

Sistema de Decisión Basado en Lógica Difusa para la Detección de Distorsiones de la Arquitectura de la Glándula Mamaria

Decision System Based on Fuzzy Logic for Detection of Architectural Distortion

Duván Alberto Gómez Betancur

MSc (c) Ingeniería – Ingeniería de Sistemas,
Universidad Nacional de Colombia
Investigador Grupo GIDIA, Universidad Nacional de Colombia
Medellín, Colombia
dagomezbe@unal.edu.co

John Willian Branch Bedoya

Ph.D. Ingeniería – Ingeniería de Sistemas,
Universidad Nacional de Colombia
Profesor Asociado, Investigador Grupo GIDIA,
Universidad Nacional de Colombia
Medellín, Colombia
jwbranch@unal.edu.co

Resumen— La distorsión de la arquitectura es un cambio anormal del tejido de la glándula mamaria con la consiguiente formación de lesiones finas y espiculadas que no están asociadas a la presencia de una masa. La distorsión es el tercer hallazgo mamográfico más común y por la dificultad de su detección es el primer causante de falsos negativos en los diagnósticos. Este artículo presenta la planeación, implementación y pruebas de un método que sirve como soporte para la detección de distorsiones de la arquitectura de la glándula mamaria a partir de imágenes de radiología de mama. El método asiste a los especialistas en el proceso de decisión diagnóstica como segundo intérprete en el análisis de mamografías mediante la integración de cuatro etapas principales que van desde el pre-procesamiento de la imagen hasta la clasificación final con base en las características de textura de las regiones de interés extraídas.

El método presentado fue validado mediante el análisis de imágenes mamográficas de la base de datos DDSM (Digital Data base for Screening Mammography), que logra valores de precisión general hasta de un 90.7% lo cual lo convierte en una base importante para la disminución del número de falsos negativos en la detección de distorsiones de la arquitectura de la glándula mamaria.

Palabras clave— Cáncer de mama, distorsión de la arquitectura, mamografía, procesamiento digital de imágenes, diagnóstico asistido por computador.

Abstract— Architectural distortion is an abnormal change in the mammary gland tissue with the consequent formation of thin and spiculated lesions that are not associated with the presence of a mass. It is the third most common mammographic finding and because of its subtlety it is the first cause of false-negative findings on screening mammograms. This paper presents the design, implementation and test of a new method that serves as support for the detection of architectural distortion in the mammary gland from breast radiology images. The method proposed here assists the specialists in the diagnosis of breast cancer through four main phases, which encompass from the preprocessing to the classification of regions of interest using a classifier based on fuzzy logic.

The method described in this paper was validated through the analysis of mammographic images from DDSM (Digital Database for Screening Mammography) obtaining values of 90.7% in the overall accuracy. This result is a very important contribution and encourages the research in order to reduce the high number of misdiagnoses that are currently presented and lead to the high rates of morbidity from breast cancer.

Keywords— Breast cancer, architectural distortion, mammography, digital image processing, computer aided diagnosis.

I. INTRODUCCIÓN

En los ambientes médicos las imágenes juegan un rol prominente en el diagnóstico y tratamiento de enfermedades, debido a que permiten que los especialistas obtengan información vital al observar el interior del cuerpo humano de una forma no invasiva, y favorecer el diagnóstico temprano de patologías para que puedan ser tratadas de manera efectiva [1].

Dentro de esas patologías que pueden ser diagnosticadas y tratadas se encuentra el cáncer que es una enfermedad que se presenta como resultado de mutaciones o cambios anormales en los genes responsables de regular el crecimiento de las células.

Uno de los tipos de cáncer más comunes es el cáncer de mama que es una patología producto del crecimiento no controlado de las células de la mama que forma un tumor maligno.

En el mundo el cáncer de mama es una patología cada vez más común entre la población femenina, por ejemplo para el caso de Estados Unidos y Canadá, se estima que 1 de cada 8 mujeres sufrirá la enfermedad a lo largo de su vida, y

en el 2006 se calcularon 212.920 nuevos casos de cáncer de mama y 41.430 muertes producidas por la enfermedad.

Los datos estadísticos sobre cáncer de mama en Colombia son difíciles de obtener y se encuentran probablemente sesgados; sin embargo, es evidente un aumento progresivo en la incidencia del carcinoma mamario, especialmente en las ciudades más densamente pobladas. Para el año 2009 se reportaron 551 nuevos casos de cáncer de mama [2], lo cual comprueba el incremento de esta patología en los últimos años en el país, convirtiéndose en la primera causa de muerte por cáncer entre las mujeres.

El cáncer de mama se ha convertido entonces en un serio problema de salud pública que ha despertado el interés de comunidades científicas mas cuando se sabe que si se detecta a tiempo, se puede evitar el desenlace fatal de la enfermedad.

Para la detección temprana del cáncer de mama existen diferentes exámenes o métodos clínicos como la resonancia magnética, la ecografía, la biopsia, la tomografía computarizada y la biopsia de ganglio linfático, entre otros. Sin embargo, la mamografía es el examen más eficaz para la detección temprana del cáncer de mama.

Los hallazgos clínicos más comunes que indican el desarrollo de una patología cancerígena en la mama y que pueden identificarse a través de la mamografía son: masas, microcalcificaciones, distorsiones de la arquitectura y asimetrías de densidad.

