

Machine Learning Model for Early-stage Melanoma Diagnosis

Flavia Pardo Valdivia, Bachelor's Degree¹, Natalia Valeria Villanueva Zárata, Bachelor's Degree², and Esther Aliaga Cerna, Master's Degree³

^{1,2,3}Universidad Peruana de Ciencias Aplicadas, Perú, u201914540@upc.edu.pe, u201911485@upc.edu.pe, pcsieali@upc.edu.pe

Abstract– There are Machine Learning (ML) algorithms for the development of recognition and classification models for medical images, aiming to facilitate access to the healthcare sector. Therefore, this paper seeks to demonstrate the effectiveness of the Support Vector Machine (SVM) algorithm for classifying skin lesion images into Melanoma and Non-Melanoma categories. With this aim, an ML model was developed and trained using the Python programming language, SVM, and images from the ISIC 2019 and ISIC 2020 repositories. For model development, training, and testing, Amazon Web Services cloud services were employed, yielding results of 0.77 precision, 0.82 recall or sensitivity, 0.80 F1-Score, and 0.76 accuracy. These effectiveness metric results exceeding 0.75 or 75% endorse the suitability of the model for medical applications in the field of image recognition and classification.

Keywords– Machine Learning, Support Vector Machine, Melanoma, Skin Melanoma.

Digital Object Identifier: (only for full papers, inserted by LACCEI).
ISSN, ISBN: (to be inserted by LACCEI).
DO NOT REMOVE

Modelo de Machine Learning para el diagnóstico de melanoma en etapas tempranas

Flavia Pardo Valdivia, Grado de Bachiller¹, Natalia Valeria Villanueva Zarate, Grado de Bachiller², and Esther Aliaga Cerna, Grado de Magister³

^{1,2,3}Universidad Peruana de Ciencias Aplicadas, Perú, u201914540@upc.edu.pe, u201911485@upc.edu.pe, pcsieali@upc.edu.pe

Abstract– Existen algoritmos de Machine Learning (ML) para el desarrollo de modelos de reconocimiento y clasificación de imágenes médicas, con el fin de facilitar el acceso al sector de salud. Es por ello que, en el presente trabajo se busca evidenciar la efectividad del algoritmo Support Vector Machine (SVM) para clasificar imágenes de lesiones cutáneas entre Melanoma y No-Melanoma. Con este objetivo se desarrolló y entrenó un modelo de ML utilizando el lenguaje de programación Python, SVM e imágenes de los repositorios ISIC 2019 e ISIC 2020. Para el desarrollo, entrenamiento y testeo del modelo se emplearon servicios de la nube de Amazon Web Services, y se obtuvieron resultados de 0.77 en precisión, 0.82 en recall o sensibilidad, 0.80 en F1-Score y 0.76 en exactitud. Estos resultados de métricas de efectividad mayores al 0.75 o 75% respaldan la idoneidad del modelo para aplicaciones médicas en el campo del reconocimiento y clasificación de imágenes.

Keywords– Machine Learning, Support Vector Machine, Melanoma, Skin Melanoma.

I. INTRODUCCIÓN

La Organización Mundial de la Salud (OMS) ha clasificado la radiación ultravioleta (RUV) en 3 tipos: UVA, UVB y UVC. El tipo UVA (315-400 nm) es el que más llega a la tierra, esto quiere decir que sus rayos atraviesan la capa de ozono y es el más conocido por provocar bronceado, envejecimiento y cáncer de piel. UVB (280-315nm) afecta a la piel, sin embargo, es usualmente detenida por la capa de ozono. UVC (100-280nm) no alcanza la superficie terrestre debido a que es absorbida por el oxígeno [1].

Para medir el nivel de la radiación se definió el índice de RUV, donde la OMS estableció las siguientes medidas: Baja (1-2), Moderada (3-5), Alta (6-7), Muy alta (8-10) y Extremadamente alta (11-20+) [2], [3]. La radiación varía por cada país y región, y puede perjudicar a algunos ciudadanos más que otros. En el caso de Perú, los niveles de radiación entre los departamentos y regiones del país varían entre 1 y 14 [4].

Estudios han probado que el residir en alturas elevadas (alrededor o superior a 3,500 m.s.n.m) es un factor asociado para el desarrollo de enfermedades cutáneas, debido a la mayor exposición a RUV por haber una atmósfera más delgada y una menor cantidad de nubes [5], [6]. Como referencia, se estima un aumento de 10% a 12% de radiación por cada 1,000 metros de elevación [5].

El melanoma es un tipo de cáncer de piel que se desarrolla como una de las consecuencias de la exposición crónica a la RUV. Este tipo de cáncer se distingue por su alta malignidad, caracterizada por una rápida progresión y la posibilidad de metástasis, lo que lo convierte en una de las formas más peligrosas de cáncer de piel. [7]. Sin embargo, si es detectado a tiempo, la probabilidad de supervivencia del paciente puede ser hasta del 90% [8].

Para el 2020, a nivel global se estimaron que 324,635 personas serían diagnosticadas con melanoma [9]. En el caso del Perú, durante el 2022 EsSalud reportó 1,877 casos de melanoma y otros tumores de piel, evidenciando un ligero aumento contra los 1,300 casos que comúnmente se pronosticaban por cada año [10], [11].

