

Recibido 12 de septiembre de 2022. Aceptado 12 de diciembre de 2022. Publicado 23 de diciembre de 2022.

ISSN: 2448-7775

Procesamiento Automático de Imágenes de la data HAM10000 usando aprendizaje automático

ANDERSON SMITH FLOREZ FUENTES*, RAFAEL GUZMAN CABRERA, EVERARDO VARGAS RODRIGUEZ.

Universidad de Guanajuato.

*Autor de Correspondencia: as.florezfuentes@ugto.mx

RESUMEN Cada vez es más popular el uso de procesamiento de imágenes en la identificación, diagnóstico y seguimiento de cáncer de piel. En este trabajo, se presentan resultados obtenidos utilizando diferentes filtros de imágenes como parte del preprocesamiento de estas antes de llevar a cabo la clasificación automática. Para la evaluación experimental se utiliza un escenario de clasificación llamado validación cruzada utilizando imágenes de la base de datos Human Against Machine con 10000 imágenes (HAM10000), la cual cuenta con siete clases. Para la clasificación automática se utiliza un modelo basado en redes neuronales, con el cual se obtuvieron resultados que alcanzaron el 99.5% en el mejor resultado, y un resultado promedio equivalente a 85.83%, resaltando que la medición de los resultados, se realizó de manera separada por cada par de grupo de cáncer de piel, con las mismas condiciones para cada ejecución realizada.

PALABRAS CLAVE— Validación Cruzada, Redes Neuronales, HAM10000, Cáncer de Piel.

I. INTRODUCCIÓN

Según el [1] para el 2020 México cuenta con 2051 nuevos casos de melanomas de piel, ocupando el lugar 21 en la clasificación de cáncer más detectados en el país, de igual manera ocupa el lugar 21 con 773 muertes por este tipo de cáncer, teniendo en cuenta los datos epidemiológicos analizados por [2] donde respaldan que la exposición al sol y las quemaduras solares en edades tempranas generan un mayor riesgo a desarrollar un cáncer de piel, considerando el gran número de personas afectadas por el cáncer de piel, es de considerar que México se encuentra entre uno de los países con mayor niveles de irradiación[3], brindando aún más confianza en poder construir una herramienta que permita la detección temprana de cáncer de piel.

En esta etapa de la investigación, la presentación y medición de avances adelantados, nos permite analizar el comportamiento que tiene el sistema inteligente propuesto, el cual fue entrenado y probado con la HAM10000[4], si bien se ha realizado diferentes formas de detectar el cáncer de piel, como la conversión en ondas de audio [5], o la implementación de imágenes 3D donde el autor [6] presenta una perspectiva totalmente diferente en la implementación del análisis de cáncer de piel con las muestras analizadas, como estos procedimientos y otros que se puedan encontrar, representan un gran esfuerzo por atacar una problemática a la cual no se es ajena, es por ello que en este trabajo se presenta una posible alternativa, para la detección de cáncer de piel, como lo es la validación cruzada, para ellos es necesario entender que otros avances se han adelantado en el estudio, lo que encontraremos en la unidad II el estado del arte,

posteriormente se encuentra en la unidad III, el desarrollo de esta investigación, iniciando por la etapa de preprocesamiento la cual es importante, ya que da una orientación de qué forma se están manejando los datos a analizar, en este caso las imágenes de cáncer de piel, también la metodología utilizada y la forma en la que se ejecutó el procedimiento, por último se encuentra un análisis de los resultados obtenidos y se cierra con las conclusiones a este trabajo.

II. ESTADO DEL ARTE

En la actualidad se pueden evidenciar trabajos como el de [7] quien presenta de manera organizada el análisis de múltiples trabajos de investigación, entre estos análisis presentan 15 datos totalmente diferente, la cuales se han utilizado en diferentes trabajos de investigación, trabajos que han marcado una diferencia desde sus inicios, la manera en la que se presentan permite analizar las ejecuciones obtenidas por cada uno de los autores analizados. Es importante considerar también el trabajo presentado por [8] que centra su investigación en la implementación de los métodos Asimetría, Borde, Color y Diferencias estructurales (ABCD), Seven-points y Menzies, también orienta su redacción en la arquitectura de visión artificial implementados como son las Redes Neuronales Convolucionales (CNN).