Las *calcificaciones* son hallazgos muy comunes en una mamografía y son consecuencias de diminutos depósitos de calcio en el tejido mamario. En cuanto a las *masas* debe describirse su tamaño, forma, márgenes y calcificaciones asociadas en los casos en los que la masa se presente con calcificaciones. Por su parte la *asimetría de densidad* es la presencia de tejido glandular en una parte de la mama y que no se presenta con la misma localización en la mama contralateral, puede verse como una opacidad similar en las dos proyecciones de una mama pero no tiene características de una masa [3].

La información restante de este artículo se estructura en cuatro secciones. En la 2 se explica la distorsión de la arquitectura de la glándula mamaria. En la 3 se describe el método propuesto. En la 4, se evalúa el método y se presentan los resultados obtenidos y en la 5 se dan las conclusiones

del método y se dejan las posibles direcciones para la investigación futura.

II. DISTORSIÓN DE LA ARQUITECTURA

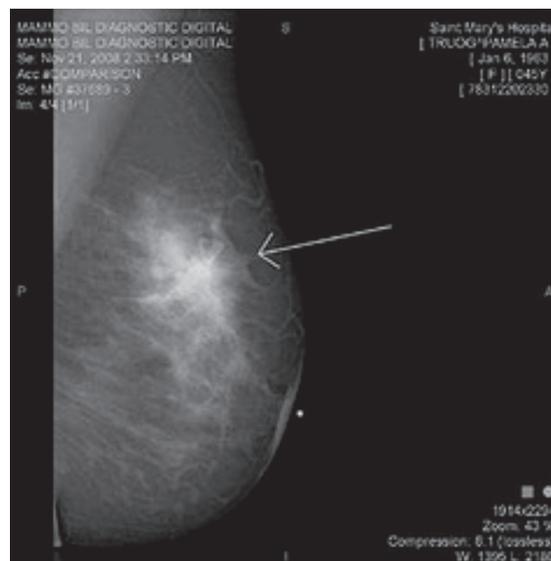
La distorsión de la arquitectura es un cambio anormal del tejido de la glándula mamaria con la consiguiente formación de lesiones finas y espiculadas que no están asociadas a la presencia de una masa.

En el BI-RADS (*Breast Imaging Reporting and Data System*) [4] se define la distorsión de la arquitectura como el hallazgo en el cual la arquitectura normal (de la mama) se distorsiona con masas no definidas visibles. Esto incluye lesiones espiculadas y la retracción focal o distorsión en el borde del parénquima.

La distorsión de la arquitectura hace referencia entonces a la distorsión del parénquima de la mama pero sin presencia de masas ni aumento en la densidad. Se trata del tercer hallazgo más común en mamografías, asociado a estados de cáncer aún no palpables [5] y el primer causante de falsos negativos [6] pues debido a su sutileza y variabilidad, la distorsión de la arquitectura es omitida y puede pasar como tejido normal superpuesto en el momento de la valoración de las mamografías de tamizaje.

Debido a que el cáncer de mama interrumpe la arquitectura normal del parénquima, la distorsión es considerada un signo temprano de cáncer [7].

Fig. 1. MAMOGRAFÍA CON PRESENCIA DE DISTORSIÓN DE LA ARQUITECTURA DE LA GLÁNDULA MAMARIA



Fuente: Imagen tomada de [8]

Como se puede observar en la Fig. 1 la distorsión de la arquitectura en la mamografía se presenta como una anomalía en la que los tejidos circundantes de la mama parecen ser dirigidos hacia un punto focal interno.

De acuerdo con [9] en más de la mitad de los casos en los cuales se han encontrado signos de distorsión de la arquitectura se comprueba posteriormente malignidad en el seno. Sin embargo, por la dificultad en la detección de la distorsión de la arquitectura, se estima que esta anomalía es la causa de entre el 12% y el 45% de los casos de cáncer omitidos o mal interpretados [10].

Si bien es cierto que son muchos los trabajos que se pueden encontrar en sistemas CAD (*Computer-Aided Diagnosis*) para el caso de cáncer de mama, también es cierto que mientras la mayoría han sido dirigidos a la detección y análisis de calcificaciones y masas [11][12][13][14], relativamente pocos han sido publicados en la detección de la distorsión de la arquitectura de la glándula mamaria.

Entre los trabajos más destacados para la detección de la distorsión de la arquitectura de la glándula mamaria se encuentra [15] donde se usa morfología matemática para detectar distorsión alrededor de la línea de piel y un índice de concentración para detectar distorsión de arquitectura al interior de la glándula mamaria obtenido tasas de sensibilidad superiores al 80%; en [16] se desarrolló un método para detectar masas y distorsión de arquitectura al localizar puntos rodeados por capas concéntricas. En [17] se presenta una investigación para la caracterización de la distorsión de arquitectura con la dimensión fractal de Hausdorff y un clasificador SVM (*Support Vector Machine*) para distinguir entre ROI (Regiones de Interés) con distorsión de arquitectura y aquellas con patrones mamográficos normales, una clasificación con una precisión del 72.5% fue obtenida con un conjunto de 40 ROI.

También se han publicado trabajos en los cuales a partir de filtros Gabor y análisis de dimensión fractal se proponen métodos para detectar candidatos iniciales de distorsión de la arquitectura en mamografías [18],[19].

