

# Identificación de cáncer de mama en imágenes termográficas mediante redes neuronales convolucionales

Diana Morales-Venegas<sup>1</sup>, Santiago Tello-Mijares<sup>1</sup>.

**Resumen**— Este artículo presenta un método novedoso para la clasificación de imágenes termográficas de mama en normal o anormal (sin o con cáncer) basado en características extraídas de la última capa de una red neuronal convolucional (CNN, Convolutional Neural Networks). El método sobre-segmenta las imágenes termográficas de mama mediante la técnica de superpíxeles. Después de la sobre-segmentación basado en el método de ajuste de niveles (level sets), y mediante un proceso de búsqueda de umbrales del modelo de color HSI se selecciona la temperatura de las áreas de interés en 10 niveles. Las áreas de máscaras obtenidas posteriormente a partir de restricciones de mama a priori son elípticas y cada imagen resultante se usa como entrada para la CNN; para entrenar y probar dicha red para la extracción de características, que es seguida por una técnica de clasificación clásica (respecto a la novedad del aprendizaje profundo). Los resultados de la clasificación, en la etapa final, utilizando el bosque de árboles al azar (TRF, Tree Random Forest) o un perceptrón votado (VTP, Voted Perceptron) incluyen un 100% de sensibilidad (TPR, True Positive Rate) y un 100% de precisión (PPV, Positive Predictive Value) en una validación cruzada doble.

**Palabras claves**— Imágenes termográficas de cáncer de mama, redes neuronales convolucionales, CNN.

**Abstract**— This article presents a novel method for the classification of thermographic images of breast into normal or abnormal (without or with cancer) based on features extracted from the last layer of a convolutional neural network (CNN). The method over-segments the breast thermographic images using the superpixel technique. After the over-segmentation based on the level set method, and through a process of searching for thresholds of the HSI color model, the temperature of the areas of interest in 10 levels is selected. The areas of masks subsequently obtained from a priori breast restrictions are elliptical and each resulting image is used as input for CNN; to train and test said network for the extraction of characteristics, which is followed by a classical classification technique (regarding the novelty of deep learning). The results of the classification, in the final stage, using Tree Random Forest (TRF) or Voted Perceptron (VTP) include a 100% sensitivity (TPR, True Positive Rate) and a 100% accuracy (PPV, Positive Predictive Value) in a double cross validation.

**Keywords**— Thermography breast cancer images, convolutional neural networks, CNN.

## I. INTRODUCCIÓN

El cáncer de mama es el cáncer más frecuente mundialmente entre las mujeres y aproximadamente 2 de cada 5 mujeres a nivel mundial desarrollarán cáncer de mama a lo largo de su vida [1]. Desde 2013, el cáncer de mama se tipificó como la segunda causa de muerte en las mujeres [2]. La Organización Mundial de la Salud (OMS) estima que para el año 2030, se puede esperar un estimado de 27 millones de nuevos casos [3]. Hoy en día, existen diferentes técnicas para llevar a cabo el diagnóstico de esta patología (mamografía, ultrasonido, resonancia magnética, biopsias, y más recientemente la termografía) [4]; siendo la mamografía el método más empleado actualmente, sin embargo, presenta el riesgo de ionización, radiación y la incomodidad de la compresión de senos [5], además de detectar los primeros signos de cáncer de 8 a 10 años después que la termografía [6]. Es importante mencionar que la detección temprana de esta enfermedad juega un papel importante en la reducción de la tasa de mortalidad [6], ya que, si el tumor se detecta antes de alcanzar un tamaño de 10 mm, el paciente tiene una probabilidad del 85% de curación [5].




Figura 1: (a-b) Imagen termográfica de senos sin cáncer de mama. (c-d) Imagen termográfica de senos con cáncer mama. (e-h) Datos Ground-Truth.

En los últimos años, ha habido un interés creciente en el análisis de imágenes de termografía [7] para la tarea de detectar el cáncer de mama. Estas técnicas tienen el potencial de aumentar la productividad en el análisis del cáncer de mama y reducir los errores de detección [8]. Este documento se centra en las primeras etapas del análisis de las imágenes de termografía de senos para identificar el cáncer mediante la clasificación en normales (Fig. 1 (a-b)) y anormales (Fig. 1 (c-d)); y en proporcionar área de interés fundamental (Ground-Truth proporcionada por expertos médicos) (Fig. 1 (e-h)).

