

Use of Convolutional Neural Networks in Smartphones for the Identification of Oral Diseases Using a Small Dataset

Jesús-David González; Jormany Quintero-Rojas

Citación: J.-D. González, J. Quintero-Rojas, “Use of Convolutional Neural Networks in Smartphones for the Identification of Oral Diseases Using a Small Dataset,” *Revista Facultad de Ingeniería*, vol. 30 (55), e11846, 2021. <https://doi.org/10.19053/01211129.v30.n55.2021.11846>

Recibido: Octubre 08, 2020; **Aceptado:** Enero 28, 2021;

Publicado: Febrero 06, 2021

Derechos de reproducción: Este es un artículo en acceso abierto distribuido bajo la licencia [CC BY](https://creativecommons.org/licenses/by/4.0/)



Conflicto de intereses: Los autores declaran no tener conflicto de intereses.

Use of Convolutional Neural Networks in Smartphones for the Identification of Oral Diseases Using a Small Dataset

Jesús-David González¹

Jormany Quintero-Rojas²

Abstract

Image recognition and processing is a suitable tool in systems using machine learning methods. The addition of smartphones as complementary tools in the health area for diagnosis is a fact nowadays due to the advantages they present. Following the trend of providing tools for diagnosis, this research aimed to develop a prototype mobile application for the identification of oral lesions, including potentially malignant lesions, based on convolutional neural networks, as early detection of indications of possible types of cancer in the oral cavity. A mobile application was developed for the Android operating system that implemented the TensorFlow library and the Mobilenet V2 convolutional neural network model. The training of the model was performed by transfer learning with a database of 500 images distributed in five classes for recognition (Leukoplakia, Herpes Simplex Virus Type 1, Aphthous stomatitis, Nicotinic stomatitis, and No lesion). The 80% of the images were used for training and 20% for validation. It was obtained that the application presented at least 80% precision in the recognition of four class. The f1-score and area under curve metrics were used to evaluate performance. The developed mobile application presented an acceptable performance with metrics higher than 75% for the recognition of three lesions, on the other hand, it yielded an unfavorable performance lower than 70% for identifying nicotinic stomatitis cases with the chosen dataset.

¹ Universidad de Los Andes (Mérida, Venezuela). ORCID: [0000-0002-9828-0594](https://orcid.org/0000-0002-9828-0594)

² M. Sc. Universidad de Los Andes (Mérida, Venezuela). jormany@ula.ve. ORCID: [0000-0002-7180-4685](https://orcid.org/0000-0002-7180-4685)

Keywords: artificial intelligence; dentistry; machine learning; medical technology; oral diagnosis; oral disease identification; preventive medicine; smartphone.

Uso de redes neuronales convolucionales en teléfonos inteligentes para la identificación de enfermedades bucales empleando un pequeño conjunto de datos

Resumen

El reconocimiento y procesamiento de imágenes es una herramienta adecuada en los sistemas que usan métodos de aprendizaje automático. La adición de teléfonos inteligentes como herramientas complementarias en el área de la salud para el diagnóstico es un hecho hoy en día por las ventajas que presentan. Siguiendo la tendencia de proporcionar herramientas para el diagnóstico, esta investigación tuvo como objetivo desarrollar una aplicación móvil prototipo para la identificación de lesiones bucales, incluyendo lesiones potencialmente malignas, basado en redes neuronales convolucionales, como la detección temprana de indicios de posibles tipos de cáncer en la cavidad bucal. Se desarrolló una aplicación móvil para el sistema operativo Android que implementó la librería de *TensorFlow* y el modelo de redes neuronales convolucionales *Mobilenet V2*. El entrenamiento del modelo se realizó por transferencia de aprendizaje con una base de datos de 500 imágenes distribuidas en cinco clases para el reconocimiento (Leucoplasia, Herpes Simple Virus Tipo 1, Estomatitis aftosa, Estomatitis nicotínica y Sin lesión). Se utilizó el 80% de las imágenes para el entrenamiento y el 20% para la validación. Se obtuvo que la aplicación presentó al menos 80% de exactitud en el reconocimiento de cuatro clases. Se usaron las métricas de f1-valor y área bajo la curva para evaluar el desempeño. La aplicación móvil desarrollada presentó un comportamiento aceptable con métricas mayores al 75% para el reconocimiento de tres lesiones, por otro lado, arrojó un desempeño desfavorable menor al 70% para identificar los casos de estomatitis nicotínica con el conjunto de datos elegido.