Rangayyan en [20] con características de textura de Haralick para la detección de distorsiones de la arquitectura de la glándula mamaria, comparó diferentes técnicas de clasificación. A partir de 4.224 ROI obtuvo una sensibilidad de 76% con un clasificador bayesiano, 73% con análisis discriminante lineal, 77% con una red neuronal artificial basada en funciones de base radial y una sensibilidad de un 77% con SVM.

III. SISTEMA DE DECISIÓN BASADO EN LÓGICA DIFUSA

En 1965 Lotfi A. Zadeh, propuso la lógica difusa como una herramienta para el control y los sistemas expertos. Se trata de un método para el razonamiento con expresiones lógicas que describen las pertenencias a los conjuntos difusos, entendidos como un instrumento para la especialización de lo bien que un objeto satisface una descripción vaga [21].

El uso de la lógica difusa resulta bastante útil en problemas con alto grado de incertidumbre y donde se necesita usar el conocimiento de un experto que utiliza conceptos ambiguos o imprecisos, por ello se ha visto un auge en su uso en sistemas de reconocimiento de patrones y visión por computador.

En [22] se plantea un ejemplo de caso de un clasificador difuso en el que se tiene un problema de clasificación n -dimensional con M clases y m patrones de entrenamiento $x_p = (x_{p1}, x_{p2}, x_{p3}, x_{p4}, \dots, x_{pn})$ para $p=1,2,3,\dots,m$ los atributos de los patrones están normalizados $[0,1]$ y se utilizan reglas difusas del tipo if-then como base del sistema de clasificación difuso:

Regla R_j : Si x_1 es A_{j1} y...y x_n es A_{jn} entonces Clase C_j con CF_j
para $j=1,2,\dots,N$

donde R_j es la regla j -ésima, $A_{j1} \dots A_{jn}$ son funciones de pertenencia de los conjuntos difusos en el intervalo $[0,1]$, C_j es la clase, dentro del conjunto de las M clases, consecuente, y CF_j es el grado de certeza de la regla if-then difusa R_j .

En [23] se demostró que la inclusión del grado de pertenencia o certeza en la creación de las reglas difusas if-then permite generar sistemas de clasificación comprensivos con un buen comportamiento.

A. Características de Textura

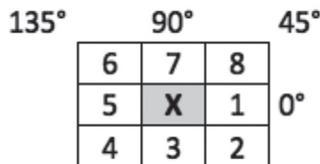
En un gran número de aplicaciones de procesamiento digital de imágenes la textura es una de las características más importantes y utilizadas para la recuperación de información y la identificación de objetos o regiones al interior de la imagen.

Muchos son los trabajos y las aproximaciones que se han hecho para la descripción automática o semi-automática de las características de textura presentes en una imagen. Un ejemplo claro de dichas aproximaciones es el propuesto por Haralick[24] quien, basado en la premisa que la textura y el tono conservan una relación inextricable entre ellos, propone catorce características para describir la textura de los objetos o regiones presentes en una imagen.

Para Haralick, las propiedades de tono y textura están siempre presentes en una imagen, y el procedimiento que sugiere para obtener las características de textura se basa en la presunción de que la información de textura de una imagen definida, está contenida en la totalidad o por lo menos el promedio de la relación espacial que los tonos de grises de la imagen tienen el uno con el otro. Es decir, esa información de textura está adecuadamente contenida en un conjunto de matrices espacio-dependientes de los tonos de gris, las cuales son calculadas para diferentes ángulos y distancias de vecindad en los pixeles de la imagen y son conocidas como GCM (*Gray level Co-Occurrence Matrix*).

En la Fig. 2 se observa la vecindad más cercana (distancia $d=1$) para cualquier punto dentro de la imagen, exceptuados los puntos ubicados en las filas y columnas de los extremos. La vecindad-8 es utilizada para la definición de las matrices GCM en la propuesta de Haralick.

Fig. 2. VECINDAD-8 DE UN PÍXEL EN UNA IMAGEN



Fuente: Haralick[24].

Considerada la vecindad-8 que se observa en la Fig. 2 la GCM se construye con las probabilidades de ocurrencia de un par de niveles de gris

(l_1, l_2) separados por una distancia d en un ángulo θ [24]. Es decir, dada una imagen I con N niveles de gris, su GCM para un ángulo θ , se construye con N filas y N columnas, y en cada intersección fila-columna se totaliza el número de veces dentro de la imagen en las cuales un punto $I(x,y)$ con un nivel de gris l_1 (de acuerdo con la columna de la GCM) posee un vecino en una distancia d y en la dirección θ con un nivel de gris l_2 (de acuerdo con la fila de la GCM).

A partir de la GCM, Haralick propone catorce características de textura: energía, contraste, correlación, suma de cuadrados, momento de diferencia inversa, suma promedio, suma de varianzas, suma de entropía, entropía, diferencia de varianzas, primera medida de información de correlación, diferencia de entropía, segunda medida de información de correlación y máximo coeficiente de correlación.

En este trabajo se utilizan sólo cinco características de textura: energía, contraste, suma promedio, momento de diferencia inversa y diferencia de varianzas, ya que de acuerdo con [20] son esas características las que empaquetan no sólo la mayor cantidad de información visual, sino también la más relevante para la descripción de la textura de las regiones de interés detectadas al interior de la glándula mamaria en la imagen mamográfica.

