujo usado indicando, las entradas, salidas y parámetros necesarios se presenta en la figura 4, en total se aplica siete procedimientos: diferencia de filtros gaussianos, binarización global, etiquetado de regiones, selección de puntos por área mínima, segmentación de la imagen, selección de puntos por promedio de gris mínimo y binarización local.

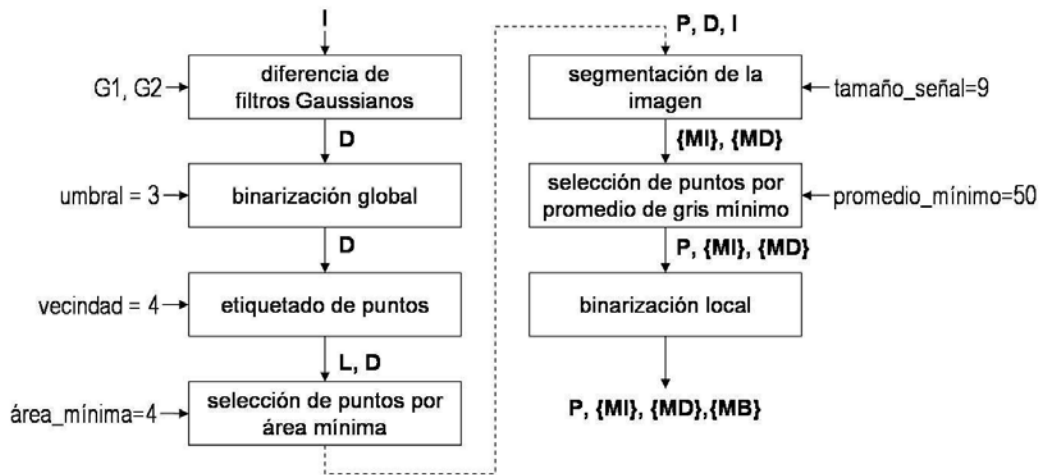


Figura 4: Diagrama de flujo. Etapa de detección de potenciales microcalcificaciones

En esta etapa los *puntos*, o regiones de alto contraste local todavía no pueden ser considerados como *microcalcificaciones*, deben de pasar por algunos procesos antes de adquirir tal categoría. En la figura 5 presentamos los diferentes nombres que adquieren en su evolución:

1. *Punto*. Son las las regiones brillantes detectadas en la imagen luego aplicar el filtro DoG y binarizar globalmente la imagen.
2. *Señal*. Son generados desde aquellos *puntos* que pasaron los dos procesos de selección (área mínima y gris mínimo) y luego de la binarización local.
3. *Calcificación*. Son aquellas *señales* que obtienen una ponderación positiva luego de pasar por un clasificador previamente entrenado.




Figura 5: Nombres que adquieren los objetos identificados en la imagen

3.1. Diferencia de filtros gaussianos

La distribución gaussiana en 2-D tiene la siguiente fórmula: $G(x, y) = ke^{(x^2+y^2)/2\sigma^2}$, donde k es la altura de la función y σ es la desviación estándar.

El filtro DoG es un filtro pasabandas, en el dominio del espacio, construido a partir de dos filtros Gaussianos simples. Estos dos filtros deben tener varianzas diferentes (ver figura 7). Al sustraer las dos imágenes obtenidas de aplicar cada filtro por separado, se obtiene una imagen que contiene un rango de frecuencia que interesa detectar, de la siguiente manera: $DoG(x, y) = k_1e^{(x^2+y^2)/2\sigma_1^2} - k_2e^{(x^2+y^2)/2\sigma_2^2}$




Figura 6: Ejemplo de una función de distribución gaussiana en 2-D

En este trabajo usamos dos filtros con desviaciones estándar: $\sigma_1 \approx ,0,7618$ para la máscara de 5x5 (ver 7.a) y $\sigma_2 \approx ,0,8226$ para la máscara de 7x7 (ver 7.b), dado que el filtro gaussiano es lineal se puede calcular la diferencia de las dos funciones gaussianas. Donde $k_1 = 9/53 \approx 0,1698$ y $k_2 = 16/140 \approx 0,1143$.