De igual forma [9], [10] presentan como es el proceso de detección de cáncer de piel, resaltando la etapa de preprocesamiento y resultados, dentro del material consultado, es importante resaltar que, si bien muchos

autores no involucran en sus aportaciones la etapa del preprocesamiento y condiciones mínimas utilizadas para el desarrollo del sistema inteligente, es un proceso que no se puede dejar pasar por alto, teniendo en cuenta que esto mejora considerablemente los resultados obtenidos, al igual que los tiempos de ejecución de la solución informática.

Caso diferente se encuentra en el documento de revisión de [11] quien centra su investigación en un extenso análisis bibliográfico, enunciando los diferentes proyectos realizados entre 2015 a 2021, permitiéndole realizar un análisis de los diferentes comportamientos en la detección de cáncer de piel.

Por otro lado tenemos, la investigación presentada por [12] implementa el método ResNet-152, logrando el reconocimiento de 12 anomalías de piel, en el procedimiento realizado por el autor, presenta el análisis a 2 diferentes tipos de datos (MED-NODE dataset, atlas site images o Edimburgo), si bien la cantidad de imágenes implementadas en el entrenamiento, el autor realiza la implementación de los métodos ResNet-152, Microsoft Research Asia, Beijing, China, pero centra los resultados obtenidos en el ResNet-152 con el que obtiene resultados igual a 0.96 en AUC, con la data Asan y 0.91 con la data Edimburgo.

En la carrera por verificar la efectividad de los sistemas inteligentes construidos, es la confrontación entre humano máquina, con el fin de realizar procesos más eficientes, en este sentido [13] presenta un trabajo que integra la experiencia profesional de especialistas en piel y los sistemas inteligentes, Los resultados obtenidos en la precisión media es de 89.2%, este análisis de expertos permite tener consideraciones con valores igual a 66%, teniendo en cuenta que los grupos que varían entre 14 a 30 expertos en detección. Por otro lado [14] realiza la comparación de los resultados obtenidos de una CNN con 58 dermatólogos, demostrando una vez más, la eficiencia que obtienen las CNN, eficiencia en tiempo y en resultados.

Igualmente los trabajos presentados por [15], [16] siguen demostrando la eficiencia de las CNN, aunque en esta ocasión se implementan 595 secciones de imágenes cortadas de portaobjetos histopatológicos de 595 pacientes individuales de las cuales 300 nevos y 295 melanomas adicional se manejaron 100 imágenes de prueba, generando un 18% de entradas erróneas para melanomas y 20% para nevos, estos tipos de cáncer se analizaron por separado analizadas por separado y 19% para el conjunto analizado completo. Por otro lado, se implementa la CNN en la data ISIC2018 la cual contienen 12378 imágenes, de igual forma el autor realiza el entrenamiento para los melanomas y un entrenamiento para nevus.

Es de resaltar también el preprocesamiento realizado por Tumpa [17], el cual realizar la eliminación de ruido, cabello, burbujas y otras imperfecciones existentes en las imágenes