Palabras clave: aprendizaje automático; diagnóstico bucal; identificación de enfermedades bucales; inteligencia artificial; medicina preventiva; odontología; tecnología médica; teléfonos inteligentes.

Uso de redes neurais convolucionais em smartphones para identificação de doenças bucais por meio de um pequeno conjunto de dados

Resumo

O reconhecimento e processamento de imagens é uma ferramenta adequada em sistemas que usam métodos de aprendizado de máquina. A incorporação dos smartphones como ferramentas complementares na área da saúde para o diagnóstico é um fato hoje pelas vantagens que apresentam. Seguindo a tendência de disponibilizar ferramentas de diagnóstico, esta pesquisa teve como objetivo desenvolver um protótipo de aplicativo mobile para identificação de lesões bucais, inclusive lesões potencialmente malignas, com base em redes neurais convolucionais, como a detecção precoce de indícios de possíveis tipos de câncer na região. cavidade oral. Um aplicativo móvel foi desenvolvido para o sistema operacional Android que implementou a biblioteca TensorFlow e o modelo de rede neural convolucional Mobilenet V2. O treinamento do modelo foi realizado por transferência de aprendizagem com um banco de dados de 500 imagens distribuídas em cinco classes de reconhecimento (Leucoplasia, Herpes Simplex Vírus Tipo 1, Estomatite aftosa, Estomatite nicotínica e Sem lesão). 80% das imagens foram utilizadas para treinamento e 20% para validação. Obteve-se que o aplicativo apresentou acerto de pelo menos 80% no reconhecimento de quatro classes. As métricas do valor f1 e da área sob a curva foram usadas para avaliar o desempenho. O aplicativo mobile desenvolvido apresentou comportamento aceitável com métricas superiores a 75% para o reconhecimento de três lesões, por outro lado, apresentou desempenho desfavorável inferior a 70% para identificar casos de estomatite nicotínica com o conjunto de dados escolhido.

Palavras-chave: aprendizado de máquina; diagnóstico oral; identificação de doenças bucais; inteligência artificial; medicina preventiva; odontologia; tecnologia médica; telefones inteligentes.

I. INTRODUCCIÓN

El diagnóstico de las enfermedades se basa en el reconocimiento y análisis de los hallazgos clínicos, referidos a los signos y síntomas alterados que el individuo presenta en un momento dado [1]. Un síntoma, es la percepción subjetiva del paciente relacionado con la enfermedad, mientras que el signo es registrado objetivamente por el profesional de la salud. Algunas manifestaciones son características de ciertas enfermedades, en otras, los estudios complementarios son indispensables para llegar al diagnóstico definitivo [2]. En el momento del examen clínico, la observación de la mucosa bucal y de la piel, son indicadores para orientar al experto a un diagnóstico presuntivo.

Durante la inspección clínica, los profesionales de la salud se apoyan en herramientas manuales, electrónicas y de software para obtener un diagnóstico preciso. Entre las herramientas de software existentes, destacan las basadas en métodos de inteligencia artificial (IA) para simplificar y mejorar las actividades clínicas [3]. La continua evolución de la tecnología ha hecho que las herramientas de diagnóstico evolucionen e incluyan otros medios para desarrollar estas actividades a distancia. En este contexto, el uso de dispositivos móviles en las actividades de diagnóstico médico es cada vez mayor, un ejemplo de ello es la teleodontología, que ha impulsado el uso de múltiples plataformas de comunicación entre los pacientes y el odontólogo utilizando la cámara del teléfono para capturar la lesión y procesarla por aplicaciones móviles [4, 5]. En el mercado actual de aplicaciones, algunas apoyan tanto al médico como al paciente, aportando soluciones que incluyen el descarte de síntomas a través de múltiples preguntas, obteniendo un posible diagnóstico con base en las respuestas recibidas [6].