Figura 7: Máscaras Gaussianas usadas con el filtro DoG. a). Máscara 5x5 con $\sigma_1 \approx 0,7618$, b). Máscara 7x7 con $\sigma_2 \approx 0,8226$ y c). Máscara 7x7 del filtro DoG

3.2. Binarización global

Luego de restar las dos imágenes convolucionadas, procedemos a binarizarla, el objetivo del proceso de binarización es obtener una imagen en blanco y negro, ubicando un umbral adecuado (T) tal que aquellos pixeles menores que T correspondan a 0 y aquellos que tomen valores mayores o iguales que T correspondan a 1, donde R es la imagen obtenida luego de restar las dos imágenes convolucionadas y P_i es un pixel en la imagen.

$$D(P_i) = \begin{cases} 0 & \text{si } R(P_i) < T \\ 1 & \text{en otro caso} \end{cases} \quad (1)$$

El *umbral* de binarización para este problema fue asignado manualmente, dependiendo de los ensayos realizados ($umbral = 3$).

El histograma típico de la imagen generada por la aplicación del filtro DoG tiene un rango de valores entre $[-15, 30]$, existe fuerte acumulación de alrededor de los niveles 0, 1 y 2, por otro lado a medida que el nivel crece la frecuencia decrece, los niveles altos correspondan a puntos brillantes en la imagen.

En la figura 8, presentamos los resultados de aplicar diferentes valores para el *umbral*, así para $umbral > 5$, sólo se puede separar las regiones muy brillantes reduciendo la sensibilidad del proceso, se aplicó dos filtro gaussianos ($DoG(5x5) - DoG(7x7)$), la relación $\sigma_2/\sigma_1 = 0,8226/0,7618 = 1,08$.




Figura 8: Resultados obtenidos para diferentes niveles del umbral. DoG(5x5) - DoG(7x7)

3.3. Etiquetado de regiones

Luego de obtener la imagen binarizada procedemos a etiquetarla, el etiquetado permite identificar aquellas regiones conectadas, se usa cuando se requiere un análisis exhaustivo de la imagen (Fontoura [9], Russ[24]). Posteriormente estas regiones se convertirán en *puntos*.

El algoritmo toma la imagen binarizada D como entrada y la recorre pixel a pixel, de izquierda a derecha y de arriba hacia abajo, en cada pixel toma una decisión sobre el color a asignarle dependiendo de una mascara de tres pixeles conexos (ver 9), buscando todos los puntos conectados en vecindad V_4 . El número de colores obtenido es igual al número de regiones en la imagen.




Figura 9: Mascara usada en el algoritmo de coloreado de regiones

La variable que representa el pixel actual es P_c , el pixel ubicado encima es P_s y el pixel ubicado a la izquierda es P_i , la representación asegura la exploración exhaustiva. Si P_c es un pixel del fondo (0), no se realiza ningún cálculo, si P_c es un pixel que pertenece a un objeto (1) se toma una decisión basada en los valores de P_s y P_i , de la siguiente forma:

- Siembra nuevo color. Cuando P_s y P_i corresponden al fondo de la imagen se siembra un nuevo color, esto es que se ha encontrado un nuevo objeto, el contador de colores se incrementa en 1.
- Propagación lateral del color. Cuando el pixel superior es fondo y el pixel de la izquierda es objeto, se propaga el color del objeto al pixel actual.
- Propagación vertical del color. Cuando el pixel de la izquierda es fondo y el pixel superior es objeto, se propaga el color del objeto al pixel actual.
- Cruce de regiones. Cuando el ambos pixeles superior e izquierdo son objeto, se verifica sus colores, si son iguales, se propaga alguno de ellos, si son diferentes se aplica un algoritmo para unir regiones predominando el color de menor valor relativo y asignando este nuevo color al pixel actual.

3.4. Selección de puntos por área mínima

Este procedimiento elimina aquellas regiones que caen fuera de los rangos de área mínima y máxima y luego calcula el centro de masa de las regiones seleccionadas. El procedimiento recibe como entradas una imagen que contiene regiones con pixeles conectados *color* indicando el color que le corresponde y la imagen binarizada D , se obtiene como resultado listado de los centros de masa de cada una de las regiones P y la imagen binarizada D luego de ser depurada, tiene dos argumentos el *área_mínima* = 2 y el *área_máxima* = 77. Aquellas regiones seleccionadas serán consideradas como un *puntos* (ver figura 10).

