

Aplicación de la inteligencia artificial en la clasificación automática de imágenes médicas

Application of artificial intelligence in the automatic classification of medical images

Gustavo Rafael Guzman Loreto¹, Esther Durán Reyes², Carlos Abraham Robles Saucedo², Leonardo Gonzales Guzman², Christian Agustín Tavera Rocha¹, Rafael Guzman Cabrera³

¹Estudiantes de la Universidad de Guanajuato, División Ciencias e ingeniería, Campus León

²Estudiantes de la Universidad de Guanajuato, División de ingenierías, Campus Irapuato Salamanca

³Departamento de Ingeniería Eléctrica, División de ingenierías, Campus Irapuato Salamanca, Universidad de Guanajuato.

guzmanc@ugto.mx*

Resumen

En el presente trabajo se desarrolla un clasificador automático para imágenes de ultrasonido mamario, diferenciando entre tejidos benignos, malignos y normales. Utilizando una base de datos pública, se mejoraron las imágenes mediante ecualización del histograma, y se emplearon segmentaciones expertas para aislar los tumores. Características clave como la irregularidad de la forma y las microcalcificaciones fueron cuantificadas y usadas en un algoritmo de mínimos cuadrados para la clasificación. Los resultados sugieren explorar clasificadores más avanzados y mejorar la segmentación para reducir errores.

Palabras clave: Inteligencia artificial; clasificación automática; segmentación de imágenes; Algoritmo de mínimos cuadrados.

Introducción

El cáncer de mama es una de las principales causas de mortalidad en mujeres en México [1]. Se caracteriza por el crecimiento anormal de células en el tejido mamario, que puede llevar a la formación de tumores malignos. En 2020, se registraron alrededor de 29,929 nuevos casos de cáncer de mama en México. Representa una de las principales causas de muerte por cáncer en mujeres. En 2020, se reportaron aproximadamente 7,931 muertes debido a esta enfermedad en el país.

La Mamografía es la herramienta de detección más eficaz y se recomienda especialmente para mujeres mayores de 40 años o con factores de riesgo [2]. El tratamiento del cáncer de mama en México varía según el estadio de la enfermedad y puede incluir cirugía, quimioterapia, radioterapia, terapia hormonal y tratamientos dirigidos [3]. Es fundamental un diagnóstico temprano para aumentar las posibilidades de éxito en el tratamiento.

El diagnóstico temprano del cáncer de mama es fundamental para mejorar la supervivencia de las pacientes. Las imágenes de ultrasonido mamario son una herramienta valiosa en la detección temprana, para su interpretación visual. Este trabajo propone el desarrollo de un clasificador automático de imágenes de ultrasonido mamario, para diferenciar entre tejidos benignos, malignos y normales, utilizando el extenso conjunto de datos de Al-Dhabyani [4] como base para el desarrollo y evaluación del sistema. Cabe mencionar que esta base de datos fue manualmente etiquetada por expertos.

Desarrollo

Dado el alto nivel de ruido presente en las imágenes de ultrasonido, se implementó una etapa de preprocesamiento para mejorar la calidad de las imágenes antes de aplicar las técnicas de segmentación y clasificación. Se optó por la ecualización del histograma [5] como método de mejora de contraste, porque permite redistribuir los niveles de intensidad de los píxeles, ampliando el rango dinámico y mejorando la visibilidad de las características de interés. La elección de este método se basó en su simplicidad computacional y su eficacia en imágenes con bajo contraste.

Debido a la complejidad de segmentar automáticamente los objetos en imágenes de ultrasonido con alto nivel de ruido y variabilidad, se optó por utilizar las máscaras proporcionadas en la base de datos de Al-Dhabyani [1] Estas máscaras fueron generadas por expertos y se consideraron de alta calidad y precisión, lo que permitió centrar nuestros esfuerzos

en la fase de clasificación. El uso de máscaras en la clasificación automática es una técnica ampliamente utilizada en el estado del arte [6].



Figura 1. Máscara obtenida de la base de datos de Al- Dhabyani.