Actualmente, existen casos de aplicaciones que utilizan Redes Neuronales Artificiales (RNA) para identificar lesiones utilizando una base de datos de más de 12000 imágenes, aplicaciones que tratan de diagnosticar mediante algún método de RNA, tomando una fotografía para dar un diagnóstico médico con un alto porcentaje de precisión [7]. Las Redes Neuronales Convolucionales (RNC) siguen siendo pioneras en los métodos de Aprendizaje Automático (AA) por su tolerancia a fallos y facilidad de inserción con la tecnología existente [8]. Estas RNC se pueden

configurar utilizando *TensorFlow*, una librería de código abierto para el entrenamiento y desarrollo de modelos de AA desarrollada por *Google*®. La unidad base es el tensor, que puede verse como una matriz de datos multidimensional que incluye información de la imagen como el ancho, la longitud en píxeles y cada canal de color [9].

Las herramientas actuales de IA que apoyan al odontólogo se basan en el análisis de imágenes radiográficas y de tomografía computarizada [10]. Sin embargo, la evidencia que apoyan el diagnóstico bucal de las enfermedades de los tejidos blandos utilizando la visión artificial, los teléfonos móviles y las imágenes clínicas son escasas y limitadas. Disponer de una aplicación móvil que pueda diagnosticar en tiempo real con una simple imagen utilizando el hardware y el software de los teléfonos inteligentes en tiempo real es ventajoso, ya que puede utilizarse para guiar a los profesionales de la salud a la hora de realizar un diagnóstico más preciso. Estas herramientas pueden servir de apoyo para aquellos odontólogos que trabajan y realizan actividades en zonas rurales donde el acceso a un especialista es difícil y complicado. En este sentido, el propósito de este trabajo fue desarrollar un prototipo de aplicación móvil para la identificación de lesiones bucales basado en redes neuronales convolucionales.

II. METODOLOGÍA

En el presente apartado se describen los datos, técnicas y metodología utilizada para el desarrollo del proyecto.

A. Conjunto de datos

El conjunto de datos utilizado en este trabajo se construyó con imágenes encontradas en internet para cada enfermedad utilizando la búsqueda web. Se usaron 500 imágenes diferentes distribuidas en 5 clases de la siguiente manera: 97 imágenes de leucoplasia, 101 imágenes de estomatitis aftosa, 74 imágenes de estomatitis nicotínica, 110 imágenes de VHS-1 y se incluyó 118 imágenes de la clase sin enfermedad/no reconocida, disminuyendo los falsos positivos y mejorando el rendimiento al clasificar. Para evitar el sobreentrenamiento de la RNC se hicieron

transformaciones lineales aleatorias como acercamientos y rotaciones a cada imagen, aumentando el conjunto de datos al menos ocho veces del conjunto original. En caso particular del VHS-1 se utilizaron imágenes para probar la función de extracción de características realizada por la RNC móvil usada.

B. Modelo usado

El modelo usado para la aplicación móvil fue *Mobilenet V2*, ya que presenta el mejor modelo de punto flotante para aplicaciones de visión móvil. Este modelo ofrece una red neuronal profunda ligera cuya arquitectura utiliza convoluciones separables en profundidad, combinando esta convolución con normalización por lotes y funciones rectificadoras lineales, adicionalmente se usó *softmax* como función clasificadora final. El conversor integrado de la API de *TensorFlow lite* generó el modelo compatible con aplicaciones móviles.