No obstante, a pesar de lo mencionado anteriormente, es altamente probable que existan numerosos casos sin diagnosticar debido a una serie de factores. Estos factores pueden contribuir a la detección tardía del cáncer, lo que a su vez disminuye las probabilidades de supervivencia y curación del paciente. Entre las razones identificadas se incluyen la falta de información y conciencia sobre el melanoma en la población, la limitación de recursos que dificulta el acceso a atención médica adecuada, la ausencia de un seguro de salud que disponga del equipo necesario para el diagnóstico de la enfermedad, la residencia en regiones remotas con un acceso complicado a servicios de salud, y, por último, la escasez de personal médico capacitado para un diagnóstico preciso de la enfermedad. [12], [13], [14].

Teniendo en cuenta lo mencionado anteriormente, nuestro objetivo principal consistió en diseñar y desarrollar un modelo basado en Machine Learning (ML) que, a través del análisis y reconocimiento de imágenes de lesiones cutáneas, sea capaz de realizar una clasificación para determinar si la imagen corresponde a melanoma o no melanoma. Se espera que el modelo sea empleado por organizaciones o entidades para desarrollar una solución o una herramienta de apoyo que agilice el proceso de diagnóstico realizado por profesionales médicos.

Hemos identificado que la problemática de la detección tardía del melanoma ha resultado difícil de abordar debido a la incorrecta implementación de programas e ideas propuestos, así como a la presencia de conflictos de naturaleza humana que agravan las causas mencionadas previamente. Por ejemplo, en

Perú se creó la ley N°30102 en el 2014, que exige la concientización de la población sobre el cuidado de la piel, las enfermedades cutáneas, prevenciones y consecuencias; no obstante, existen entidades que no capacitan a sus trabajadores ni cuentan con los materiales necesarios para su protección contra la exposición al sol. [12]. El gobierno también creó un seguro de salud para la población menos favorecida económicamente, empero no cuentan con establecimientos propios para la atención de los afiliados y en muchas ocasiones no cuentan con el personal y/o equipo médico para brindar una atención médica efectiva [15], [16].

Anteriormente se han propuesto enfoques similares al nuestro para la identificación de melanoma mediante ML. Como en el caso de [17], donde utilizaron los algoritmos Adaptive Thresholding y K-Means Clustering para la segmentación de lesiones cutáneas. Sin embargo, para su evaluación utilizaron los índices de Jaccard y Dice, que consisten en medir la similitud entre conjuntos de elementos, y sus resultados fueron de 0.77 y 0.87. Esto solo evalúa la semejanza entre las imágenes, más no si el modelo fue efectivo en identificar melanoma. Por ello, consideramos al modelo poco confiable, ya que no fue evaluado con métricas para medir la efectividad, como precisión y exactitud.

En [18], utilizaron los algoritmos de Support Vector Machine (SVM), Random Forest y Naive Bayes para el reconocimiento de melanoma. Empero, solo utilizaron 95 imágenes, de las cuales el 80% son de entrenamiento y el resto se utilizó para el testeo. En nuestro caso utilizamos imágenes recopiladas de una base de datos de una organización internacional (ISIC), debido a que se cuentan con más de 5000 imágenes de variados casos de Melanoma y No-Melanoma, con ello se brindará más información para el entrenamiento del modelo.

En cuanto a los componentes técnicos clave de nuestra investigación, contamos con el uso de SVM y la propuesta de utilizar los servicios de Amazon Web Services (AWS). Con respecto a SVM, es un algoritmo de aprendizaje supervisado comúnmente utilizado para resolver problemas de clasificación. Según los resultados de artículos pasados, es uno de los algoritmos de ML más efectivos, obteniendo resultados similares a los de Deep Learning (DL) [18], [19], [20]. En cuanto a AWS, es una de las nubes más reconocidas a nivel mundial e incluye servicios enfocados en el desarrollo e implementación de modelos de ML [21].

Nuestras contribuciones principales son las siguientes:

- 1) Se desarrolló un modelo que permite el reconocimiento de melanoma a partir de imágenes haciendo uso de un algoritmo de ML para la clasificación.
- 2) Se desarrollaron arquitecturas que especifican el uso de servicios de AWS para el desarrollo del modelo.
- 3) Se desarrolló el modelo con el enfoque de lograr el resultado mínimo de 75% en las métricas de exactitud, precisión, sensibilidad (o *recall*) y F1-Score.

El presente artículo está distribuido en las siguientes secciones: en la Sección II describimos trabajos similares donde se desarrollaron modelos de clasificación usando una variedad de algoritmos de ML. Luego, en la Sección III brindamos el contexto necesario para entender el trabajo desarrollado. Después, en la Sección IV exponemos los experimentos de validación realizados, y finalmente, en la Sección V exponemos nuestra conclusión.

II. TRABAJOS RELACIONADOS

Una amplia variedad de algoritmos, métodos y modelos ha sido desarrollada con el propósito de implementar y mejorar el reconocimiento de imágenes. En esta sección, exploraremos trabajos relacionados que comparten objetivos e ideas similares a los nuestros. En estos estudios, se han empleado una variedad de algoritmos y modelos con el fin de lograr un exitoso sistema de reconocimiento de imágenes.