(ISIC y PH2), posteriormente implementa los métodos red neuronal artificial (Artificial Neural Network por sus siglas ANN), Maquinas de soporte vectorial (Support Vector Machine SVM), Fuzzy C-Means, k-vecinos más cercanos (K-Nearest-Neighbor kNN), algoritmo Otsu Thresholding, una vez aplicado el preprocesamiento y la aplicación del modelo inteligente obtiene un resultado equivalente 97%, por otro lado [18] implementa el modelo resnet-50, DenseNet-201, entre otros, también realiza un desglose de las datos implementadas en el análisis realizado e implementado en el modelo que consolida. para la preparación de datos utiliza un canal RGB normalizado a [0,1], y se realiza una redimensión de 192x256 pixeles mediante interpolación bilineal, la gran diferencia entre los dos procesos, es la gran cantidad de imágenes que implementa [18], además de los resultados obtenidos en la implementación de los modelos CNN (Inception-v3, ResNet-50, Inception ResNet-v2 y DenseNet-201), los cuales alcanzan umbral ente 73.44 hasta 89,28%, este último en la aplicación del modelo ResNet-50 con la data ISIS 2018.

Continuando con la implementación de la inteligencia artificial [19] implementa de los métodos SVM, kNN, y la unión de los dos métodos, además la cantidad de imágenes que implementa son pocas para generar buenos resultados. El entrenamiento lo realizan con un set de datos propio, adicional el proceso de alistamiento realizado suavizado gaussiano, en la operación de convolución 2D, en el proceso de extracción de características, realiza varias combinaciones de colores, como son RGB, GLCM, HSV, NTSc, entre otros filtros de imágenes para su verificación. Además calcula color promedio, asimetría en la distribución, varianza de la distribución, y la variación de la distribución.

De igual manera la implementación que realiza [20] con los modelos de CNN, donde utiliza (VGG19, Inception V3, InceptionResnetV2, ResNet50, Xception y MobileNet), el autor realiza el aprendizaje en dos tiempos, el primero lo realiza con las imágenes que contiene, pasándola por cada uno de los modelos de precisión con valores promedio de 0.82 para imágenes no repetidas y 0.90 para imágenes repetidas. La precisión obtenida con Xception Net precisión, le permite llegar a 0.94 con recall de 0,94 para el Melanocytic Nevi.

Dando continuidad a la variabilidad de métodos, modelos, herramientas implementadas para la detección de [21] como la aplicación Deep Learning Studio (DLS) para ejecutar el modelo, para que el modelo sea efectivo y no aprenda rutas, utiliza el método de abandono a .25 y .50 para acelerar el entrenamiento, los procedimientos utilizados le permiten obtener AUC de 99.77 dentro de los resultados de manera general los resultados varían entre 94.24 a 98.19. En esta implementación se utiliza la data HAM10000.

III. DESARROLLO

A. DATA

Para esta implementación se tiene en cuenta la data HAM10000[4] siglas de Human Against Machine, la cual cuenta con 7 tipos de cáncer, Queratosis actínicas y carcinoma intraepitelial / enfermedad de Bowen (akiec), carcinoma de células basales (bcc), lesiones benignas tipo queratosis (lentigos solares / queratosis seborreicas y queratosis tipo liquen-planus, bkl), dermatofibroma (df), melanoma (mel), nevos melanocíticos (nv) y lesiones vasculares (angiomas, angioqueratomas, granulomas piógenos y hemorragias, vasc). Las imágenes contenidas en la HAM10000 son imágenes manualmente etiquetadas. En la Fig. 1 podemos visualizar los tipos de cáncer de piel y las cantidades de imágenes contenidas en cada muestra.

En la Fig. 2 Se puede evidenciar grupos de imágenes perteneciente a la data HAM10000 en implementadas en el procesamiento de prueba y entrenamiento de la red neuronal, de igual forma se evidencia la variabilidad de anomalías contenidas entre los mismos tipos de cáncer, además de los diferentes factores que generan ruido, como el cabello, las tonalidades de la piel, lunares cercanos a la zona afectada, entre otros, los cuales deben ser eliminados en el preprocesamiento para generar una identificación más exacta de cáncer de piel.