C. Descripción y requisitos de la aplicación

La aplicación móvil desarrollada posee dos actividades y un servicio general. El servicio de reconocimiento prepara la imagen, carga al modelo de RNC, analiza la imagen, realiza inferencias y muestra los resultados. El modelo de reconocimiento transforma el mapa de bits recibido a un tensor que es entendido por *TensorFlow* para ejecutar el modelo devolviendo la probabilidad de inferencia a través de una lista dinámica con los porcentajes de confianza. Adicionalmente se permite elegir cual CPU realiza la inferencia (CPU o API de redes neuronales como acelerador de hardware). La información referente al tamaño del cuadro, el recorte, la rotación y el tiempo de inferencia se despliega en una pestaña (Figura 1). La versión de Android a la que va dirigida la aplicación es Android 9, siendo la mínima Android 4.4.2 para su ejecución y las pruebas se realizaron en un dispositivo Nokia 7.1 con la versión 9 de Android.



Fig. 1. Captura de pantalla de la aplicación en ejecución.

D. Preparación de los datos y entrenamiento

El conjunto de datos se dividió aleatoriamente en dos, un 80% para el entrenamiento y un 20% para las pruebas y validación. El preprocesamiento de las imágenes incluyó además de las transformaciones lineales, adaptar la imagen a un objeto RGB de 640x480px. Para ahorrar en tiempo de entrenamiento y de cómputo se aplicó el método de transferencia de aprendizaje del modelo de RNC *ImageNet*, usando para ello *Google colabory* y *Tensorflow*.

III. RESULTADOS

Se probó el rendimiento y la validación de la aplicación móvil con 102 imágenes. El tiempo de inferencia durante las pruebas no superó los 500ms. Para establecer una relación medible entre los valores reales y los valores predichos se realizó la matriz de confusión con datos desbalanceados que se muestra en la Figura 2. Los resultados del análisis de dicha matriz están descritos en la Tabla 1, la cual resume los hallazgos de verdaderos positivos (VP), falsos positivos (FP), falsos negativos

(FN) y verdaderos negativos (VN) para cada clase. Se obtuvo un índice de Kappa de 0,739 para medir la concordancia.




Fig. 2. Matriz de confusión para el conjunto de datos desbalanceados.

Tabla 1. Resultados del análisis de la matriz de confusión.

| Clases | Total Verdaderos | Total Identificados | VP | FP | FN | VN |
|------------------------|------------------|---------------------|----|----|----|----|
| Estomatitis aftosa | 21 | 29 | 19 | 10 | 2 | 71 |
| VHS-1 | 22 | 25 | 21 | 4 | 1 | 76 |
| Leucoplasia | 20 | 16 | 15 | 1 | 5 | 81 |
| Estomatitis nicotínica | 15 | 7 | 6 | 1 | 9 | 86 |
| No lesión | 24 | 25 | 20 | 5 | 4 | 73 |

Los resultados del análisis de la matriz de confusión permitieron generar métricas para comparar el desempeño de cada una de las clases del modelo entrenado (Tabla 2). Las métricas usadas fueron exactitud, precisión, sensibilidad, especificidad, valor-f1 y área bajo la curva (ABC) que se muestra en la Figura 3. Se observó que la clase VHS-1 presentó mejor desempeño en exactitud y precisión, la clase leucoplasia fue la más sensible en este conjunto de pruebas y la clase

estomatitis nicotínica la más específica. Para comparar el desempeño general entre ellas se usó las métricas ABC y f1-valor, resultando la clase VHS-1 con mejor desempeño y la clase estomatitis nicotínica con un rendimiento desfavorable.