Para aislar el tumor y eliminar el ruido de fondo, se utilizó la máscara binaria proporcionada para recortar cada imagen. Mediante una operación lógica AND entre la imagen original y la máscara, se obtuvo una nueva imagen que contenía únicamente los píxeles correspondientes al tumor. Es importante destacar que las máscaras utilizadas presentaban formas irregulares para adaptarse a la variabilidad en el tamaño y forma de los tumores.

Para extraer características relevantes para la clasificación de tumores como benignos o malignos, se consultó a un panel de radiólogos expertos. Basándose en su experiencia, se identificaron tres características clave: la irregularidad de la forma y la presencia de microcalcificaciones. La irregularidad de la forma se cuantificó mediante la desviación estándar, debido a que, en las imágenes vistas, los tumores malignos presentaban más variación de gris. Por otro lado, la presencia de microcalcificaciones se detectó mediante un algoritmo de detección de puntos, utilizando la siguiente expresión:

La elección de estas características se basó en la amplia evidencia en la literatura médica que asocia la irregularidad de la forma y las microcalcificaciones con el cáncer de mama. Sin embargo, es importante reconocer que la evaluación visual de estas características puede existir otras características relevantes no consideradas en este trabajo.

$$\text{Circularidad} = \frac{4\pi \cdot \text{Área}}{\text{Perímetro}^2}$$

Se optó por utilizar un algoritmo de LMS (este es una implementación del método de gradiente, en la cual se generan diferentes valores de $X(n)$ hasta obtener un porcentaje de error pequeño) para clasificar el tejido presentado en las imágenes. Se seleccionó este algoritmo debido a su simplicidad computacional y su capacidad de adaptarse a cambios en los datos de entrada. Para cada imagen, se extrajo un vector de características compuesto por desviación estándar, el número de tumores y la irregularidad. Obteniendo los pesos del LMS, minimizando el error cuadrático medio entre la salida del clasificador y la etiqueta de clase correspondiente. Si bien el LMS proporcionó resultados satisfactorios, se planea explorar en futuros trabajos el uso de clasificadores más complejos como redes neuronales convolucionales, que podrían capturar mejor las características no lineales presentes en las imágenes de ultrasonido.

Resultados

El clasificador de mínimos cuadrados, diseñado para distinguir entre tumores benignos y malignos, presentó una tasa de error de clasificación del 8%. Sin embargo, al expandir el problema para incluir un tejido normal, la tasa de error aumentó significativamente hasta un 40%. Este incremento podría atribuirse a una mayor complejidad en la frontera de

decisión, un desbalance en el conjunto de datos o a la insuficiencia de las características extraídas para discriminar entre las tres clases.

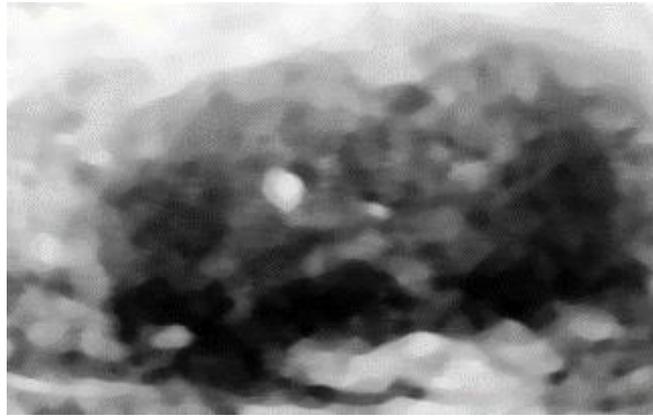


Figura 2. Imagen recortada.



Figura 3. Imagen umbralizada.

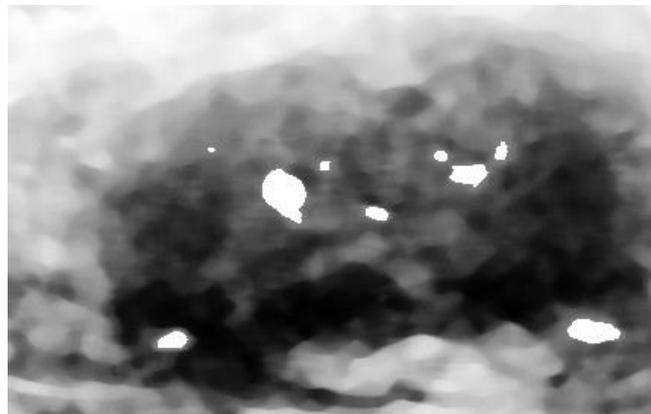


Figura 4. Tumores detectados.