Las expresiones matemáticas para las cinco características de textura utilizadas son:

TABLA I

Nomenclatura utilizada para las ecuaciones de las características de textura de Haralick utilizadas

$p(i,j)$	Entrada (i,j) -ésima en la GCM, $=P(i,j)/R$
$p_x(i)$	i -ésima entrada de la GCM obtenida sumando las filas de $p(i,j)$, $= \sum_{j=1}^{N_g} p(i,j)$
$p_y(j)$	j -ésima entrada de la GCM obtenida al sumar las columnas de $p(i,j)$, $= \sum_{i=1}^{N_g} p(i,j)$
N_g	Número de niveles de gris presentes en la imagen

Energía:

$$f_1 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \{p(i,j)\}^2 \quad (1)$$

Contraste:

$$f_2 = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j) \right\}_{|i-j|=n} \quad (2)$$

Suma promedio:

$$f_3 = \sum_{i=2}^{2N_g} i p_{x+y}(i) \quad (3)$$

donde

$$p_{x+y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j), k = 2,3, \dots, 2N_g \\ i + j = k$$

Momento de diferencia inversa:

$$f_4 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1 + (i-j)^2} p(i,j) \quad (4)$$

Diferencia de Varianzas:

$$f_5 = \text{varianza of } p_{x-y} \quad (5)$$

donde

$$p_{x-y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j), k = 0,1, \dots, N_g - 1 \\ |i-j| = k$$

Algunas de las características de textura de Haralick tienen interpretación física directa con respecto a la textura de la imagen, por ejemplo, para cuantificar la suavidad y la tosquedad de la misma. Aunque otras características no poseen dicha propiedad directa, ellas contienen y codifican información visual relativa a la textura con un alto grado discriminatorio.

La característica de Energía se trata del cálculo del segundo momento angular y representa una medida de la "suavidad" de la imagen, es decir, si todos los píxeles comprendidos en la región de análisis poseen el mismo nivel de gris, entonces el valor de Energía será igual a 1 mientras que si se tienen todas las posibles parejas de niveles de gris con igual probabilidad, entonces, la región será menos suave y por lo tanto el valor de Energía será menor.

El Contraste de la imagen es una medida de la variación local de los niveles de gris de la ima-

gen. De hecho, $\sum_i \sum_j p(i,j)$ es el porcentaje de parejas de píxeles cuya intensidad difiere por n . La dependencia n_2 incrementa aún más las grandes diferencias; por lo tanto, el valor de esta característica toma valores altos para imágenes con alto contraste.

El Momento de Diferencia Inversa es una característica de textura que toma valores altos para imágenes con bajo contraste debido a la dependencia inversa $(i-j)^2$.

La Diferencia de Varianza es una medida de cuán grande es la variación existente en las magnitudes de las transiciones de intensidad. Por ejemplo, si hay distribución equilibrada de las magnitudes de las transiciones de intensidad, entonces el valor de diferencia de varianza será bajo, mientras que si ciertas magnitudes de las transiciones de intensidad ocurren con mucha más frecuencia de lo que otras transiciones entonces se esperaría un valor de diferencia de varianza más alto.

La Suma Promedio es una medida de la relación entre zonas claras y densas de la imagen, es decir, es una medida del promedio de los niveles de gris presentes en las zonas de interés detectadas al interior de la glándula mamaria.

Sin embargo, la interpretación de cada una de las características mencionadas y su representación desde la concepción del sistema de visión humano es producto de las pruebas que se realicen para cada aplicación en particular[24][25][26].

Con el cálculo de las cinco características de textura de Haralick mencionadas se generan las medidas suficientes para alimentar el clasificador difuso de tal manera que se pueda discriminar cada ROI en una de las dos posibles clases definidas en la investigación: normal o anormal.

B. Sistema de decisión difuso

Los valores calculados de las características de textura de Haralick de las ROI detectadas se utilizan para la identificación, clasificación y determinación final de las áreas con presencia de distorsión de la arquitectura de la glándula mamaria mediante un clasificador basado en lógica difusa.

El método propuesto en este documento propone el uso de la lógica difusa ya que ésta presenta diferentes ventajas pues al utilizar términos lingüísticos permite plantear el problema en los mismos términos en los que lo haría un experto humano.

Asimismo, el éxito de la lógica difusa radica en el hecho de que el mundo es difuso y, por lo tanto, podría pensarse que no tiene sentido buscar la solución a un problema no perfectamente definido por medio de un planteamiento matemático muy exacto, cuando es el ser humano el primero que razona con la inexactitud.

Los componentes principales de un sistema de decisión difuso son: los conjuntos difusos, las funciones de membresía o pertenencia difusas y las reglas difusas. Cada conjunto difuso tiene una función de pertenencia correspondiente. Los rangos de los valores de la función de pertenencia oscilan entre cero y uno y pueden ser considerados como un grado de verdad. Normalmente las funciones de pertenencia de los sistemas de clasificación difuso son de forma trapezoidal, triangular y curva S [27].

En el método propuesto en este documento, a diferencia de las funciones de pertenencia tradicionalmente utilizadas en la literatura, se utilizan funciones de pertenencia con distribución gaussiana, es decir, en forma de campana de Gauss.