Tabla 2. Métricas de desempeño para cada clase.

| Clases | Exactitud | Precisión | Sensibilidad | Especificidad | Valor-F1 | ABC |
|------------------------|---------------|---------------|---------------|---------------|---------------|---------------|
| Estomatitis aftosa | 0.8824 | 0.6552 | 0.9048 | 0.8765 | 0.7600 | 0.8907 |
| VHS-1 | 0.9510 | 0.8400 | 0.9545 | 0.9500 | 0.8936 | 0.9523 |
| Leucoplasia | 0.9412 | 0.9375 | 0.7500 | 0.9878 | 0.8333 | 0.8689 |
| Estomatitis nicotínica | 0.9020 | 0.8571 | 0.4000 | 0.9885 | 0.5455 | 0.6943 |
| No lesión | 0.9118 | 0.8000 | 0.8333 | 0.9359 | 0.8163 | 0.8846 |

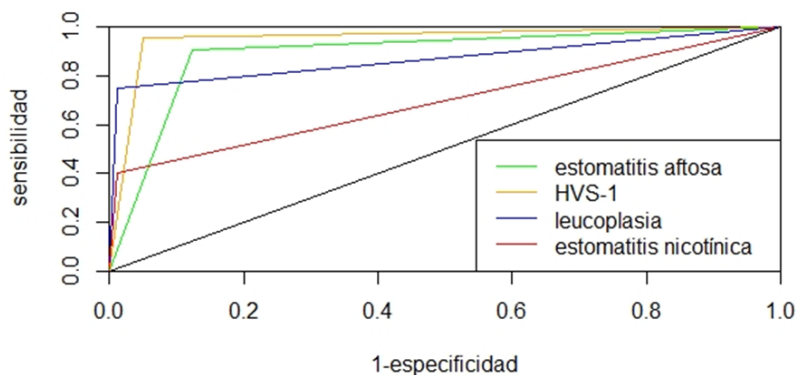


Fig. 3. Curva ROC para cada enfermedad.

IV. DISCUSIÓN

El modelo implementado se fundamentó en RNC para el reconocimiento de un grupo de lesiones bucales, usando para ello la red *Mobilenet V2* preentrenada con *ImageNet*, la cual se caracteriza por ser una gran base de datos con varias categorías que incluyen plantas, flores, animales, objetos entre otras, con excelentes resultados al momento de clasificar [11,12]. Esta es la razón por la cual se consideró este modelo para realizar la transferencia de aprendizaje. Se han descrito en la literatura sistemas de reconocimiento de lesiones que usan transferencia de aprendizaje con los modelos de redes AlexNet [11], VGGNet [13,14] y ResNet [12,15-18], cuyo desempeño es similar al modelo usado para este

trabajo. En cuanto al entrenamiento del modelo se ha evidenciado en diferentes investigaciones el uso *TensorFlow* para aplicaciones móviles de reconocimiento de enfermedades por visión artificial con buenos resultados [12,16,20,21].

Cuando se trabaja con imágenes de la cavidad bucal, es difícil encontrar un gran número de fotografías para cada caso de estudio. Una de las limitaciones son el consentimiento de los pacientes para el uso de sus imágenes y la incertidumbre sobre la privacidad de los datos de estas [22]. La naturaleza del entrenamiento de los modelos de RNC para la identificación de lesiones requiere de un gran banco de imágenes. En este trabajo el número de ítems por clases fue pequeño, alrededor de 100 imágenes, lo que implicó usar el método de transformaciones lineales, acercamiento y rotaciones aleatorias para ampliar la base de datos al momento del entrenamiento [9], esta técnica también fue usada por Jae-Hong et al. en su investigación para la clasificación de lesiones en imágenes radiográficas logrando un reconocimiento mayor del 90% en sus clases [23].

Durante las pruebas y validación, al utilizar *Tensorflow Lite*, se obtuvo un tiempo de inferencia inferior a los 500ms, lo que resulta excelente cuando se usa como herramienta de diagnóstico en tiempo real. Este tiempo se considera rápido para la identificación, así como también lo es el cambio de porcentaje de certeza arrojado cuando se identifica la lesión. El reconocimiento de las imágenes no es directo, sino hecho en base a la probabilidad de pertenecer a una de las clases programadas en el modelo.