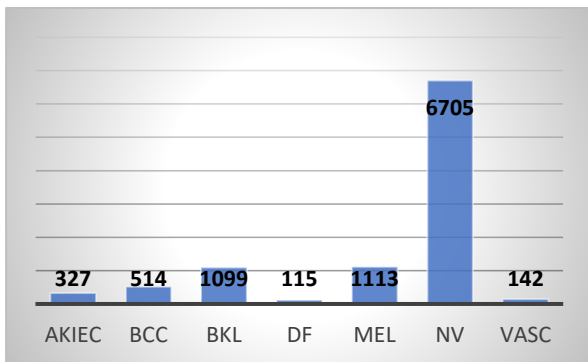


Fig. 1. Data HAM10000.



Fig. 2. Imágenes de la HAM10000 fuente: imágenes HAM10000

B. PREPROCESAMIENTO

Para contrastar el funcionamiento del sistema con varios filtros, en esta ejecución se realiza el procedimiento con las imágenes originales, esta determinación se llegó, teniendo en cuenta que, se aplicaron los filtros canny, RGB, binario, escala a grises y las imágenes originales a color. Se trabajo con el 100% de las imágenes del HAM10000, en todas las etapas del proceso. Todo el procedimiento realizado para la implementación de los filtros, se manejaron en los tamaños originales.

C. METODOLOGÍA

Una vez escogida las imágenes de entrenamiento y prueba, se procedió con anticipación a probar 5 modelos, como lo son: kNN, SVM, arboles de decisión (TREE), Naive Bayes, redes neuronales. Teniendo en cuenta los resultados obtenidos en la implementación de cada uno de los modelos anteriormente citados, en los filtros definidos, se realiza todo el procedimiento de entrenamiento y prueba con las imágenes a color y el modelo de redes neuronales, y realizar una validación cruzada para analizar el comportamiento del algoritmo y evitar el underfitting.

D. EJECUCIÓN

Al tener 7 tipos de cáncer, inicia el procedimiento con el akiec, el cual se incluye como grupo de entrenamiento, este grupo es probado con los otros 6 tipos de cáncer restantes, para analizar el comportamiento de la red neuronal, procedimiento que se repite para cada tipo de cáncer de piel con los 6 tipos restantes, de igual manera se realiza la ejecución de entrenamiento y prueba con los mismos tipos de cáncer, generando una matriz de ejecución más completa. En este proceso se tiene en cuenta la metodología propuesta en la Fig. 3, con el cual se obtienen resultados óptimos, en este procedimiento se ejecutó teniendo en cuenta la cantidad de datos relacionados anteriormente para el entrenamiento. Esta implementación es el producto de la ejecución de los modelos kNN, Tree, SVM, Naive Bayes y Redes Neuronales, la ejecución fue realizada con anticipación encontrando un procedimiento eficiente para predecir de manera correcta y efectiva la detección de cáncer de piel.

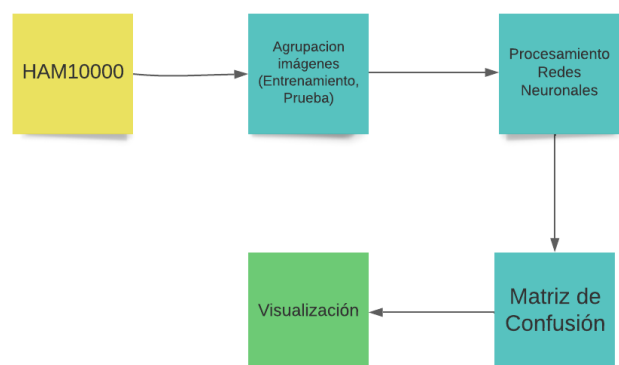


Fig. 3. Metodología implementada. Fuente: Propia.