En [18], proponen la captura de fotografías de lunares mediante cámaras de teléfonos móviles, seguida de su clasificación a través de un algoritmo de ML para determinar si son sospechosos de ser melanoma o no. Su proceso incluyó la utilización del algoritmo K-Means para la segmentación de las imágenes. Posteriormente, en la etapa de clasificación, se evaluaron los tres algoritmos: SVM, Random Forest y Naive Bayes, con 3 métricas de efectividad: exactitud, sensibilidad y especificidad. Sus resultados más resaltantes fueron las exactitudes, donde obtuvieron valores de 0.9473 (SVM), 0.7368 (Random Forest) y 0.6842 (Naive Bayes). En contraste, en nuestro enfoque, hemos utilizado cuatro métricas: precisión, sensibilidad, exactitud y F1-Score. Esto se debe a que contar con un mayor número de métricas nos proporciona una base más sólida para analizar y determinar la validez del modelo con un mayor grado de certeza.

En [22], los autores propusieron un modelo que utilizó la red neuronal convolucional (CNN) aplicada para la etapa de segmentación y selección de características de las imágenes, y un algoritmo de ML como clasificador. Su modelo obtuvo uno de los mejores resultados, con una exactitud de 0.9975. Para realizarlo, recopilaron las imágenes de diversos sets de datos como: International Skin Imaging Collaboration (ISIC) 2018-2019, PH2 y HAM10000, lo que generó que tuvieran alrededor de 20,000 imágenes a utilizar. Para el desarrollo de nuestro modelo solo empleamos un set de datos: ISIC 2019 y 2020. Se ha comprobado que SVM no necesita un set de datos masivo para su entrenamiento. Esto no significa que no se deba o pueda utilizar un set de datos masivo, sino que, teóricamente, el incrementar la cantidad de data no influye significativamente en la mejora de la efectividad del modelo [23].

En [24] proponen un modelo de ML, para la detección y clasificación de cáncer de piel, además de una arquitectura a nivel local y Cloud, donde utilizaron el modelo CNN para la extracción de características y validación. En el caso de la preparación de data los autores indican que se realizó un

aumento de data (data augmentation), donde aplican técnicas como la rotación, mejora de la nitidez, zoom, entre otros. En el caso de nuestro proyecto, se estableció que primero se empezará con el aumento de data donde se rotará la imagen en 90° para posteriormente iniciar con el mejoramiento de imagen que consiste en el reajuste, mejora de calidad y aumento de contraste. Se estableció de esta manera con el fin de mantener un orden y no saturar las instancias en AWS con diferentes funciones a la vez.

En [25], los autores proponen un framework para la clasificación de cáncer de piel, donde utilizan una arquitectura CNN, cuya precisión fue del 0.96. En el artículo se menciona que en el pre-procesamiento se realiza el aumento de data que consiste en la mejora y aumento de imágenes. Sin embargo, en nuestro proyecto, luego del pre-procesamiento de imágenes continúa la fase de extracción de características en base a la regla ABCD (asimetría, bordes, color, diámetro), que es utilizada por doctores profesionales para emitir un diagnóstico oficial sobre una lesión cutánea. El utilizar este método nos permitirá ofrecer más variables de entrenamiento para el análisis del modelo [26].

Finalmente, en [27] se utilizó un algoritmo de clasificación híbrido que combinaba SVM y un algoritmo de optimización heurística. Siguió los pasos comunes de un pre-procesamiento de la imagen, extracción de características, clasificación, entrenamiento y pruebas. Utilizaron 2 set de datos: ISIC y PH2; y compararon los resultados obtenidos con cada uno. Con el set de datos ISIC tuvieron mejores resultados con una precisión de 0.969, recall (sensibilidad) de 0.979, F1-score de 0.974, y exactitud de 0.975. Pese a que obtuvieron resultados elevados y satisfactorios, estos fueron similares a otros artículos [18], [19], [28], [29] donde no se generó un híbrido del algoritmo SVM, sino que se le utilizó independientemente. Por consiguiente, en nuestro modelo no se contempló el combinar SVM con otro algoritmo.

III. RECONOCIMIENTO DE IMÁGENES PARA LA IDENTIFICACIÓN DE MELANOMA CON MACHINE LEARNING

A. Conceptos Preliminares

En esta sección se presentarán los conceptos principales para el trabajo.

Definición 1 (Machine Learning [30]): se define como el campo de estudio que le brinda a las computadoras, la capacidad de aprender independientemente. Es la forma de enseñar a las máquinas a manejar los datos de manera eficiente y autónoma.

Definición 2 (algoritmos en ML [30], [31], [32]): el conjunto de reglas o procedimientos que el sistema sigue para aprender de la data se le denomina algoritmo. Algunos tipos son: Aprendizaje Supervisado, No Supervisado, Semi-Supervisado, Reforzamiento, Multi-tarea, Conjunto, Redes Neuronales y Aprendizaje Basado en Instancias. Para el análisis de imágenes se pueden utilizar los siguientes tipos de

algoritmos: Redes Neuronales Convolucionales, aprendizaje supervisado, no supervisado y Clustering.

Definición 3 (algoritmo SVM de ML [19], [33]): es un algoritmo /técnica /modelo de ML que resuelve problemas de clasificación y reconocimiento de imágenes. Su funcionamiento consiste en la búsqueda/creación del mejor hiperplano que pueda separar 2 clases diferentes de data. Después busca aquellos hiperplanos con el margen máximo de distancia, y este margen indica la confianza del clasificador en separar la data. Mientras el margen sea mayor, significa que existe menor probabilidad de una clasificación errónea.