La aplicación desarrollada presentó para la identificación de lesiones de tipo VHS-1, estomatitis aftosa y leucoplasia un desempeño aceptable y un rendimiento desfavorable para el reconocimiento de lesiones de tipo estomatitis nicotínica. A diferencia de otras aplicaciones esta se basa en el reconocimiento clínico de varias lesiones bucales tomando en cuenta la observación y la visión por computadora desde un teléfono inteligente. Se ha evidenciado que sistemas de reconocimiento de lesiones similares presentan un desempeño menor al obtenido en esta investigación, alrededor del 75% [14,24-27] usando preprocesamiento de las imágenes y un conjunto de datos superior al empleado en este trabajo. Sin embargo, estudios han descrito que un buen rendimiento en la predicción debe ser mayor del

90% [12,16,23,28,29]. Un estudio similar usó reconocimiento de lesiones tipo estomatitis aftosa y VHP-1 con resultados mayores del 90% usando un conjunto de datos de 200 imágenes y el método de bosque aleatorio como método de reconocimiento [8].

Con base a las métricas obtenidas la clase con mejor desempeño general fue VHS-1, sin embargo, en cuanto a los atributos de precisión y especificidad otras clases obtuvieron un mejor rendimiento. A pesar de que la clase estomatitis nicotínica obtuvo métricas desfavorables y poco aceptables, tuvo el mejor desempeño en cuanto a la especificidad, esto es debido al conjunto de imágenes que fue usado para el entrenamiento de la red, a pesar de tener una sensibilidad del 40% su especificidad fue del 99%. La baja sensibilidad de esta clase se fundamentó en la similitud de las imágenes de entrenamiento con otras clases, lo que reduce la tasa de reconocimiento de VP. Sin embargo, al comparar estas métricas con el estudio de A. Rana et al. se aprecia que los resultados de este trabajo fueron superiores a pesar de contar con un conjunto de datos similar [21].

V. CONCLUSIONES

Los sistemas de reconocimiento de lesiones implementados usando métodos de aprendizaje automático deben presentar un buen desempeño, para minimizar la tasa de falsos positivos y falsos negativos. La aplicación desarrollada mostró un rendimiento aceptable para tres lesiones elegidas, sin embargo, los resultados reflejan que este modelo necesita mejoras en el proceso de entrenamiento de la red. El poder efectuar el reconocimiento de forma local en tiempo real usando teléfonos inteligentes presenta una gran ventaja para el uso de esta aplicación como herramienta de diagnóstico en áreas remotas sin acceso a internet.

Esta aplicación serviría como aliada para los odontólogos en actividades de diagnóstico clínico precoz de lesiones potencialmente malignas que pueden evolucionar a patologías más complicadas como cáncer bucal. Por esta razón se deben continuar investigaciones en el área para mejorar las características del modelo de RNC, como por ejemplo aumentar el número de imágenes para el entrenamiento, separación de las características clínicas de la lesión para aumentar

la tasa de verdaderos positivos y permitir la incorporación de otros datos para mejorar el diagnóstico usando datos adicionales.

CONTRIBUCIÓN DE LOS AUTORES

Jesús-David González: Acondicionamiento de datos, Análisis formal, Investigación, Metodología, Recursos, Software, Visualización, Redacción - borrador original.

Jormany Quintero-Rojas: Conceptualización, acondicionamiento de datos, Investigación, Administración del proyecto, Recursos, Supervisión, Validación, Visualización, Redacción-revisión y edición.