E. RESULTADOS

Los valores obtenidos en las 49 ejecuciones presentadas para poder validar la eficiencia de la red neuronal implementando validación cruzada cuyos resultados se ven en la [Tabla I](#), demostrando de manera general la eficiencia de la red neuronal, generando un resultado promedio equivalente a 85.83% para la validación realizada, es de aclarar que estos resultados se obtienen de la implementación de la red neuronal con los datos cargados de HAM10000, en esta validación no se eliminan las muestras de cáncer de piel para tener un mayor número de muestras para entrenar y realizar las pruebas. De igual manera se pueden ejecutar otros procedimientos como el dropout o leave one out, para garantizar un mejor funcionamiento del modelo, pero la demanda de ejecución del algoritmo hace que este proceso sea costoso, por eso se brinda la alternativa de la validación cruzada para garantizar así, la efectividad del modelo, que en este caso supera muchos indicadores humanos, como lo demuestran [14], [15], donde los resultados obtenidos por profesionales en dermatología, los cuales no superan el 60% y cuyos tiempos de análisis de grupos imágenes demanda alrededor de 4 semanas.

Como se puede evidenciar el mejor resultado obtenido en la implementación de la red neuronal es el obtenido por melanocytic nevi (nv) con 99.5% de exactitud, este resultado es obtenido en la implementación de vasc como data de entrenamiento y nv como data de prueba, si bien el comportamiento del entrenamiento de la red neuronal dio buenos resultados con el dataset implementado con imágenes originales a color, los resultados obtenidos por el tipo de cáncer vasc como imágenes de entrenamiento, genera de manera constante con cada tipo de cáncer unos buenos resultados. Estos resultados obtenidos son comparables con los obtenidos en algunos de los resultados con la implementación de la red neuronal, teniendo en cuenta los resultados de los autores citados en este documento.

En la [Tabla II](#) se puede observar, que los resultados obtenidos, se encuentran en un alto rango de resultados, dejando muestras a considerar para implementar sistemas inteligentes que no cumplan con estos rangos.

TABLA I. RESULTADOS EJECUCIÓN RED NEURONAL. FUENTE: PROPIA.

TEST/TRAIN	AKIEC	BCC	BKL	DF	MEL	NV	VASC
AKIEC	64.3	93.7	68.3	89.6	76.9	64.5	98.1
BCC	82.7	84.9	84.3	90.5	82.4	77.6	95.8
BKL	87.9	90.6	86.4	94.8	79.5	68.5	96.4
DF	88	77.3	75	90.4	89.6	40.2	91.4
ME	90.9	96.5	81.1	95.3	87.2	60.2	98.7
NV	98.4	98.2	94.7	99	92.4	79.2	99.5
VASC	98.5	93.9	92.1	95	87	70	88.5

TABLA II. RANGO DE RESULTADOS DE DETECCIÓN DE CÁNCER DE PIEL.

REFERENCIA	MODELO	RESULTADO
[17]	ANN, SVM, Fuzzy C-Means	97%
[18]	ResNet-50	89%
[20]	CNN (Xception Net Precision)	94%
[21]	Deep Learning Studio - DLS	99.77%
ESTE TRABAJO	Red Neuronal	99.5%

IV. CONCLUSIONES

Si bien las ejecuciones realizadas con las redes neuronales tienen a aprender generando overfitting, en este procedimiento se llevó a cabo un procedimiento de validación cruzada, el cual disminuye este proceso, generando resultados óptimos, en mejores ejecuciones, y al ser un solo proceso, se disminuye el tiempo de ejecución del algoritmo pasando de 25.032 a 13.81 minutos en la ejecución por par de imágenes cruzadas en el entrenamiento con las imágenes configuradas en una validación cruzada, es de aclarar que las ejecuciones se realizan desde un equipo MacBook Air chip M1, ram 8 GB, ejecutado por medio de jupyter-lab, en la ejecución de estos resultados, se logra alcanzar un resultado promedio igual al 85.83%.

Es por ello por lo que, es importante seguir aunando esfuerzos para mejorar los indicadores de resultados de los sistemas propuestos para realizar una detección de cáncer de piel de manera temprana y eficiente. Actualmente si bien los resultados obtenidos son eficientes, se hace necesario continuar las pruebas, incluyendo modelos como el ResNet-150, ResNet-201, entre otros CNN, que permitan mejorar los resultados obtenidos en el entrenamiento, al igual que la implementación de datos, que contengan muchas más muestras de cáncer de piel.