Definición 4 (reconocimiento de imágenes [31], [32]): es un área de la inteligencia artificial enfocada en el desarrollo de técnicas y algoritmos para enseñar a un sistema a realizar actividades como la clasificación de imágenes, detección, localización y segmentación de objetos. Es utilizada en campos como el reconocimiento facial, dispositivos móviles y aplicaciones médicas.

Definición 5 (Melanoma [34], [35]): es un tipo de cáncer que afecta a las células productoras de pigmento en la piel llamadas melanocitos, y es considerado uno de los cánceres más peligrosos, a pesar de que no es uno de los más comunes; esto debido a su tendencia de expandirse rápidamente.

Definición 6 (Regla ABCDE [36]): la regla ABCDE es utilizada por los doctores profesionales, ya que les permite evaluar si un lunar/lesión cutánea tiene el riesgo de ser un Melanoma. Las letras representan la Asimetría, Bordes, Color, Diámetro y Evolución del lunar.

B. Método

En esta sección se detallará la solución propuesta.

1) Modelo

El aporte principal es el diseño y desarrollo de un modelo que utiliza el algoritmo Support Vector Machine para procesar, analizar y clasificar una imagen entre “melanoma” y “no-melanoma”. Adicionalmente, el modelo retorna el porcentaje de probabilidad del resultado. En la Figura 1, se observa el flujo del modelo que inicia con el ingreso de imágenes al almacenamiento en Amazon S3. Con ello, empieza la fase inicial de aumento de data que consiste en emitir diferentes variables de las imágenes originales para aportar mayor cantidad de data en el análisis. En nuestro caso se realizó una rotación de 90° por cada imagen, cuyo resultado final fue 4 veces la cantidad de imágenes iniciales. Cabe resaltar que el aumento de data solo se realizó a las imágenes que son Melanoma con el fin de brindar más información de entrenamiento al modelo y obtener un balance de la misma cantidad de data de Melanoma y No-Melanoma. Además, se realizó otra ampliación a todas las imágenes, donde se rotaron en 45° y 135°.

Luego, se continúa con la segunda fase, que es el mejoramiento de las imágenes. En esta sección se realiza un reajuste de tamaño mínimo de altura de 1000 y máximo de

1500, se aumenta el contraste y se mejora la nitidez de la imagen.

Se procede a la ejecución de la tercera fase, donde se realizan las siguientes operaciones con el fin de quitar los vellos de las imágenes que podrían estar cubriendo las lesiones cutáneas a analizar: Primero, la imagen se convierte a escala de grises para aplicar el filtro Black Hat, que es utilizado para resaltar los detalles oscuros sobre un fondo claro, posterior a este, se utiliza el filtro Gaussiano, que resalta los vellos, suaviza y reduce el ruido de la imagen. Segundo, se utiliza la umbralización binaria que creará una máscara e identificará los vellos. Por último, se sustituye cada píxel que pertenece a los vellos por valores originales, con ello se logra eliminar los vellos y mejorar la imagen.

En la cuarta fase se continúa con la etapa de segmentación, donde se realizó la conversión de la imagen a escala de grises y se aplicó umbralización para resaltar las áreas de la lesión. Luego, se realiza una búsqueda del contorno mayor que debe corresponder a la lesión. Después, se crea una máscara en blanco para aislar la lesión y se suavizan los contornos. Por último, la máscara es aplicada a la imagen inicial con el fin de obtener la lesión segmentada, y lo externo a esta se torna negro y se exporta el resultado a .PNG.

Posteriormente, en la quinta fase se extraen 4 características de la lesión cutánea que serán de apoyo para ofrecer un mejor detalle en la etapa de entrenamiento. Nos basamos en el método médico ABCDE que se utiliza para el análisis y diagnóstico de aquellas lesiones sospechosas de melanoma, que consisten en lo siguiente:

1) Asimetría: Beaumont [37], indica que una lesión cutánea con posibilidades de ser melanoma tiende a ser asimétrica. Se considera asimétrica cuando ambas mitades de la lesión no son parecidas en tamaño, forma o color. En el proyecto se realizó la diferenciación entre la imagen original y su versión en escala de grises para determinar el grado de asimetría.

2) Bordes: En el caso del melanoma, las lesiones suelen tener bordes mal definidos o irregulares. Para calcular los bordes se utilizó el algoritmo Canny, que identifica aquellos cambios bruscos en la intensidad de los píxeles, calcula el valor promedio de su intensidad y cuanto mayor sea el valor, más irregulares serán los bordes.

3) Color: El color es una de las características más importantes al momento de realizar la evaluación, ya que, en el caso de las lesiones benignas, este suele ser un color uniforme; mientras que, en el caso de las malignas, estas suelen conformarse una variedad de colores. En el caso del código, se calculó la desviación estándar de la saturación en HSV (Matiz, Saturación y Valor), ello representa de manera cuantitativa la diversidad de colores identificados en la lesión; a mayor nivel de desviación estándar ello sugiere un indicativo de ser lesión maligna.

4) Diámetro: Un melanoma tiende a tener un diámetro mayor a las lesiones benignas. En caso este sea superior a 6 mm

es motivo de observación y sospecha [38]. Para hallar el diámetro, el código convierte la imagen a escala de grises, se detectan los contornos lo cual permite determinar los puntos extremos, y define el diámetro de la lesión.