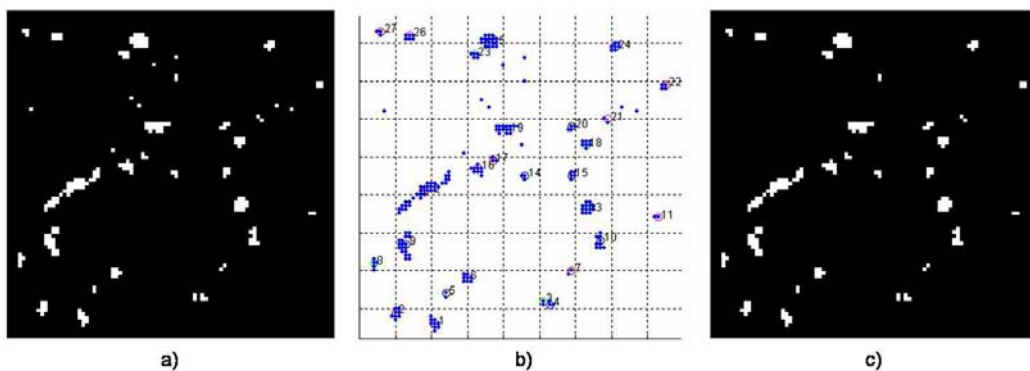


Figura 10: Etiquetado de regiones. a) Imagen Binarizada, b) Etiquetado de Regiones, c) Regiones seleccionadas como *puntos*

3.5. Segmentación

El procedimiento de segmentación extrae ventanas cuadradas de 9×9 , cuyo centro corresponde al centro de masa de cada uno de los *puntos* seleccionados en la etapa anterior. Extraer ventanas conteniendo los

puntos tiene dos finalidades, primero depurar aquellas regiones en la imagen cuyos promedios de gris sean menores que cierto umbral y segundo, aplicar una binarización local que permitirá obtener finalmente las *señales* que tienen alta probabilidad de ser *microcalcificaciones*.

El procedimiento recibe como entradas la imagen pre-procesada I , la imagen binarizada D , el listado de los centros de masa de cada región P , se obtiene como resultado la lista de *puntos* tomados de la imagen pre-procesada MI , lista de *puntos* tomados de la imagen binarizada MD y tiene un argumento el tamaño del lado de la ventana *tamaño_lado*.

El algoritmo para cada *punto*, corta en cada imagen un cuadrado cuyo centro es el centroide P de lado *tamaño_lado*.

3.6. Selección de puntos por gris mínimo

Este procedimiento permite seleccionar aquellos *puntos* que cumplen el criterio de promedio de gris mínimo, en este caso se ha colocado en 50, en una escala de [0, 255].

El procedimiento recibe como entradas el listado de los centros de masa de cada *punto* P , el listado de *puntos* tomados de la imagen pre-procesada MI , el listado de *puntos* tomados de la imagen binarizada MD , se obtiene las mismas salidas y tiene un argumento el el gris mínimo.

El área considera para el cálculo del promedio en cada ventana de MI depende de su mascara asociada MD (ver figura 11)




Figura 11: Calculo del gris promedio. a). niveles de gris (MI), b). mascara de la región de interés (MD), c). región de interés. Promedio total = 166, Promedio ROI = 175

El algoritmo depura aquellos puntos con promedio de gris menores que el gris mínimo, eliminándolos de las lista P , MI y MD .

3.7. Binarización local

El procedimiento de binarización local se aplica a cada una de las ventanas resultantes MI , con la finalidad de obtener las *señales* que luego pasarán al proceso de clasificación, bajo el supuesto de que histograma del *punto* seleccionado se puede dividir en dos regiones, el fondo y la *señal*.

El algoritmo de Otsu [22] es usado para calcular el umbral de binarización automáticamente, bajo el supuesto que el histograma es bimodal, el algoritmo consiste en buscar el mejor umbral T que separe las dos modas del histograma.

En la figura 12, se presenta dos casos en el que aplicamos el procedimiento de calculo de umbral, en el gráfico superior se presenta el histograma y la distribución de la función a maximizar ω (ver Otsu [22]), se traza una línea donde ω es máximo, se puede apreciar como que la línea trazada divide al histograma en dos campanas, correspondientes a las modas. Debajo de cada gráfica, presentamos 3 ventanas: la primera corresponde a la imagen pre-procesada, la segunda corresponde al *punto* y la tercera corresponde a la *señal* obtenida por este procedimiento.