REFERENCIAS

- [1] C. Carvajal, "El impacto del diagnóstico médico como experiencia traumática. Algunas reflexiones," *Revista Médica Clínica Las Condes*, vol. 28, no. 6, pp. 841-848, 2017. <https://doi.org/10.1016/j.rmclc.2017.10.010>
- [2] A. Goic, "Sobre el origen y desarrollo del libro *Semiología Médica*," *Revista Médica Chile*, vol. 146, no. 3, pp. 387-390, 2018. <https://doi.org/10.4067/s0034-98872018000300387>
- [3] M. Del Río, J. M. López, C. Vaquero, "La inteligencia artificial en el ámbito médico," *Revista Española de Investigaciones Quirúrgicas*, vol. 21, no. 3, pp. 113-116, 2018.
- [4] R. Karthikayan, A. Sukumaran, M. Parangimalai, V. Raj, "Accuracy of smartphone based photography in screening for potentially malignant lesions among a rural population in Tamil Nadu: A cross-sectional study," *Digital Medicine*, vol. 5, no. 2, pp. 56, 2019. https://doi.org/10.4103/digm.digm_29_18
- [5] A. Pereira, S. A. Lazaro, C. G. Molina-Bastos, V. L. Oliveira, R. Nunes, M. Rodrigues, V. Coelho, "Teledentistry in the diagnosis of oral lesions: A systematic review of the literature," *Journal of the American Medical Informatics Association*, vol. 27, no. 7, pp. 1166-1172, 2020. <https://doi.org/10.1093/jamia/ocaa069>
- [6] M. Estai, Y. Kanagasingam, D. Xiao, J. Vignarajan, B. Huang, E. Kruger, M. Tennant, "A proof-of-concept evaluation of a cloud-based store-and-forward telemedicine app for screening for oral diseases," *Journal of telemedicine and telecare*, vol. 22, no. 6, pp. 319-325, 2016. <https://doi.org/10.1177/1357633X15604554>
- [7] J. González, "Diseño e implementación de una aplicación móvil inteligente en Android para reconocimiento de lesiones y enfermedades cutáneas y en la mucosa bucal," Grade Thesis, Universidad de Los Andes, Mérida, Venezuela, 2019.
- [8] R. Anantharaman, M. Velazquez, Y. Lee, "Utilizing Mask R-CNN for detection and segmentation of oral diseases," in *IEEE International Conference on Bioinformatics and Biomedicine*, Spain, 2018, pp. 2197-2204. <https://doi.org/10.1109/BIBM.2018.8621112>
- [9] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, H. Adam, "Mobilenets: Efficient convolutional neural networks for mobile vision applications," *arXiv Preprint*, 2017.