Así, si se considera x una característica de textura cualquiera que puede ser medida sobre una imagen. Si μ es la media de los valores de x definidos para un conjunto de imágenes dentro de una misma categoría (normal ó anormal) y σ es la desviación estándar del conjunto de valores de x . Se define el conjunto difuso con una distribución gaussiana y la función de pertenencia, normalizada puede ser expresada como se observa en (6):

$$f(x) = \exp \left\{ -\frac{1}{2} \left(\frac{x - \mu}{\sigma} \right)^2 \right\} \quad (6)$$

Los parámetros μ y σ se utilizan para definir con detalle las funciones de pertenencia a las clases normal o anormal para cada una de las medidas de textura calculadas. Sin embargo, si el número de imágenes de entrenamiento es pequeño, los valores de μ y σ pueden no reflejar las verdaderas características del conjunto de imágenes propias de una de las clases.

Para el proceso de clasificación se generan inicialmente las funciones de pertenencia calculando los valores de μ y de σ usando los valores de las características de textura definidas. Así se generan diez funciones de pertenencia, cinco para cada una de las características de textura para el

caso normal y cinco para cada una de las cinco características de textura para el caso anormal.

En el método propuesto se utilizan reglas difusas simples del tipo:

Regla i : Si x_1 es C_{i1} y..., x_m es C_{im} entonces y es w_i

donde i es el número de la regla analizada (con $i = 1, 2, \dots, N$ para N reglas), x_1, \dots, x_m son variables de entrada para el clasificador difuso, y es la salida del clasificador difuso, C_{i1}, \dots, C_{im} son etiquetas difusas correspondientes a las variables de entrada, y w_i es un número real del consecuente de la regla difusa.

Las siguientes son las dos reglas usadas en el trabajo investigativo descrito:

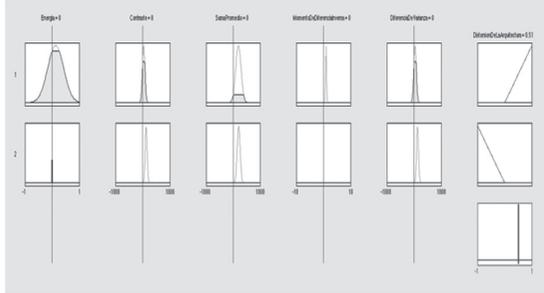
Regla (1): Si el valor de energía es la media de los valores de energía de los casos normales y el valor de contraste es la media de los valores de contraste de los casos normales y el valor de suma promedio es la media de los valores de suma promedio de los casos normales y el valor del momento de diferencia inversa es la media de los valores de momento de diferencia inversa de los casos normales y el valor de diferencia de varianza es la media de los valores de diferencia de varianza de los casos normales, entonces el caso es clasificado como normal con 99.9% de certeza.

Regla (2): Si el valor de energía es la media de los valores de energía de los casos anormales y el valor de contraste es la media de los valores de contraste de los casos anormales y el valor de suma promedio es la media de los valores de suma promedio de los casos anormales y el valor del momento de diferencia inversa es la media de los valores de momento de diferencia inversa de los casos anormales y el valor de diferencia de varianza es la media de los valores de diferencia de varianza de los casos anormales, entonces el caso es clasificado como anormal con 99.9% de certeza.

Estas dos reglas se pueden observar gráficamente en la Fig. 3.

Para el proceso de defusificación se utiliza el método de centro de gravedad tradicionalmente utilizado [22]. La función utilizada en la parte del consecuente del sistema de decisión difuso, es un triángulo isósceles normalizado, es decir, cuyo valor máximo es la unidad, como se puede observar en la Fig. 3

Fig. 3. MODELO DE RAZONAMIENTO DIFUSO. REGLAS DIFUSAS



El método de inferencia difusa se describe a continuación:

Si $\mu_{normal}(Q_1), \mu_{normal}(Q_2), \mu_{normal}(Q_3), \mu_{normal}(Q_4)$ y $\mu_{normal}(Q_5)$ son las respectivas funciones de pertenencia con distribución gaussiana para el caso normal y $\mu_{anormal}(Q_1), \mu_{anormal}(Q_2), \mu_{anormal}(Q_3), \mu_{anormal}(Q_4)$ y $\mu_{anormal}(Q_5)$ son las respectivas funciones de pertenencia con distribución gaussiana para el caso anormal, la relación de tipo *and* en las reglas difusas es el mínimo valor para $\mu_{normal}(Q_1), \mu_{normal}(Q_2), \mu_{normal}(Q_3), \mu_{normal}(Q_4)$ y $\mu_{normal}(Q_5)$ y para $\mu_{anormal}(Q_1), \mu_{anormal}(Q_2), \mu_{anormal}(Q_3), \mu_{anormal}(Q_4)$ y $\mu_{anormal}(Q_5)$ estarán definidos como:

$$\mu_{normal} = \min \left[\begin{matrix} \mu_{normal}(Q_1), \mu_{normal}(Q_2), \mu_{normal}(Q_3), \\ \mu_{normal}(Q_4), \mu_{normal}(Q_5) \end{matrix} \right]$$

y

$$\mu_{anormal} = \min \left[\begin{matrix} \mu_{anormal}(Q_1), \mu_{anormal}(Q_2), \mu_{anormal}(Q_3), \\ \mu_{anormal}(Q_4), \mu_{anormal}(Q_5) \end{matrix} \right]$$

Finalmente, se toma el centroide o centro de masa entre μ_{normal} y $\mu_{anormal}$.