4. EXTRACCIÓN DE CARACTERÍSTICAS

Esta etapa tiene por finalidad extraer características desde cada *señal* identificada en la etapa anterior, para luego clasificarlas como *calcificación* o como *no calcificación*. En posteriores trabajos estas características pueden ser usados para clasificar clusters de microcalcificaciones.

En total 5 características fueron extraídas: área, nivel de gris promedio, nivel promedio de gris del fondo, contraste relativo y compacidad

1. Área.

Calcula el área que ocupa la *señal* (número de pixels).




Figura 12: Ejemplos de cálculo del umbral de binarización local

$$\text{área} = \sum_{f=1}^{f=N} \sum_{c=1}^{c=N} D(f, c) \quad (2)$$

Donde $N = 9$ es el lado de la ventana y $D(f, c)$ es un pixel de la *señal* binarizada.

2. Nivel promedio de gris.

Obtiene el promedio de los niveles de gris de la *señal*, es un buen indicador del nivel de brillo.

$$\text{promedio_señal} = \frac{1}{\text{área}} \sum_{i=1}^{i=N} D(f, c) I(f, c) \quad (3)$$

Donde: $D(f, c)$ es un pixel de la *señal* binarizada y $I(f, c)$ es nivel de gris del pixel.

3. Nivel promedio de gris del fondo.

Obtiene el promedio de los niveles de gris del fondo.

$$\text{promedio_fondo} = \frac{1}{(N^2 - \text{área})} \sum_{i=1}^{i=N} (1 - D(f, c)) I(f, c) \quad (4)$$

4. Contraste relativo.

El contraste relativo se calcula con el promedio de gris de la calcificación y con el promedio de gris del fondo, proporciona una medida de contraste.

$$\text{contraste_relativo} = \frac{\text{promedio_señal} - \text{promedio_fondo}}{\text{promedio_señal} + \text{promedio_fondo}} \quad (5)$$

5. Compacidad.

La compacidad de una medida de qué tan compacta o aglutinada es la *señal*.

$$\text{compacidad} = \frac{\text{perímetro}^2}{\text{área}} \quad (6)$$

Los objetos que con bordes irregulares y por lo tanto grandes tendrán un valor alto de compacidad.

El menor valor que puede tomar la *compacidad* es 4π en el caso de un círculo perfecto.

5. CLASIFICACIÓN

En este trabajo usamos una red neuronal de tres capas con conexión hacia adelante usando un algoritmo de retro-propagación. La data de entrada y la data de salida fueron normalizadas antes de ser usadas en el proceso de entrenamiento. La red fue entrenada en 200 épocas.

5.1. Redes Neuronales Artificiales

Las redes neuronales artificiales han sido usadas en múltiples problemas de clasificación de patrones, donde se requiere aprender de la experiencia, de generalizar casos o de abstraer características esenciales a partir de información irrelevante. La red está conformada por muchos elementos computacionales (nodos) no lineales que operan en paralelo. Los nodos están conectados en capas mediante pesos que son adaptados en el proceso de entrenamiento. El algoritmo de retro-propagación es usado para entrenar los pesos de la red en dos fases, en la primera un patrón de entrenamiento es presentado propagándose a través de la red hasta la salida, donde se calcula el error (salida deseada Vs. salida obtenida); en la segunda fase estos errores se transmiten hacia atrás, hacia los nodos de la capa de entrada, recibiendo cada nodo un porcentaje del error. Basado en este error es que se ajustan los pesos de los nodos.

5.2. Arquitectura de la Red

Una red neuronal de retro-propagación de tres capas (ver figura 13), es usada en este trabajo, la red neuronal tiene tantas entradas como características tiene cada *señal*, la capa intermedia tiene 4 neuronas, la capa de salida tiene una neurona que indica si la *señal* corresponde o no a una *calcificación*. La función de transferencia usada en todos los nodos es la *tangente hiperbólica sigmoideal* y la función de medida de performance es el *error cuadrático medio*.