La letra E significa evolución, que corresponde a si la lesión ha sufrido cambios con el tiempo. Este análisis no fue utilizado en el modelo, debido a que se refiere a aspectos cualitativos que no se miden por medio de métricas cuantitativas.

Después de ello, en la sexta fase se entrena, se exporta el modelo entrenado y este es utilizado para clasificar las lesiones. En la última fase se evalúa el rendimiento del modelo a través de las métricas de efectividad: precisión, sensibilidad, F1-Score y exactitud.

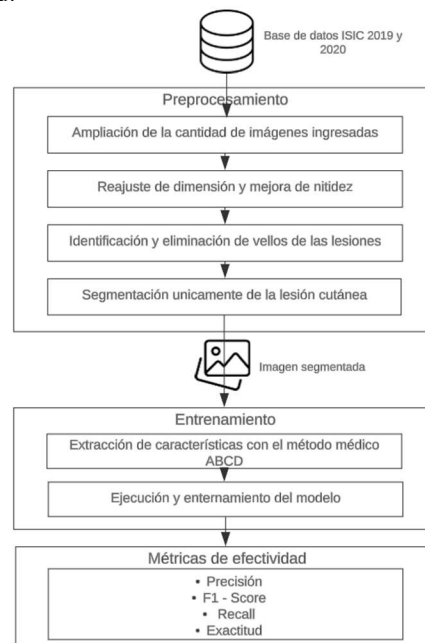


Fig. 1 Diagrama del modelo propuesto. En el diagrama del modelo se puede apreciar el funcionamiento y flujo de la data, para llegar al resultado

2) Arquitectura Física

Otra contribución de esta propuesta fue el establecer los servicios de la nube para el entrenamiento del modelo y el despliegue de una aplicación de prueba, en lugar de utilizar recursos on-premises o en premisa. Esto debido a la capacidad de fácil escalamiento, resiliencia y tolerancia a fallos que se pueden conseguir al utilizar los servicios de AWS.

En la Figura 2 se aprecian los servicios y el orden en los que fueron utilizados. Por ejemplo, utilizamos un servicio de almacenamiento (Amazon S3), donde subimos y almacenamos las imágenes procesadas; un servicio especializado para el entrenamiento de modelos de machine learning (Amazon Sagemaker); y un balanceador de carga de aplicaciones junto con el servicio EC2 (servicio de máquinas virtuales) para el

despliegue de la aplicación de prueba utilizando el archivo .PKL del modelo entrenado.

La aplicación de prueba permite al usuario ingresar una imagen para ser analizada por el modelo entrenado; y como resultado se muestra el porcentaje de probabilidad de que la lesión cutánea sea melanoma. Cabe resaltar que la aplicación de prueba es una herramienta de apoyo y que el usuario debe acudir a un doctor profesional para un diagnóstico oficial; y que fue desarrollada con el objetivo de evidenciar la posibilidad de implementar el modelo en una aplicación.

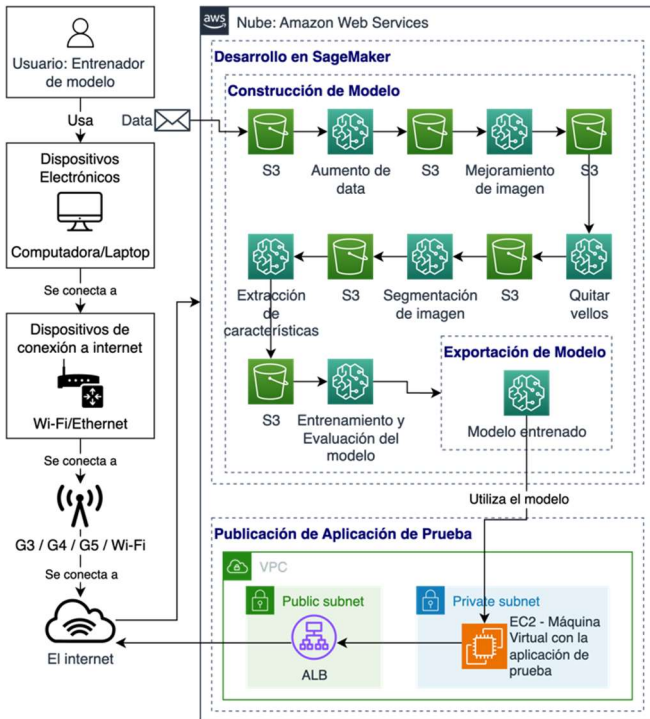


Fig. 2 Arquitectura Física con los componentes para entrenar el modelo y desplegar la aplicación de prueba.

3) Arquitectura Lógica

La tercera contribución fue la creación de la arquitectura lógica del modelo, la cual se encuentra en la Figura 3. En ella se puede apreciar cómo un usuario interactúa con los componentes tecnológicos sobre los que se entrena el modelo y se despliega la aplicación de prueba. La capa lógica de negocios o de aplicaciones y la capa de datos se encuentran desplegadas en AWS con servicios propios del proveedor. También contamos con una capa de presentación o interfaz de usuario, que puede ser visualizada en la parte inferior de la Figura 3, donde se indica que se utilizará una máquina virtual para el despliegue de la aplicación de prueba con un servidor WSGI llamado Waitress.