Cuando $\mu_{normal} = \mu_{anormal}$ se trata de un caso sobre el cual no se puede decidir y en el presente trabajo de investigación se toma como una falla o error de clasificación.

IV. RESULTADOS

Como se mencionó anteriormente los componentes principales de un sistema de decisión ba-

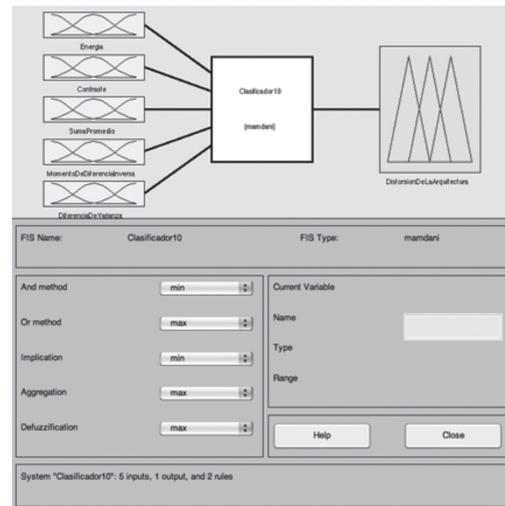
sado en lógica difusa son: los conjuntos difusos, las funciones de membresía o pertenencia difusas y las reglas difusas[27]. Cada conjunto difuso tiene una función de pertenencia correspondiente.

En el método propuesto se definen cinco variables de entrada correspondientes a las medidas de las cinco características de textura de Haralick seleccionadas en la investigación, como se observa en la Fig. 4.

Para cada una de las variables de entrada se definen dos funciones de pertenencia correspondientes a los casos normal y anormal.

Debido a que el comportamiento de una característica de textura definida en cualquier imagen está estadísticamente distribuida en forma gaussiana, las funciones de pertenencia se definen de acuerdo con (6).

FIG. 4. SISTEMA DE DECISIÓN BASADO EN LÓGICA DIFUSA



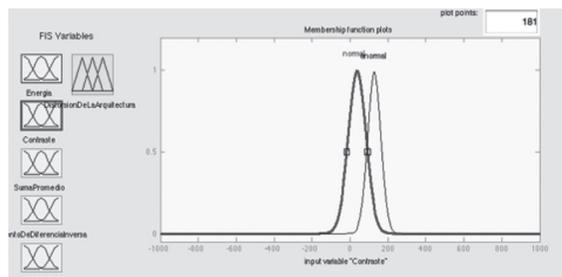
En la Tabla II se relacionan los valores de las medias y desviaciones estándar para cada variable de entrada y para los casos normal y anormal. Un ejemplo de una de las variables de entrada implementadas con sus dos funciones de pertenencia se puede observar en la Fig. 5.

TABLA. II.

Características de textura utilizadas y valores de media y desviación estándar calculados para el sistema de decisión difuso

Característica de Textura	Media		Desviación Estándar	
	caso normal	caso anormal	caso normal	caso anormal
Suma Promedio	7.2656	204.37	99.86	53.5
Energía	0.13	0.00083	0.29	0.0014
Diferencia de Varianza	49.17	140.44	52.87	29.54
Momento de Diferencia Inversa	0.96	0.998	0.17	0.00043
Contraste	49.17	140.44	52.87	29.54

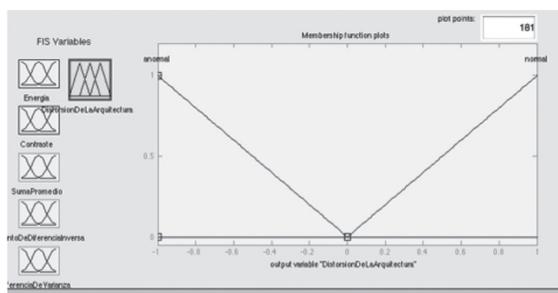
FIG. 5. EJEMPLO DE LA VARIABLE DE ENTRADA DE LA CARACTERÍSTICA DE CONTRASTE PARA EL SISTEMA DE DECISIÓN DIFUSO Y LAS FUNCIONES DE PERTENENCIA ASOCIADAS A LA MISMA



Posteriormente se definen las clases de salida del sistema de decisión difuso implementado. Para este caso se definen los conjuntos *anormal* y *normal* como clases de salida del sistema para los casos de presencia y no presencia de la distorsión de la arquitectura de la glándula mamaria respectivamente.

Los conjuntos de salida se representan como una función en forma de triángulo isósceles como se observa en la Fig. 6.

FIG. 6. CONJUNTOS DE SALIDA DEL SISTEMA DE DECISIÓN DIFUSO



En la Fig. 6 se observan las funciones de pertenencia del conjunto de salida con las clases normal y anormal definidas. Para los casos con pertenencia a la clase anormal la salida estará en el rango [-1 0] y para los casos con pertenencia a la clase normal la salida estará en el rango [0 1].

Finalmente, se define el sistema de decisión difuso de tipo Mandani y se establecen las reglas difusas definidas anteriormente.