Figura 13: Arquitectura de la red neuronal

5.3. Normalización de la data

Dado que los datos utilizados como entrada a la red neuronal pueden cubrir diferentes rangos de valores, sus valores fueron normalizados en el rango $[-1, 1]$ antes de entrar al proceso de entrenamiento, para ello se usó una tabla de máximos y mínimos. Luego durante el proceso de prueba los datos de entrada también fueron normalizados usando la tabla, los datos de salida no fueron normalizados, dado que solo pueden tomar dos valores $[-1, +1]$.

6. RESULTADOS EXPERIMENTALES

Para estimar el indicador de efectividad del procedimiento propuesto, usaremos el estimador por validación cruzada de K conjuntos (Efron [11], Stone [26]), usado frecuentemente para probar esquemas de clasificación.

Se usaron 50 imágenes de 322 imágenes de la base de datos del MIAS, 25 de ellas con calcificaciones y 25 de ellas sin calcificaciones.

El diseño consiste en armar 10 experimentos, primero las 50 imágenes son divididas aleatoriamente en 10 conjuntos disjuntos conformados por 5 imágenes cada uno, luego cada experimento se construye tomando el primer conjunto como prueba y los 9 siguientes como entrenamiento, para el segundo experimento se toma el segundo conjunto como prueba y los restantes 9 conjuntos como entrenamiento, así hasta armar los 10 experimentos.

El detalle de los resultados se muestran en la tabla 1. Ellos corresponden a los mejores resultados obtenidos en promedio luego de sucesivas pruebas con el clasificador. El promedio de eficiencia es del 62.45 %.

Cuadro 1: Resultados Obtenidos

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

7. CONCLUSIONES Y RECOMENDACIONES

Los resultados experimentales obtenidos hasta el momento son del 62.45 % de eficacia, estos resultados se pueden mejorar en la medida que los parámetros usados en el sistema se optimicen.

El número de casos de entrenamiento es relativamente poco para obtener resultados determinantes, este problema se encuentra en proceso de solución. Se trata de ampliar el numero de muestras considerando las señal como muestras y no las imágenes como muestras, lo cual permitiría desde una imagen extraer un número grande de muestras.

En este momento estamos probando otros clasificadores para intentar mejorar la eficacia del sistema, tales como árboles de decisión y reglas de asociación.

Reconocimientos

El autor agradece al Dr. Hugo Terashima y al MSc. Rolando Hernández Centro de Sistemas Inteligentes, Instituto Tecnológico de Monterrey ITESM, por sus aportes y sugerencias en el desarrollo de este proyecto.

Referencias

- [1] R. Brancaccio R. Campanini N. Lanconelli A. Bazzani, D. Bollini and D. Romani. System for automatic detection of clustered microcalcifications in digital mammograms. *International Journal of Modern Physics C*, 11(5):901–912, 2000.
- [2] I. Anttinen, M. Pamilo, M. Soiva, and M. Roiha. Double reading of mammography screening films: one radiologist or two? *Clin Radiol*, (48):414–421, 1993.
- [3] L. Bocchi, G. Coppini, J.Ñori, and G. Valli. Detection of single and clustered microcalcifications in mammograms using fractals models and neural networks. *Med Eng Phys*, 26(4):303–12, 2004.
- [4] R. Campanini, A. Bazzani, A. Bevilacqua, D. Bollini, D.N. Dongiovanni, E. Iampieri, N.Lanconelli, A. Riccardi, M. Roffilli, and R. Tazzoli. A novel approach to mass detection in digital mammography based on support vector machines (svm). In *Proc. of IWDM2002*, pages 399–401, Bremen, Germany, June 22-25, 2002, 2002.
- [5] C.A. Castro, T.S. Pérez, J.M. González Barcena, and J. R. Santiago. Interferón y cáncer de mama avanzado. *Revista Cubana de Oncología*, 15(2):89–94, 1999.
- [6] H. D. Cheng, Y.M. Lui, and R. I. Freimanis. A novel approach to microcalcification detection using fuzzy logic technique. *IEEE Transactions on Medical Imaging*, 17(3):442–450, 1998.
- [7] S. Ciatto, MR. Del Turco, G. Risso, S. Catarzi, R. Bonardi, V. Viterbo, P. Gnutti, B. Guglielmoni, L. Pinelli, A. Pandiscia, F.Ñavarra, A. Lauria, R. Palmiero, and PL. Indovina PL. Comparison of standard reading and computer aided detection (cad) on a national proficiency test of screening mammography. *European Journal of Radiology*, 45(2):135–8, 2003.