- [10] A. Leite, K. Vasconceslos, H. Willems, R. Jacobs, "Radiomics and machine learning in oral healthcare," *Proteomics Clinical Applications*, vol. 14, e1900040, 2020. <https://doi.org/10.1002/prca.201900040>
- [11] A. Bhattacharya, A. Young, A. Wong, S. Stalling, M. Wei, D. Hadley, "Precision Diagnosis Of Melanoma And Other Skin Lesions From Digital Images," in *AMIA Joint Summits on Translational Science proceedings*, 2017, pp. 220-226
- [12] J. Velasco, C. Pascion, J. W. Alberio, J. Apuang, J. S. Cruz, M. A. Gomez, B. Jr. Molina, L. Tuala, A. Thio-ac, R. Jr. Jorda, "A Smartphone-Based Skin Disease Classification Using MobileNet CNN," *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 8, no. 5, pp. 2632-2637, 2019. <https://doi.org/10.30534/ijatcse/2019/116852019>
- [13] A. Romero-Lopez, X. Giro-i-Nieto, J. Burdick, O. Marques, "Skin Lesion Classification from Dermoscopic Images Using Deep Learning Techniques," in *Biomedical Engineering*, Canada, 2017, pp. 49-54. <https://doi.org/10.2316/P.2017.852-053>
- [14] J. Burdick, O. Marques, J. Weinthal, B. Furht, "Rethinking Skin Lesion Segmentation in a Convolutional Classifier," *Journal of Digital Imaging*, vol. 31, no. 4, pp. 4354440, 2018. <https://doi.org/10.1007/s10278-017-0026-y>
- [15] S. Han, M. Kim, W. Lim, G. Park, I. Park, S. Chang, "Classification of the Clinical Images for Benign and Malignant Cutaneous Tumors Using a Deep Learning Algorithm," *Journal of Investigative Dermatology*, vol. 138, no. 7, pp. 1529-1538, 2018. <https://doi.org/10.1016/j.jid.2018.01.028>
- [16] E. Ziaten-Cerezo, "Clasificación de lesiones en la piel usando aprendizaje profundo," Grade Thesis, Universidad de Málaga, Málaga, Spain, 2019.
- [17] J. Yap, W. Yolland, P. Tschandl, "Multimodal skin lesion classification using deep learning," *Experimental Dermatology*, vol. 27, no. 11, pp. 1261-1267, 2018. <https://doi.org/10.1111/exd.13777>
- [18] T. Domènech, "Clasificación de imágenes dermatoscópicas utilizando Redes Neuronales Convolucionales e información de metadatos," Grade Thesis, Universidad Politécnica de Catalunya, Barcelona, Spain, 2019.
- [19] C. S. Cheng, P. Shueng, C. Chang, C. Kuo, "Adapting an Evidence-based Diagnostic Model for Predicting Recurrence Risk Factors of Oral Cancer", *Journal of Universal Computer Science*, vol. 24, no. 6, pp. 742-752, 2018. <https://doi.org/10.3217/jucs-024-06-0742>
- [20] R. Méndez-Hernández, "Aprendizaje profundo para la segmentación de lesiones pigmentadas de la piel," Grade Thesis, Universidad de Sevilla, Sevilla, Spain, 2019.
- [21] A. Rana, G. Yauney, L. C. Wong, O. Gupta, A. Muftu, P. Shah, "Automated Segmentation of Gingival Diseases from Oral Images," in *IEEE Healthcare Innovations and Point of Care Technologies*, United States, 2017, pp. 144-147. <https://doi.org/10.1109/HIC.2017.8227605>
- [22] M. Estai, Y. Kanagasigam, B. Huang, J. Shiikha, E. Kruger, S. Bunt, M. Tenant, "Comparison of a smartphone-based photographic method with face-to-face caries assessment: a mobile teledentistry model," *Telemedicine and e-Health*, vol. 23, no. 5, pp. 435-440, 2017. <https://doi.org/10.1089/tmj.2016.0122>
- [23] L. Jae-Hong, K. Do-Hyung, J. Seong-Nyum, "Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network," *Oral Diseases*, vol. 26, pp. 152-158, 2019. <https://doi.org/10.1111/odi.13223>

- [24] J. Yang, X. Sun, J. Liang, P. L. Rosin, "Clinical Skin Lesion Diagnosis Using Representations Inspired by Dermatologist Criteria," in *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, United States, 2018, pp. 1258-1266. <https://doi.org/10.1109/CVPR.2018.00137>
- [25] J. Serrano-Fernández, "Sistema de ayuda al diagnóstico para la detección temprana de melanomas," Grade Thesis, Universidad Carlos III, Madrid, Spain, 2017.
- [26] Y. Gal, R. Islam, Z. Ghahramani, "Deep Bayesian Active Learning with Image Data," in *Proceedings 34th International Conference on Machine Learning*, Australia, 2017, pp. 1183-1192. <https://doi.org/10.17863/CAM.11070>
- [27] J. Sánchez-Hernández, D. Hernández-Rabadán, "Comparación de métodos de clasificación aplicados al diagnóstico de melanomas malignos mediante asimetría," *Programación Matemática y Software*, vol. 6, no. 2, pp. 51-56, 2014.
- [28] J. Kawahara, A. BenTaieb, G. Hamarneh "Deep features to classify skin lesions," in *IEEE 13th International Symposium on Biomedical Imaging*, Praga, 2016, pp. 1397-1400. <https://doi.org/10.1109/ISBI.2016.7493528>
- [29] U. Kalwa, C. Legner, T. Kong, S.Pandey, "Skin Cancer Diagnostics with an All-Inclusive Smartphone Application," *Symmetry*, vol. 11, no. 6, pp. 790, 2019. <https://doi.org/10.3390/sym11060790>