El comportamiento del método propuesto se evalúa en términos de la sensibilidad, especificidad y precisión general. La sensibilidad es la probabilidad de un diagnóstico positivo dado el caso de una paciente con distorsión de la arquitectura de la glándula mamaria. La especificidad es la probabilidad de un diagnóstico negativo dado el caso de una paciente que no presenta distorsión de la arquitectura de la glándula mamaria. La precisión

general es la probabilidad de que el diagnóstico emitido por el método sea correcto y acorde con la situación real del paciente [27].

Las tres medidas del comportamiento se definen de la siguiente manera:

$$Sensibilidad = \frac{VP}{VP + FN} \quad (7)$$

$$Especificidad = \frac{VN}{VN + FP} \quad (8)$$

$$Precisión = \frac{VP + VN}{VP + VN + FP + FN} \quad (9)$$

donde

VP=Verdadero Positivo

VN=Verdadero Negativo

FP=Falso Positivo

FN=Falso Negativo

Con la extracción de las características de textura de las ROI identificadas y la clasificación de las mismas con un sistema de decisión basado en lógica difusa para asociarlas a las clases anormal o normal según presentaran o no distorsión de la arquitectura de la glándula mamaria respectivamente, se encuentran valores significativos en la precisión general del método.

A continuación se relaciona en la Tabla III de los datos para las variables de comportamiento del método presentado en este documento.

TABLA. III.

Resultados del método de detección propuesto

VP	FP	VN	FN
44	12	112	4

A partir de los datos de la Tabla. III. se pueden calcular los siguientes valores para las variables de comportamiento: Sensibilidad 91.7%, Especificidad 90.3% y Precisión General 90.7%.

Los tres valores obtenidos en las medidas de comportamiento del método propuesto superan el 90% de precisión general lo cual hace de este método una herramienta de apoyo para la detección de distorsiones de la arquitectura de la glándula mamaria comparable con los trabajos publicados por otros autores, sin embargo realizar un análisis comparativo a niveles más detallados resulta bastante difícil ya que en cada investigación reporta-

da los conjuntos de datos e imágenes varían de un trabajo a otro.

V. CONCLUSIONES

Los resultados del desempeño del método demuestran que debido al grado de incertidumbre inmerso en los diagnósticos que se hacen a partir de las radiologías de mama, el uso de un sistema de decisión diferente a los clasificadores clásicos reportados en el estado del arte, como el caso del sistema de decisión basado en lógica difusa implementado en el presente estudio, permite alcanzar niveles de precisión general cercanos a un 90%. Lo cual, considerado que se utilizó una base de datos de dominio público, hace del método propuesto una línea base de investigación en el tema de la detección de distorsiones de la arquitectura de la glándula mamaria.

Asimismo, el método presentado puede ser usado en diferentes escenarios clínicos para diagnóstico y seguimiento de patologías donde se presente alteración de la distribución normal de tejidos como, por ejemplo, en el tratamiento y evolución de quemaduras. Además, según los resultados obtenidos para la detección de la distorsión de la arquitectura de la glándula mamaria, puede plantearse la extensión del método para la detección de otras anomalías de la mama que pueden ser vistas a través de la mamografía como las micro-calcificaciones, las masas y las asimetrías de densidad.

Por otra parte, aunque las pruebas realizadas muestran resultados de precisión superiores al 90%, es importante una segunda validación al utilizar, por ejemplo, un conjunto de imágenes diferente a la base de datos DDSM que permita evaluar con más precisión el comportamiento del método propuesto.

Siempre será deseable incrementar los porcentajes de sensibilidad, especificidad y precisión general, en los sistemas de diagnóstico asistido por computador. Por esta razón para trabajos futuros se podría realizar un proceso de afinación de las funciones de pertenencia propias de los conjuntos difusos propuestas en este documento, a través del afinamiento de los parámetros de dichas funciones de pertenencia al aplicar, por ejemplo, algoritmos genéticos como se sugiere en [27].

Finalmente, el método de detección de distorsiones de la arquitectura de la glándula mamaria desarrollado, resulta ser una base importante para la investigación aplicada, ya que los resultados obtenidos a nivel de precisión general hacen posible que se pueda llevar a un entorno real y encontrar aplicación local o regional incluso ampliando el alcance del mismo método, para que además de asistir a los radiólogos en el momento de la evaluación de las mamografías, también sirva como herramienta de entrenamiento de nuevos especialistas y como instrumento para la medición de la calidad del servicio diagnóstico prestado por los radiólogos ya expertos.