<sup>1</sup> Tecnológico Nacional de México/Instituto Tecnológico Superior de Lerdo. Av. Tecnológico N° 1555, Periférico Lerdo Km. 14.5, C.P. 35150 Cd Lerdo, Durango. México. \*jtello@itslerdo.edu.mx.

II. PARTE TÉCNICA DEL ARTÍCULO

En esta sección se describe un método de clasificación de imágenes termográficas de mama para un prediagnóstico temprano de cáncer de mama. La Figura 2 ilustra las etapas del algoritmo de clasificación propuesto, las cuales se detallan en las siguientes subsecciones.

A. Segmentación y selección de las áreas de temperatura de interés

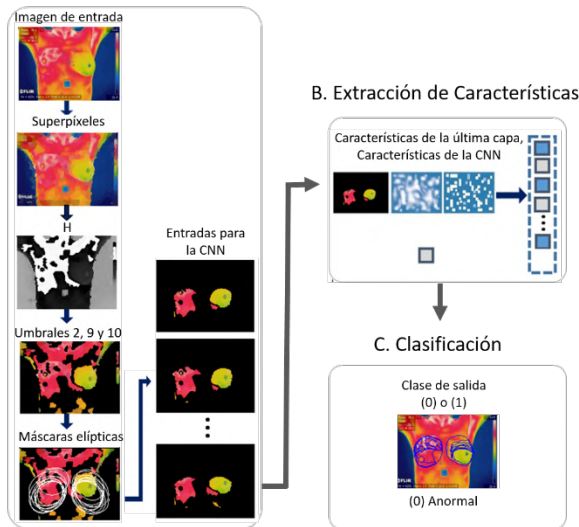


Figura 2: Algoritmo de clasificación propuesto.

A. Segmentación y selección de las áreas de temperaturas de interés

Se realiza un proceso de segmentación y selección para la separación de áreas y temperaturas de interés; el objetivo es aislar las regiones de interés de la imagen termográfica y someter esta parte representativa de las imágenes a una extracción y clasificación de características completas utilizando la CNN.

Se utiliza el algoritmo de superpíxeles [9] para el preprocesamiento y para obtener una imagen sobre-segmentada. La técnica de superpíxeles agrupa a los píxeles en regiones perceptivamente significativas, que pueden usarse para reemplazar la estructura rígida de la cuadrícula de píxeles, es decir realiza el agrupamiento de píxeles con características similares dentro de una imagen y proporciona una manera conveniente de realizar una caracterización focal de parámetros en una imagen digital. Con la sobre-segmentación se propone capturar la redundancia de la imagen, proporcionar una forma primitiva conveniente para calcular las características de la misma y reducir en gran medida la complejidad del procesamiento posterior de la imagen basado en el método de ajuste de nivel (Level-Set). Por lo tanto, superpíxeles permite reducir la imagen inicial de 57,600 píxeles a 1,500 superpíxeles (500 por cada canal de color). Agrupando las regiones de cada superpíxel en base a las características

similares de la temperatura representada, lo cual permite analizar de una mejor manera cada región.

El cáncer de mama ocurre cuando las células de la mama comienzan a crecer fuera de control e invaden los tejidos cercanos [10] lo cual genera un aumento de la temperatura en la superficie del seno. Por medio de esta premisa se separa la imagen sobre-segmentada (Fig. 3b) en 10 niveles de umbral utilizando el tono (H) del modelo de color HSI. Por lo tanto, a partir de la imagen sobre-segmentada en RGB (Fig. 3b) se obtiene el tono H (Fig. 3c).




Figura 3: (a) Imagen termográfica original. (b) Imagen termográfica sobre-segmentada con superpíxeles. (c): H (tono) del modelo HSI.

La imagen representativa de H obtenida (Fig. 3c) es separada en diez niveles diferentes. En base al método de ajuste de nivel, obteniendo 10 máscaras mediante 10 niveles de umbrales de H que van desde 1 hasta 0 los cuales se muestran en la Figura 4.




Figura 4: 10 máscaras de umbrales de H.

Las máscaras obtenidas de los niveles de umbrales (Fig. 4) se aplican a la imagen RGB sobre-segmentada (Fig. 3b), obteniendo como resultado los 10 niveles mostrados en la Figura 5. De éstos se seleccionan el nivel 2 (rojo), el nivel 9 (verde) y el nivel 10 (amarillo) para mostrarlos en conjunto, obteniendo como resultado la región de temperaturas de interés mostrada en la Figura 6a, donde dichos colores de interés permiten distinguir entre el tejido mamario normal y el anormal.