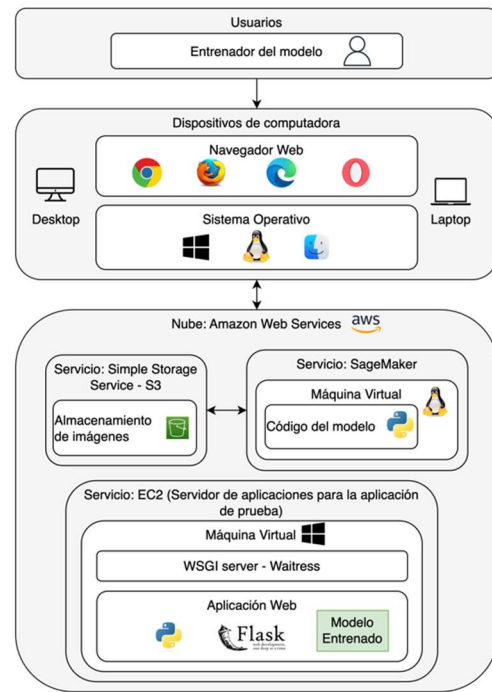


Fig. 3 Arquitectura Lógica del modelo desarrollado.

4) Arquitectura Integrada

La cuarta contribución es la entrega de la arquitectura integrada, donde se visualiza la relación entre las diferentes partes del sistema. Por ejemplo, en la parte superior de la Figura 4 se observa al usuario encargado de entrenar al modelo y su conexión con dispositivos electrónicos como laptop, navegadores y sistemas operativos que deben estar conectados a una red de internet. Luego de ello, se visualiza la conexión, a través de una interfaz de usuario, hacia los servicios de la nube como S3 y Sagemaker.

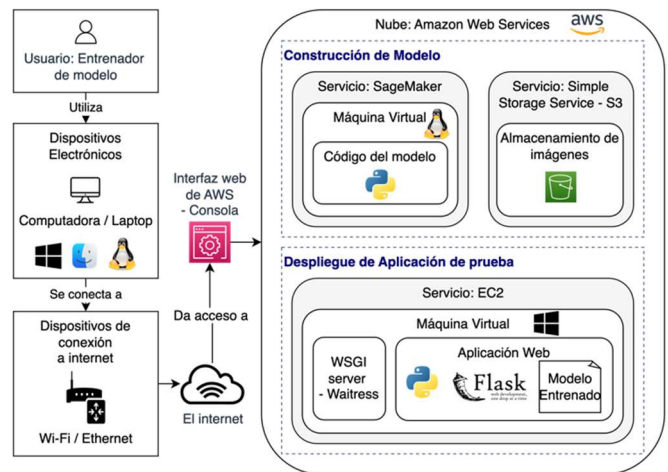


Fig. 4 Arquitectura integrada del modelo desarrollado.

5) Arquitectura por Capas

La quinta contribución es la entrega de la arquitectura por capas. Este es un enfoque de diseño que divide la funcionalidad en capas, principalmente en la capa de negocio, la de aplicaciones y la de tecnología. En la Figura 5 se aprecia a la capa de negocio, donde se cuenta con un actor; luego a la capa de aplicaciones, donde están los procesos, funciones, interfaces y objetos de datos; y finalmente la capa de tecnología, donde tenemos los nodos y softwares.

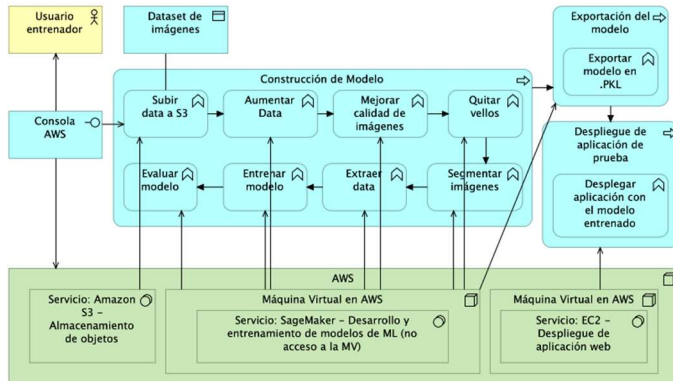


Fig. 5 Arquitectura por capas del modelo desarrollado.

IV. EXPERIMENTOS

En esta sección se detalla el experimento realizado, los recursos necesarios para su ejecución y la evaluación sobre los resultados.

A. Protocolo Experimental

El código del modelo se desarrolló localmente, y luego de verificar que las funciones cumplieran con lo establecido en el Diagrama del modelo (Figura 1), estas fueron enviadas a una instancia de SageMaker para ser ejecutadas.

Explicando más a fondo el manejo del algoritmo SVM, primero se hizo una investigación y prueba a pequeña escala sobre 3 tipos de SVM para determinar con cuál se obtendrían mejores métricas de efectividad. Se probó con RBF, Lineal y Polinómico; y se determinó que los mejores resultados se obtendrían con RBF. Radial Basis Function Kernel (RBF) es comúnmente usado en clasificación y se destaca en este ámbito [39]. Este método utiliza dos hiperparámetros: C y gamma. C controla la compensación entre ampliar el margen y reducir las clasificaciones erróneas, mientras que gamma ajusta la influencia de los ejemplos de entrenamiento cercanos en el límite de decisión. Para encontrar los valores óptimos de C y gamma se realizó una evaluación utilizando dos series de valores potenciales, y se determinó que se emplearía $C=5.0$ y $gamma=0.01$.