REFERENCIAS

- [1] E. Coto, "Método de Segmentación de Imágenes Médicas," 2003.
- [2] Instituto Nacional de Cancerología, "Casos nuevos de cáncer de mama, según estadio clínico al ingreso y régimen de afiliación." 2009.
- [3] F. R. Narváez E., "Sistema de Anotación para Apoyo en el Seguimiento y Diagnóstico de Cáncer de Seno," Universidad Nacional de Colombia, 2010.
- [4] American College of Radiology (ACR), *Breast Imaging Reporting and Data System*, 4th ed. 2003.
- [5] A. M. Knutzen and J. J. Gisvold, "Likelihood of malignant disease for various categories of mammographically detected, nonpalpable breast lesions.," in *Mayo Clinic proceedings. Mayo Clinic*, 1993, Vol. 68, p. 454.
- [6] S. Banik, R. M. Rangayyan, and J. E. L. Desautels, "Detection of Architectural Distortion in Prior Mammograms," *Medical Imaging, IEEE Transactions on*, vol. 30, no. 2, pp. 279–294, 2011.
- [7] D. A. Gómez Betancur, "Método de detección de distorsiones de la arquitectura de la glándula mamaria a partir de imágenes radiológicas," Universidad Nacional de Colombia, 2012.
- [8] M. D. Phillips, "Invasive Lobular Breast Carcinoma: Pathology And Genetics Reflected By MRI," *The World-Care Clinical (WCC) Note*, Vol. 4, 2010.
- [9] T. Matsubara, T. Ichikawa, T. Hara, H. Fujita, S. Kasai, T. Endo, and T. Iwase, "Novel method for detecting mammographic architectural distortion based on concentration of mammary gland," in *International Congress Series*, 2004, vol. 1268, pp. 867–871.
- [10] B. C. Yankaskas, M. J. Schell, R. E. Bird, and D. A. Desrochers, "Reassessment of breast cancers missed du-

- ring routine screening mammography: a community-based study," *American Journal of Roentgenology*, vol. 177, no. 3, p. 535, 2001.
- [11] M. Bustamante, G. Lefranc, A. Núñez, and M. G. Pesce, "Calculo De La Amplitud Dispersada En Mamografias, Usando Como Modelo De Degradacion El Filtro Bosso.," *PHAROS*, Vol. 8, No. 1, 2001.
- [12] H. D. Cheng, X. J. Shi, R. Min, L. M. Hu, X. P. Cai, and H. N. Du, "Approaches for automated detection and classification of masses in mammograms," *Pattern Recognition*, vol. 39, no. 4, pp. 646–668, 2006.
- [13] J. Tang, R. M. Rangayyan, J. Xu, I. El Naqa, and Y. Yang, "Computer-aided detection and diagnosis of breast cancer with mammography: Recent advances," *Information Technology in Biomedicine, IEEE Transactions on*, Vol. 13, No. 2, pp. 236–251, 2009.
- [14] R. M. Rangayyan and T. M. Nguyen, "Fractal Analysis of Contours of Breast Masses in Mammograms," *Journal of Digital Imaging*, Vol. 20, pp. 223–237, Oct. 2006.
- [15] T. Matsubara, T. Ichikawa, T. Hara, H. Fujita, S. Kasai, T. Endo, and T. Iwase, "Automated detection methods for architectural distortions around skinline and within mammary gland on mammograms," *International Congress Series*, vol. 1256, no. 0, pp. 950–955, Jun. 2003.
- [16] N. Eltonsy, G. D. Tourassi, and A. Elmaghraby, "Investigating performance of a morphology-based CAD scheme in detecting architectural distortion in screening mammograms," *Proc. 20th Int. Congr. Exhib. Comput. Assist. Radiol. Surg*, pp. 336–338, 2006.
- [17] G. D. Tourassi, D. M. DeLong, and C. E. Floyd, "A study on the computerized fractal analysis of architectural distortion in screening mammograms," *Physics in Medicine and Biology*, Vol. 51, pp. 1299–1312, Mar. 2006.
- [18] R. M. Rangayyan, S. Prajna, F. J. Ayres, and J. E. L. Desautels, "Detection of architectural distortion in prior screening mammograms using Gabor filters, phase portraits, fractal dimension, and texture analysis," *International Journal of Computer Assisted Radiology and Surgery*, Vol. 2, No. 6, pp. 347–361, 2008.
- [19] S. Prajna, R. M. Rangayyan, F. J. Ayres, and J. E. L. Desautels, "Detection of architectural distortion in mammograms acquired prior to the detection of breast cancer using texture and fractal analysis," in *Proceedings of SPIE*, 2008, Vol. 6915, p. 691529.
- [20] R. M. Rangayyan, S. Banik, and J. E. L. Desautels, "Computer-aided detection of architectural distortion in prior mammograms of interval cancer," *Journal of Digital Imaging*, Vol. 23, No. 5, pp. 611–631, 2010.
- [21] S. Russell, *Inteligencia Artificial - Un Enfoque Moderno*, 2nd ed. 2004.
- [22] T. Nakashima, G. Schaefer, Y. Yokota, and H. Ishibuchi, "A weighted fuzzy classifier and its application to image processing tasks," *Fuzzy sets and systems*, Vol. 158, No. 3, pp. 284–294, 2007.
- [23] H. Ishibuchi and T. Nakashima, "Effect of rule weights in fuzzy rule-based classification systems," *Fuzzy Systems, IEEE Transactions on*, Vol. 9, No. 4, pp. 506–515, 2001.
- [24] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural Features for Image Classification," *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 3, No. 6, pp. 610–621, Nov. 1973.
- [25] M. Amadasun and R. King, "Textural features corresponding to textural properties," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 19, no. 5, pp. 1264–1274, Oct. 1989.
- [26] H. Tamura, S. Mori, and T. Yamawaki, "Textural Features Corresponding to Visual Perception," *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 8, No. 6, pp. 460–473, Jun. 1978.
- [27] D.-Y. Tsai and K. Kojima, "Measurements of texture features of medical images and its application to computer-aided diagnosis in cardiomyopathy," 2005.