Figura 5: Máscaras de umbrales de H aplicadas a la imagen sobre-segmentada RGB.

Para la selección de las áreas de interés de la temperatura de los senos, se comienza por la observación de que las regiones que pertenecen a un seno deben ser elípticas, también la posición del centro del eje  $k$  del seno izquierdo y derecho es casi similar, desde el centro  $(h, k)$  de cada seno. Después se utilizan las imágenes de Ground-Truth proporcionadas por expertos médicos, se aplican restricciones básicas a priori a la forma y el tamaño de ambos senos. En cada seno, tanto a la izquierda como a la derecha (Fig. 6a y 6b), se obtienen las coordenadas usando la ecuación paramétrica de una elipse, con el centro en  $(h, k)$ , y siendo  $a$  el eje mayor,  $b$  el eje menor, y  $\theta$  el ángulo polar de orientación al centro, es:  $x=h+a\cos(\theta)$ ;  $y=k+b\cos(\theta)$ . Por estas razones, se obtienen las características elípticas, centro, eje mayor, eje menor y orientación de ambos senos (Fig. 6b): derecha  $(a_r, b_r$  y  $\theta_r)$  e izquierda  $(a_l, b_l$  y  $\theta_l)$ ; y la coordenada central de ambos senos (Fig. 6c).




Figura 6: (a) Región de temperaturas de interés. Conjunto de niveles 2, 9 y 10. (b) Características de las elipses: (a) Eje mayor  $(a)$ , eje menor  $(b)$  y orientación  $\theta$ . (c) Centroide  $(h, k)$ . Subíndice derecho  $r$  (right) para mama derecha y subíndice izquierdo  $l$  (left) para mama izquierda. (d) Máscaras elípticas.

Posteriormente se lleva a cabo el agrupamiento para cada centro de los ejes  $k$  izquierdo y derecho ( $k_r$  y  $k_l$ , Fig.7) por medio del método de agrupación de K-Medias (K-Means clustering) de  $K=10$  centros de agrupamiento iniciales. El método de agrupación de K-medias [11] se usa comúnmente para particionar automáticamente un conjunto de datos en  $K$  grupos. Después, desde el grupo  $K=10$ , se obtiene el valor promedio del eje mayor, el eje menor y la orientación de cada seno, derecho e izquierdo, en su grupo. Para finalmente, dibujar las máscaras elípticas de 10 representantes del valor promedio obtenido en cada una de las interacciones  $K$  ( $K=1:10$ ) de cada grupo en ambos senos.

El resultado de este método de recorte de imagen, es un conjunto de imágenes de 10 niveles elípticos (Fig. 6d) para aplicarlos como datos de entrada a la CNN (Fig. 8), las cuales se redimensionan a  $127 \times 127$  píxeles. Estos son un conjunto de imágenes de seno resultado de una fusión de regiones conectadas caracterizadas por estas restricciones y solo las regiones relevantes de temperatura de interés. Esta fase está diseñada para maximizar el conocimiento

para evitar falsos negativos, que es un factor crítico en la imagen médica. El objetivo de las siguientes fases es maximizar la precisión para eliminar o al menos identificar falsos candidatos. Los valores específicos de las restricciones a priori son bastante flexibles porque solo deberían evitar perder los verdaderos positivos.

### B. Extracción de características

En esta subsección se presenta una extracción efectiva y eficiente de las características de las mamas de las imágenes termográficas: un conjunto de características que resultan de la última capa de una CNN, por ejemplo, las características de la CNN (Fig. 8). Originalmente propuesta por LeCun [12], una CNN es un modelo de red neuronal con tres ideas arquitectónicas clave: campos receptivos locales, reparto de peso y submuestreo en el dominio espacial. Una CNN consta de tres tipos principales de capas diseñadas para obtener los mapas de características: capas de convolución espacial (CONV 1), capas de agrupamiento de submuestreo (MaxPool 1) y capas totalmente conectadas (FC 1) — 1 es un índice de capa (1-5), respectivamente— se utiliza para obtener las características de nivel bajo, nivel medio y nivel alto (Fig. 8).