Posteriormente, se cargaron las imágenes y metadata a Amazon S3. Con ello se procedió a la ejecución de las fases establecidas en la Figura 1. Este procesamiento de data

continuó por varias de horas hasta que todas las imágenes fueron analizadas.

Finalmente, el código del modelo en SageMaker devolvió el archivo .PKL que contenía el modelo entrenado, los resultados Verdaderos Positivos, Verdaderos Negativos, Falsos Positivos y Falsos Negativos en base a un grupo de data de prueba (lo cual se utilizó para la matriz de confusión), y los resultados de las métricas de efectividad establecidas: precisión, exactitud, recall (o sensibilidad) y F1- score.

En cuanto a las especificaciones técnicas del desarrollo local del código; se utilizó Python 3.8.9, 2 laptops con CPUs Core i3 o superior, 8GB RAM como mínimo y 500GB de almacenamiento en disco SSD o más. En SageMaker se aprovisionó una máquina con 1 GPU, 8 vCPU, 32 GB de RAM y 50 GB de almacenamiento; y en S3 se utilizó, aproximadamente, 1.1 TB. En cuanto al código, este se encuentra en el siguiente repositorio: <https://github.com/Natalia020302/PRY20231010-v.1.0>

Una segunda sección de la validación consistió en tener sesiones con dermatólogos para conocer su apreciación del proyecto e identificar mejoras. Esta segunda validación consistió en 3 partes: primero se mostró la aplicación web de prueba que fue desarrollada utilizando el modelo entrenado para probar su funcionalidad a pequeña escala; segundo, se realizó una prueba “humano vs máquina” donde se otorgó el mismo set de imágenes a los doctores y al modelo para verificar cuántas clasificaciones se hicieron correctamente; y tercero, se realizaron preguntas de apreciación para los dermatólogos, para las cuales se utilizó la escala de Likert del 1 a 5.

Para el despliegue de la aplicación de prueba, tal como se puede apreciar en la Figura 2, se utilizó el servicio EC2 y un balanceador de carga de aplicaciones. La EC2 o máquina virtual era una Windows con 2 vCPUs, 4 GB de RAM y 50 GB de almacenamiento.

B. Resultados

Para el entrenamiento y validación se utilizaron los sets de datos de ISIC (International Skin Imaging Collaboration) 2019 y 2020, que contienen imágenes de lesiones cutáneas malignas y benignas de más de 2,000 pacientes. Cabe destacar que las imágenes fueron obtenidas en colaboración con el Hospital Clínic de Barcelona, Memorial Sloan Kettering Cancer Center, Medical University of Vienna, Melanoma Institute Australia, University of Athens Medical School y University of Queensland. Del total de imágenes entre ambos data sets se destinó el 70% al entrenamiento, y el restante 30% a la validación.

Para la fase de validación, primero, se realizó una matriz de confusión con el fin de proporcionar visualmente la comparación del resultado de las predicciones del modelo y sus valores reales en un conjunto de datos de prueba. La matriz se

encuentra en la Tabla 1 y dentro de esta se observan 4 categorías:

1) Verdaderos positivos (TP): Representan aquellos casos que el modelo realizó la clasificación de “Melanoma” correctamente. Según la matriz, el modelo identificó 9,116 imágenes como Melanoma de manera acertada.

2) Falsos positivos (FP): Casos en los que el modelo predijo incorrectamente un caso negativo de Melanoma. En nuestro caso se obtuvieron 2,053 falsos positivos.

3) Verdaderos negativos (TN): Representan aquellos casos que el modelo predijo correctamente que la imagen era No-Melanoma o un caso negativo de Melanoma. De acuerdo con los resultados se clasificaron correctamente 6,277 imágenes.

4) Falsos negativos (FN): Casos en los que el modelo predijo incorrectamente que la imagen era melanoma o que era un caso positivo. En el caso de los resultados del modelo propuesto se clasificaron 2,746 imágenes incorrectamente.

TABLA I
MATRIZ DE CONFUSIÓN

		Predicción	
		Positivo	Negativo
Real	Positivo	9,116 TP	2,053 FP
	Negativo	2,746 FN	6,277 TN

Dentro de la fase de validación, también se codificó el cálculo de las métricas de efectividad en base a los resultados de la Matriz de Confusión. Estos resultados se visualizan en la Tabla 2.

Cada una de las métricas significa lo siguiente:

1) La precisión es la proporción entre los casos positivos correctamente identificados sobre el total de casos positivos clasificados por el modelo [28]. El modelo obtuvo una precisión del 77% para clasificar las imágenes como melanoma.

2) El recall (o sensibilidad) es la proporción de casos positivos correctamente identificados sobre el total de casos reales positivos [28], [40]. El modelo obtuvo un recall del 82% para identificar las imágenes como malignas.

3) F1-score es un punto de armonía entre precisión y sensibilidad (recall), lo que provee una sola medida que simboliza un puntaje general del rendimiento del modelo. Mientras el puntaje sea mayor, el rendimiento del modelo es mejor [40]. Para el caso de la detección de melanoma se obtuvo un 80%.

4) Por último, tenemos a la exactitud. Esta medida es global y determina la exactitud general del modelo o la relación entre las predicciones correctas y el número total de predicciones [40]. Según el resultado obtenido, el modelo clasifica correctamente el 76% de los casos.