- [8] F. Calero Cuerda. Factores de riesgo en cancer de mama. *Progresos de Obstetricia y Ginecología*, 42(90):9065–9088, 1999.
- [9] L. da Fontoura and R. Marcondes. *Shape Analysis and Classification. Theory an Practice*. CRC Press, 2001.
- [10] S. De Paredes E. *Radiographic breast anatomy: Radiologic signs of breast cancer, Syllabus: a categorical course in physics - Technical aspects of breast imaging*. M Yaffe ed., Oak Brook, IL, RSNA Publications, 1993.
- [11] B. Efron and R. Tibshirani. An introduction to the bootstrap. *Journal of the National Cancer Institute*, 94(18):1373–80, 2002.
- [12] R. Egan. *Breast Imaging: Diagnosis and Morphology of Breast Diseases*. Philadelphia. W.B. Saunders Company, 1988.
- [13] I. El-Naqa, Y. Yang, M.Ñ. Wernick, N. P. Galatsanos, and R. M. Nishikawa. A support vector machine approach for detection of microcalcifications. *IEEE Transactions on Medical Imaging*, 21(12):1552–1563, 2002.
- [14] J.G. Elmore, D. L. Miglioretti, L. M. Reisch, M. B. Barton, W. Kreuter, C. L. Christiansen, and S. W. Fletcher. Screening mammograms by community radiologists:variability in false-positive rates. *Journal of the National Cancer Institute*, 94(18):1373–80, 2002.
- [15] Marie A. Ganott, MD, Kathleen M. Harris, MD, FACR, Herta M. Klamann, RT(R)(N)(M), RDMS, RDCS, and Terri L. Keeling. Analysis of false-negative cancer cases identified with a mammography audit. *The Breast Journal*, 5(3):166, 1999.
- [16] J.M. Alonso Gordo. Cancer de mama. manejo desde atención primaria. *SEMERGEN*, 26:491–501, 2000.
- [17] S. Hayken. *Neural networks: A comprehensive foundation*. Nueva York: Macmillan, 1994.
- [18] Norhayati Ibrahim, Hiroshi Fujita, Takeshi Hara, and Tokiko Endo. Automated detection of clustered microcalcifications on mammograms: Cad system application to mias database. *Physics in Medicine and Biology*, 42(12):2577–2589, 1997.
- [19] N. Karssemeijer and G. Brake. Detection od stellate distortions in mammograms. *IEEE Transactions on Medical Imaging*, 15(5):611, 1996.
- [20] MIAS. <http://www.wiau.mam.ac.uk/services/mias/miasweb.html>. 2002.
- [21] AI. Mushlin, RW. Kouides, and DE. Shapiro. Estimating the accuracy of screening mammography: a meta-analysis. *Am J Prev Med*, 14(2):143–53, 1998.
- [22] N. Otsu. A thresholding selection method from gray-level histogram. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1):62–66, 1979.
- [23] R. M. Rangayyan, N. M. El-Faramawy, J.E. Leo Desautels, and O. A. Alim. Measures of accurate and shape for classification of breast tumors. *IEEE Transactions on Medical Imaging*, 16(6):799–810, 1997.
- [24] J. C. Russ. *The Image Processing Handbook Third Edition*. CRC Press, IEEE Press, 1999.
- [25] Y. Shen and M. Zelen. Screening sensitivity and sojourn time from breast cancer early detection clinical trials. mammograms and physical examinations. *Journal of Clinical Oncology*, 19(15):3490–9, 2001.
- [26] M. Stone. Cross-validation choice and assessment of statistical predictions. 1993.
- [27] EL. Thurffjell, KA. Lernevall, and AAS. Taube. Benefit of independent double reading in a population-based mammography screening program. *Radiology*, (191):241–244, 1994.
- [28] UCHC. radiology.uchc.edu. 2004.
- [29] Songyang Yu and Ling Guan. A cad system for the automatic detection of clustered microcalcifications in digitized mammograms films. *IEEE Transactions on Medical Imaging*, 19(2):115–126, 2000.