REFERENCIAS

- [1] W. H. O. WHO, "Mexico", 2021. Consultado: oct. 08, 2022. [En línea]. Available: <https://gco.iarc.fr/today/data/factsheets/populations/484-mexico-fact-sheets.pdf>
- [2] A. Zkik y G. Berdeaux, "Prevalence And Risk Factors Of Skin Cancer In Mexico: An Observational Study", *Value in Health*, vol. 18, núm. 7, p. A438, nov. 2015, doi: 10.1016/j.jval.2015.09.1067.
- [3] J. M. Belman-Flores, G. Camacho-Vázquez, y A. P. Rodríguez-Muñoz, "A review of hybrid systems including photovoltaic solar energy: General aspects in Mexico", *Journal of Renewable and Sustainable Energy*, vol. 8, núm. 4, p. 044701, jul. 2016, doi: 10.1063/1.4960404.
- [4] P. Tschandl, C. Rosendahl, y H. Kittler, "The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions", *Sci Data*, vol. 5, ago. 2018, doi: 10.1038/SDATA.2018.161.
- [5] A. Dascalu y E. O. David, "Skin cancer detection by deep learning and sound analysis algorithms: A prospective clinical study of an elementary dermoscope", *EBioMedicine*, vol. 43, pp. 107–113, may 2019, doi: 10.1016/j.ebiom.2019.04.055.
- [6] F. H. Silver, T. Deshmukh, N. Kelkar, K. Ritter, N. Ryan, y H. Nadiminti, "The 'Virtual Biopsy' of Cancerous Lesions in 3D: Non-Invasive Differentiation between Melanoma and Other Lesions Using Vibrational Optical Coherence Tomography", *Dermatopathology*, vol.