Se utiliza una CNN basada en estudios previos diseñados para procesar imágenes tridimensionales (3D), la AlexNet [13] y en la Figura 8 se explican las capas de la arquitectura. La motivación es que una CNN es ventajosa para la extracción de características, ya que es jerárquica (con múltiples capas para mayor compacidad y eficiencia) y redundancia de invarianza (para posición, tamaño, luminosidad, rotación, ángulo de pose, ruido y distorsión) Y se propone un método eficiente para extraer las características de clasificación de las imágenes de senos de la última capa de la CNN.




Figura 7: Agrupación de centroides mediante k-medias en 10 grupos.






Figura 8: Estructura de la CNN.

Se demuestra que un método de clasificación que utiliza la combinación de características clásicas y las características CNN es más eficiente. Las CNN generalmente operan sobre miles de imágenes de entrada de tamaño normalizado, que requieren una adaptación previa. La principal contribución en esta fase es reemplazar esta adaptación por la generación basada en el contenido de las 10 imágenes de niveles de umbral. Para cada imagen de seno de entrada, se generaron imágenes de 10 niveles de umbral de tamaño fijo que capturan la semántica y las regiones de temperatura del seno, mediante el uso de un método basado en Level-Set Method. Primero se redimensiona la imagen a  $227 \times 227 \times 3$  según el conjunto de entrenamiento AlexNet [13]. Estas imágenes RGB de  $227 \times 227$  píxeles  $\times 3$  niveles de color alimentan la CNN (Fig. 8), que está diseñada para extraer 1043 vectores de características de alto nivel, los cuales son obtenidos al pasar por las capas de la arquitectura AlexNet [13], mediante  $O = ((I - K + 2P) / S) + 1$  para las capas CONV y  $O = ((I - P_s) / S) + 1$  para las capas MaxPool, siendo O el tamaño de la imagen de salida en ambos casos y dependiendo de las siguientes variables; I=tamaño de la imagen de entrada; K=ancho de los kernels (filtros) utilizados en la capa de convolución; N=número de kernels; S=stride (saltos de pixel) de la operación de convolución; P=padding (relleno) y  $P_s$ =tamaño del filtro MaxPool. Además de la capa FC conectada a la última capa CONV que toma el valor del número de neuronas de la misma capa y la capa FC conectada a otra FC la cual toma el valor de la capa FC anterior.

De acuerdo a lo anterior se muestra la evolución de la imagen de entrada de un tamaño de  $227 \times 227 \times 3$  a través de las distintas capas de la CNN. Después de CONV 1 (96 filtros de  $11 \times 11$ ), el tamaño cambia a  $55 \times 55 \times 96$ , que se transforma en  $27 \times 27 \times 96$  después de MaxPool 1 (agrupación  $3 \times 3$ ). Después de CONV 2 (256 filtros de  $5 \times 5$ ), el tamaño cambia a  $27 \times 27 \times 256$  y luego MaxPool 2 (agrupación  $3 \times 3$ ) cambia a  $13 \times 13 \times 256$ . CONV 3 (384

filtros de  $5 \times 5$ ) lo transforma a un tamaño de  $13 \times 13 \times 384$ , mientras que CONV 4 (384 filtros de  $5 \times 5$ ) conserva el tamaño y CONV 5 (256 filtros de  $5 \times 5$ ) cambia el tamaño de vuelta a  $27 \times 27 \times 256$ . Finalmente, MaxPool 3 (agrupación  $5 \times 5$ ) reduce el tamaño a  $6 \times 6 \times 256$ . Esta imagen se alimenta a FC 1 que la transforma en un vector de tamaño  $4096 \times 1$ . Estos vectores contienen las características del extracto CNN para alimentar las cuatro técnicas de clasificación utilizadas presentadas en la subsección C.

### C. Clasificación

Para clasificar estas regiones en normales o anormales y obtener resultados de clasificación finales, se exploró el uso de cuatro enfoques de clasificación diferentes implementados en Weka (Waikato Environment for Knowledge Analysis) [14; 15]: Red bayesiana (BN Bayes Net) [16], Perceptrón votado (VTP Voted Perceptron) [17], J48 [18] y Bosque aleatorio (TRF Tree Random Forest) [18], utilizando un esquema de validación cruzada de s-fold ( $s=2$ ), es decir, una validación cruzada doble; donde el conjunto de datos se divide en dos partes iguales: una se utiliza para el entrenamiento y la otra se utiliza para la prueba, obteniendo resultados experimentales para estas técnicas (ver sección III).