Los resultados obtenidos se muestran en la Figura 5 y sugieren que las características propuestas, aunque aportan cierta discriminabilidad entre las clases, requieren un refinamiento matemático más riguroso para lograr una clasificación más precisa y robusta. La incorporación de técnicas de extracción de características más sofisticadas, como la aplicación de transformadas de onda o la extracción de texturas basadas en modelos estadísticos, podría mejorar significativamente el rendimiento del clasificador.

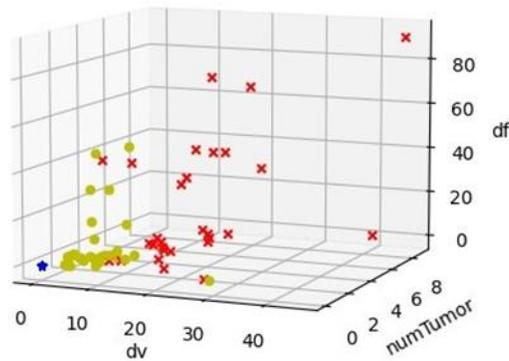


Figura 5. Visualización de la base de datos obtenida.

La Figura 5 presenta una visualización de los resultados de clasificación obtenidos para un conjunto de 90 imágenes de tejido mamario. Cada punto en el gráfico representa una imagen individual, cuya clasificación se indica mediante un símbolo específico: estrella azul para tejido normal, círculo amarillo para tejido benigno y asterisco para tejido maligno. Esta representación gráfica permite visualizar de forma intuitiva la distribución de las clases y evaluar el desempeño del modelo de clasificación.

Conclusión

Un análisis exhaustivo de la base de datos sugiere que existen oportunidades significativas para mejorar la precisión de nuestro clasificador. Dos enfoques prometedores son:

1. **Exploración de nuevos modelos:** Implementar un clasificador basado en redes neuronales convolucionales (CNN) podría aprovechar la capacidad de estas arquitecturas para aprender automáticamente características jerárquicas de las imágenes, lo que podría resultar en una mejor discriminación entre clases.
2. **Refinamiento de las características:** Profundizar en la ingeniería de características podría conducir a una representación más discriminativa de los datos. Esto implica explorar nuevas métricas para cuantificar la irregularidad de los tumores, así como desarrollar técnicas más robustas para la detección de microcalcificaciones.

Además, para reducir la tasa de falsos positivos, proponemos segmentar de manera más precisa la región de interés (ROI) correspondiente al tumor.

Bibliografía/Referencias

1. Palmero Picazo, J., Lassard Rosenthal, J., Juárez Aguilar, L. A., & Medina Núñez, C. A. (2021). Cáncer de mama: una visión general. *Acta médica Grupo Ángeles*, 19(3), 354-360.
2. Aguilar-Torres, C. R., Cisneros-Castolo, M., Stener-Lechuga, T., Pérez-Molinar, K. F., Parra-Acosta, H., Sáenz-Cabral, I. P., & Ornelas-Flores, C. (2021). Panorama actual del tamizaje para detección del cáncer de mama en el estado de Chihuahua, México. *Ginecología y obstetricia de México*, 89(2), 91-99.
3. Pizan, R. I. S., Morales, B. J., Cruz, R. C., López, L. S., Jiménez, M. D. L. Á. S., & Echeverría, G. R. (2022). Características epidemiológicas, radiológicas e histológicas de cáncer de mama en usuarias de un hospital general regional en Guerrero, México. *Atención familiar*, 29(1), 15-19.
4. Al-Dhabyani, W., Gomaa, M., Khaled, H., & Fahmy, A. (2020). Dataset of breast ultrasound images. *Data in brief*, 28, 104863.
5. Zamarrón-Pérez, M., Pedraza-Ortega, J., & Tovar-Arriaga, S. Estudio comparativo de técnicas de preprocesamiento en imágenes de retina.
6. Pérez Ortiz de Landaluce, M. (2021). Clasificación de imágenes mediante algoritmos de Deep Learning: Mascarillas de COVID-19.