- 8, núm. 4, pp. 539–551, dic. 2021, doi: 10.3390/dermatopathology8040058.
- [7] M. Goyal, T. Knackstedt, S. Yan, y S. Hassanpour, “Artificial intelligence-based image classification methods for diagnosis of skin cancer: Challenges and opportunities”, *Comput Biol Med*, vol. 127, p. 104065, dic. 2020, doi: 10.1016/J.COMPBIOMED.2020.104065.
- [8] K. Munir, H. Elahi, A. Ayub, F. Frezza, y A. Rizzi, “Cancer diagnosis using deep learning: A bibliographic review”, *Cancers (Basel)*, vol. 11, núm. 9, sep. 2019, doi: 10.3390/cancers11091235.
- [9] K. Das *et al.*, “Machine learning and its application in skin cancer”, *International Journal of Environmental Research and Public Health*, vol. 18, núm. 24, MDPI, dic. 01, 2021. doi: 10.3390/ijerph182413409.
- [10] M. Dildar *et al.*, “Skin cancer detection: A review using deep learning techniques”, *International Journal of Environmental Research and Public Health*, vol. 18, núm. 10, MDPI AG, may 02, 2021. doi: 10.3390/ijerph18105479.
- [11] D. Popescu, M. El-Khatib, H. El-Khatib, y L. Ichim, “New Trends in Melanoma Detection Using Neural Networks: A Systematic Review”, *Sensors*, vol. 22, núm. 2, MDPI, ene. 01, 2022. doi: 10.3390/s22020496.
- [12] S. S. Han, M. S. Kim, W. Lim, G. H. Park, I. Park, y S. E. Chang, “Classification of the Clinical Images for Benign and Malignant Cutaneous Tumors Using a Deep Learning Algorithm”, *Journal of Investigative Dermatology*, vol. 138, núm. 7, pp. 1529–1538, jul. 2018, doi: 10.1016/j.jid.2018.01.028.
- [13] A. Hekler *et al.*, “Superior skin cancer classification by the combination of human and artificial intelligence”, *Eur J Cancer*, vol. 120, pp. 114–121, oct. 2019, doi: 10.1016/j.ejca.2019.07.019.
- [14] H. A. Haenssle *et al.*, “Man against Machine: Diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists”, *Annals of Oncology*, vol. 29, núm. 8, pp. 1836–1842, ago. 2018, doi: 10.1093/annonc/mdy166.
- [15] T. J. Brinker *et al.*, “Deep learning outperformed 136 of 157 dermatologists in a head-to-head dermoscopic melanoma image classification task”, *Eur J Cancer*, vol. 113, pp. 47–54, may 2019, doi: 10.1016/j.ejca.2019.04.001.
- [16] A. Hekler *et al.*, “Pathologist-level classification of histopathological melanoma images with deep neural networks”, *Eur J Cancer*, vol. 115, pp. 79–83, jul. 2019, doi: 10.1016/j.ejca.2019.04.021.
- [17] P. P. Tumpa y M. A. Kabir, “An artificial neural network based detection and classification of melanoma skin cancer using hybrid texture features”, *Sensors International*, vol. 2, p. 100128, 2021, doi: 10.1016/j.sintl.2021.100128.
- [18] M. A. Al-masni, D. Kim, y T. Kim, “Multiple skin lesions diagnostics via integrated deep convolutional networks for segmentation and classification”, *Comput Methods Programs Biomed*, vol. 190, p. 105351, 2020, doi: 10.1016/j.cmpb.2020.105351.
- [19] R. Sumithra, M. Suhil, y D. S. Guru, “Segmentation and classification of skin lesions for disease diagnosis”, en *Procedia Computer Science*, 2015, vol. 45, núm. C, p. 85. doi: 10.1016/j.procs.2015.03.090.
- [20] S. Jain, U. Singhanía, B. Tripathy, E. A. Nasr, M. K. Aboudaif, y A. K. Kamrani, “Deep learning-based transfer learning for classification of skin cancer”, *Sensors*, vol. 21, núm. 23, dic. 2021, doi: 10.3390/s21238142.
- [21] M. A. Kadampur y S. al Riyae, “Skin cancer detection: Applying a deep learning based model driven architecture in the cloud for classifying dermal cell images”, *Inform Med Unlocked*, vol. 18, p. 100282, ene. 2020, doi: 10.1016/J.IMU.2019.100282.


BIOGRAFÍAS



ANDERSON FLOREZ FUENTES Estudiante Doctorado en Ciencias de la Ingeniería, 3^{er} semestre, en el Departamento de Estudios Multidisciplinarios, División de Ingenierías, Campus Irapuato-Salamanca, Magister en Educación, Ingeniero de Sistemas, Investigador Asociado – Colciencias Colombia.



EVERARDO VARGAS RODRÍGUEZ Es Ingeniero Electrónico, Maestro en Ingeniería Eléctrica y Doctor en Optoelectrónica, este último por la Universidad de Southampton del Reino Unido. Su trabajo de investigación se enfoca en el diseño, modelado e implementación de sensores optoelectrónicos. Además, ha colaborado con grupos multidisciplinarios en la aplicación métodos y técnicas de modelado matemático a temas de Ingeniería Industrial, negocios y problemas sociales. En el área de investigación ha publicado más de 45 artículos en revistas de reconocida calidad a nivel internacional. Desde el año 2018 es miembro del Comité de Editores Académicos del Journal of Sensors y miembro del Sistema Nacional de Investigadores Nivel II.



RAFAEL GUZMÁN CABRERA Profesor Titular del departamento de Ingeniería Eléctrica de la División de Ingenierías del Campus Irapuato-Salamanca de la Universidad de Guanajuato desde hace 21 años. Dr. en Reconocimiento de Formas e Inteligencia Artificial por la Universidad Politécnica de Valencia, España. Miembro de la Academia Mexicana de Ciencias, SNI-1. Miembro del cuerpo académico de física aplicada y tecnologías avanzadas.