## III. RESULTADOS

El conjunto de datos utilizado incluye 659 imágenes termográficas (298 normales y 361 anormales) en formato de color RGB y en formato de imagen JPEG, con un tamaño de  $160 \times 120$  píxeles y con una resolución de  $72 \times 72$  ppp, proporcionadas amablemente por [8]. El método propuesto puede adaptarse fácilmente a diferentes imágenes de mamas termográficas. La Figura 1 muestra imágenes de ejemplo del conjunto de datos, (la segmentación correcta de los datos para la segmentación y clasificación de las mamas y su grado de alteración respecto a los diferentes niveles de temperatura), y la Figura 9 muestra los resultados de estas imágenes. Los

datos Ground-Truth para la segmentación y clasificación del tejido mamario y su grado de alteración con respecto a los diferentes niveles de temperatura se obtuvieron de médicos especializados en base a la verificación de la localización de la mama.

Se obtuvieron varios indicadores de calidad para evaluar cuantitativamente los resultados de la clasificación de mamas y el rendimiento de las técnicas BN, VTP, J48 y TRF. Se han dividido en indicadores de calidad finales o externos, que evalúan los resultados finales de la segmentación y son útiles para la comparación externa con otros trabajos, e indicadores de calidad internos, que son útiles para evaluar el comportamiento interno de las opciones de clasificación propuestas.

Para obtener los indicadores sean TP, FP, TN Y FN; el número de verdaderos positivos (True Positive), falsos positivos (False Positive), verdaderos negativos (True Negative) y falsos negativos (False Negative), respectivamente. Después para los indicadores externos se define lo siguiente: sensibilidad, recuperación o tasa de verdadera positiva:  $TPR=TP/(TP+FN)$ ; precisión o valor predictivo positivo:  $PPV=TP/(TP+FP)$ ; tasa de descubrimiento falso:  $FDR=FP/(FP+TP)$ ; Y la puntuación F1 o la media armónica HM de TPR y PPV:  $F1=2TP/(2TP+FP+FN)$  o  $HM=(2*TPR*PPV)/(TPR+PPV)$ .

Para los indicadores internos se define lo siguiente: especificidad o tasa negativa verdadera:  $SPC=TP/(TP+FN)$ ; valor predictivo negativo:  $NPV=TN/(TN+FN)$ ; exactitud:  $ACC=(TP+TN)/(TP+FP+TN+FN)$ ; tasa de caída o falsos positivos:  $FPR=FP/(FP+TN)$ ; y el área bajo la curva característica de funcionamiento del receptor: AUC.

El resultado de la selección de las regiones de la temperatura de la mama de interés y las fases de extracción de características para el conjunto de datos descrito es una colección de 6590 regiones (2980 de senos normales y 3610 de senos anormales, que deben fusionarse en 659 imágenes según el Ground-Truth). Cada región se caracterizó por un vector de características de 4096 dimensiones extraído de la CNN. Como se menciona, se exploraron cuatro técnicas de clasificación representativas (BN, VTP, J48 y TRF) utilizando el experimento de clasificación más difícil, pero más realista que involucró un esquema de validación cruzada de 2 veces ( $s=2$ ) para entrenamiento y pruebas. La Tabla I resume todos los resultados cuantitativos. VTP y TRF logran los mejores resultados en el experimento de clasificación más difícil pero más realista que involucra la validación cruzada doble; donde el conjunto de datos se divide en dos partes iguales: una (primera parte) utilizada para el entrenamiento y la otra (segunda parte) para pruebas, y luego viceversa; la segunda parte utilizada para el entrenamiento y la primera parte para la prueba. Esto

demuestra que el clasificador es razonable para la clasificación de imágenes termográficas de senos y confirma las ventajas reportadas de VTP y TRF sobre otros clasificadores de vanguardia.

Los resultados cualitativos para la clasificación de las imágenes termográficas de los senos se muestran en la Figura 9 con regiones blancas y azules superpuestas sobre senos normales detectados correctamente (TN, en blanco) y senos anormales correctamente clasificados (TP, en azul). Estos se muestran para ilustrar el buen desempeño de las fases de extracción y clasificación de características. Los resultados muestran que el método de clasificación propuesto puede clasificar las imágenes termográficas de senos con éxito, incluso en entornos con un alto grado de dificultad.




Figura 9: Resultados cualitativos de la clasificación: (a-b) Imágenes termográficas de senos sin cáncer; (c-d) Imágenes termográficas de senos con cáncer.

La Tabla I muestra los resultados cuantitativos; los cuales están representados mediante los colores blanco y azul dentro de la segmentación de las mamas (Figura 9), clasificados como normales (TP, en blanco) y anormales (TN, en azul); esto se muestran para ilustrar el rendimiento de las fases de extracción y clasificación de características. Los resultados muestran que el método de segmentación propuesto puede clasificar las mamas con éxito.

TABLA I  
RESULTADOS (%) DE SEGMENTACIÓN CUANTITATIVA EN EXPERIMENTO DE VALIDACIÓN CRUZADA  $S=2$ .

Técnica	Indicadores de calidad						
	TPR	PPV	FDR	F1-HM	SPC	NPV	ACC
Bayes Net	99.75	100	0	99.88	100	99.70	99.88
Voted Perceptron	100	100	0	100	100	100	100
J48	93.83	99.97	0.03	99.9	99.97	99.8	99.90
Random Forest	100	100	0	100	100	100	100

Se demuestra mediante resultados exitosos que una CNN como parte del método para la detección de cáncer de mama mediante la clasificación de imágenes termográficas de senos es una opción viable para el prediagnóstico de dicha patología, obteniendo los mejores resultados mediante los clasificadores VP y TRF logrando un TPR, SPC y ACC de 100%, respectivamente.

#### IV. DISCUSIÓN, CONCLUSIÓN Y RECOMENDACIONES

Distintos trabajos se han centrado en analizar

automáticamente las imágenes de cáncer de mama en situaciones termográficas prácticas. El objetivo final de los trabajos es clasificar los senos como normales o anormales (sin o con cáncer), por lo que la clasificación de los senos se considera un primer paso crucial para el prediagnóstico de esta patología. Faltan conjuntos de datos de imágenes o escenarios de evaluación accesibles al público que permitan una comparación justa entre los métodos, y el código para los métodos informados no está disponible. Por lo tanto, hemos optado por presentar solo nuestros resultados en imágenes proporcionadas amablemente por [8].

Las principales contribuciones de este trabajo son: la extracción novedosa de las características de la CNN de la región de interés de la imagen termográfica de senos; la generación de imágenes de entrada; capturando información relevante de los senos, para entrenar y alimentar a la CNN, la generación de un conjunto de datos representativos con datos Ground-Truth, y la evaluación de varias estrategias de clasificación para enfrentar el problema de clasificación. Obteniendo los mejores resultados mediante los clasificadores VP y TRF logrando un TPR, SPC y ACC de 100 %, respectivamente.

#### V. REFERENCIAS

- [1] J. H. Vasconcelos, W. P. dos Santos, and de R. C. F. Lima, "Analysis of Methods of Classification of Breast Thermographic Images to Determine their Viability in the Early Breast Cancer Detection". *IEEE Latin America Transactions*, vol. 16, no 6, pp. 1631-1637, 2018. 10.1109/TLA.2018.8444159
- [2] M. A. Díaz-Cortés, N. Ortega-Sánchez, S. Hinojosa, D. Oliva, E. Cuevas, R. Rojas, and A. Demin, "A multi-level thresholding method for breast thermograms analysis using Dragonfly algorithm". *Infrared Phys Technol*, vol. 93, pp. 346-361, 2018. 10.1016/j.infrared.2018.08.007
- [3] M. C. Araújo, R. C. Lima, and R. M. De Souza, "Interval symbolic feature extraction for thermography breast cancer detection". *Expert Syst Appl*, vol. 41, no 15, pp. 6728-6737, 2014. 10.1016/j.eswa.2014.04.027
- [4] N. Cruz-Ramirez., M. M. Efrén, A. A. María Yaneli, M. D. C. M. Enrique, A. M. Héctor Gabriel, P. C. Nancy, and B. M. Rocío Erandi, "Evaluation of the diagnostic power of thermography in breast cancer using bayesian network classifiers". *Comput Math Methods Med*, 2013. 10.1155/2013/264246
- [5] L. A. Bezerra, M. M. Oliveira, T. L. Rolim, A. Conci, F. G. S. Santos, P. R. M. Lyra, and R. C. F. Lima, "Estimation of breast tumor thermal properties using infrared images". *Signal Process*, vol. 93, no 10, pp. 2851-2863, 2013. 10.1016/j.sigpro.2012.06.002
- [6] M. EtehadTavakol, V. Chandran, E. Y. K. Ng, and R. Kafieh, "Breast cancer detection from thermal images using bispectral invariant features". *Int J Therm SCI*, vol. 69, pp. 21-36, 2013. 10.1016/j.ijthermalsci.2013.03.001
- [7] E. Mahmoudzadeh, M. A. Montazeri, M. Zekri, and S. Sadri, "Extended hidden Markov model for optimized segmentation of breast thermography images". *Infrared Phys Technol*, vol. 72, pp. 19-28, 2015. 10.1016/j.infrared.2015.06.012
- [8] L. F. Silva, D. C. M. Saade, G. O. Sequeiros, A. C. Silva, A. C. Paiva, R. S. Bravo, and A. Conci, "A New Database for Breast Research with Infrared Image", *J Med Imaging Health Inform*, vol. 4, no 1, pp. 92-100(9), 2014. 10.1166/jmih.2014.1226
- [9] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk, "SLIC Superpixels Compared to State-of-the-art Superpixel Methods". *IEEE Trans Pattern Anal Mach Intell*, vol. 34, no 11, pp. 2274-2282, 2012. 10.1109/TPAMI.2012.120
- [10] E. Y. K. NG, "Detection and differentiation of breast cancer using neural classifiers with first warning thermal sensors". *Inform Sciences*, vol. 177, no 20, pp. 4526- 4538, 2007. 10.1016/j.ins.2007.03.027
- [11] J. B. MacQueen, "On convergence of k-means and partitions with minimum average variance". *Ann Math Stat*, vol. 36, pp. 1084, 1965.
- [12] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition". *Proceedings of the IEEE*, vol. 86, no 11, pp. 2278-2324, 1998. 10.1109/5.726791
- [13] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks". *Adv Neural Inf Process Syst*, vol. 25, no 2, pp. 1097-1105, 2012. 10.1145/3065386
- [14] G. Holmes, A. Donkin and I. H. Witten, "Weka: A machine learning workbench". Presented at IEEE Second Australian and New Zealand Conference on Intelligent Information Systems, 1994. 10.1109/ANZIIS.1994.396988
- [15] S. R. Garner, S. J. Cunningham, G. Holmes, C. G. Nevill-Manning and I. H. Witten, "Applying a machine learning workbench: Experience with agricultural databases". Presented at Proceeding Machine Learning in Practice Workshop, Machine Learning Conference, 1995.
- [16] J. Pearl, "Causality: Models, Reasoning, and Inference". *Econ Theory*, vol. 19, no 46, pp. 675-685, 2003. 10.1017/S0266466603004109
- [17] M. Collins, and N. Duffy, "New ranking algorithms for parsing and tagging: Kernels over discrete structures, and the voted perceptron". *Proceedings of the 40th annual meeting on association for computational linguistics*, pp. 263-270, 2002. 10.3115/1073083.1073128
- [18] S. Ponmani, R. Samuel, and P. VidhuPriya, "Classification Algorithms in Data Mining-A Survey". *International Journal of Advanced Research in Computer Engineering & Technology*, vol. 6, 2017.

#### VI. BIOGRAFÍA

**Diana Morales-Venegas.** Recibió el título de Ingeniero de Software en 2016 por la Universidad Autónoma de Chihuahua, México; y en 2019 recibió el título de Maestro en Ingeniería Mecatrónica por parte del Instituto Tecnológico Superior de Lerdo, México. Su interés de investigación es el procesamiento de distintos tipos de imágenes digitales mediante la inteligencia artificial.

**Santiago Tello-Mijares.** Recibió el título de Ingeniero en Electrónica en 2006, y el de Doctor en Ciencias Eléctricas en 2013, por parte del Instituto Tecnológico de la Laguna, México; y en 2017 recibió el título de Doctor en Ingeniería Informática y de Telecomunicación por parte de la Universidad Autónoma de Madrid, España, obteniendo Mención Cum Laude. En la actualidad es Profesor Titular A e Investigador Científico del Departamento de Postgrado de Mecatrónica del Instituto Tecnológico Superior de Lerdo, México. Es candidato al SNI por parte del CONACYT. Sus intereses de investigación son el procesamiento de imágenes biomédicas y la inteligencia artificial.