TABLA II
RESULTADO DE LA EXPERIMENTACIÓN

	Precisión	Recall	F1-Score	Exactitud
Melanoma Maligno	0.77	0.82	0.80	0.76

Como parte de la segunda validación dirigida a experiencia y discusión con doctores se divide en 3 partes:

En la primera parte se realizó una aplicación web utilizando el modelo desarrollado, con el objetivo de evidenciar y probar su funcionalidad en una aplicación. En la Figura 6 se visualiza un formulario que solicita los datos personales del paciente como nombres completos y edad. Luego de ello, se encuentran los datos con respecto a la lesión cutánea como el nivel del dolor, tez de piel, ubicación del lunar y por último se debe adjuntar la imagen de la lesión a analizar.

Fig. 6 Formulario de aplicación web de prueba, donde se deben registrar los datos del paciente y adjuntar la imagen de la lesión.

Luego de que el paciente seleccione el botón “Analizar”, el código procede a realizar la extracción de características ABCD de la imagen. Luego de ello, dentro del código se llamará al archivo del modelo (archivo .PKL), que analizará las características y brindará el porcentaje de probabilidad de que este se trate de Melanoma, ello se puede observar en la siguiente imagen:

Fig. 7 Vista de los resultados de probabilidad de que la lesión sea Melanoma.

Como resultado, presentamos el porcentaje de probabilidad de que la lesión o lunar sea melanoma en lugar de realizar una

clasificación, ya que nuestro objetivo principal no es generar preocupación a gran escala entre los usuarios. Es importante recordar que el melanoma es un cáncer altamente peligroso y de rápida propagación, y siguiendo las recomendaciones de algunos dermatólogos, optamos por mostrar la probabilidad en lugar de una clasificación, con el propósito de evitar generar pánico innecesario en los usuarios.

En la parte izquierda de color azul (Figura 7), agregamos un texto de aviso, que indica que estos resultados no son certificados por un médico, además se señala que la aplicación es una herramienta de soporte; por lo que se le recomienda al paciente acudir a un doctor que defina un diagnóstico oficial.

En la segunda parte de la validación se utilizaron 12 imágenes extraídas del repositorio ISIC 2020 y del libro Clinical Cases in Dermatology [41] para solicitarles a los doctores que realicen un diagnóstico en base a la información otorgada. Las mismas imágenes fueron analizadas con el modelo para dar su propio resultado en base a su entrenamiento. Se llevó a cabo esta prueba con el fin de realizar una comparación entre las respuestas y determinar qué tan cerca puede estar el modelo de brindar resultados parecidos a las evaluaciones de los doctores.

TABLA III
CANTIDAD DE RESPUESTAS CORRECTAS

Promedio de aciertos por los dermatólogos	Cantidad de respuestas correctas por el modelo entrenado
7/12	7/12

De acuerdo con los resultados presentados de la Tabla 3, en promedio, los doctores tuvieron 7 aciertos de 12 imágenes; y el modelo entrenado obtuvo 7 aciertos de 12. Los resultados han demostrado que el modelo iguala en rendimiento al promedio de evaluación realizada por los doctores. Esto comprueba que el modelo es capaz de convertirse en una herramienta de apoyo médico, con la capacidad de brindar una respuesta o diagnóstico inicial para incentivar al usuario a acudir a un dermatólogo.

En la tercera validación se realizó una encuesta de apreciación del proyecto a los doctores. Se utilizó la Escala de Likert como herramienta para recolectar cuantitativamente las opiniones, percepción y actitud de los doctores con respecto a nuestro proyecto.

De acuerdo con lo mencionado anteriormente, se realizó un cuestionario conformado de 7 preguntas, que están diseñadas para ser calificadas en una escala del 1 al 5, que va desde “Totalmente en desacuerdo” hasta “Totalmente de acuerdo”. Ello con el fin de obtener datos cuantitativos que serán analizados para identificar la satisfacción y opinión de los doctores con respecto al modelo.

Las preguntas formuladas fueron las siguientes:

TABLA IV
PREGUNTAS DE APRECIACIÓN Y PROMEDIOS DE RESPUESTAS

Pregunta	Promedio de respuesta por los doctores
¿Considera que el modelo proporciona una herramienta útil para el diagnóstico temprano de melanoma?	3.75
¿Considera que el modelo de detección temprana de melanoma puede ser una herramienta complementaria en la práctica médica diaria?	4.00
¿Usted lo recomendaría a sus pacientes para un pre-diagnóstico?	4.00
¿Cómo calificaría la precisión general del modelo?	3.75
¿Cómo calificarías la velocidad de respuesta y el tiempo de procesamiento del modelo?	4.50
¿Crees que, de entrenar a mayor escala al modelo, podría ser utilizado en entornos clínicos reales para respaldar la toma de decisiones médicas?	4.25
¿Crees que el modelo podría integrarse fácilmente en el flujo de trabajo de un dermatólogo?	3.75

De acuerdo con los resultados visualizados en la Tabla 4, se verifica que todas las preguntas obtuvieron un puntaje mayor a 3.75 y el promedio de todas las respuestas es 4.00. Esto indica que, que la mayoría de las respuestas de los doctores encuestados tienden a estar entre “De acuerdo” o “Muy de acuerdo”, por lo que proporcionan calificaciones positivas en base a las preguntas relacionadas al modelo.

C. Discusión

Tal como se mencionó en la subsección anterior, se establecieron métricas de validación con el fin de evaluar los resultados y rendimiento del modelo. Estas se componen de fórmulas de divisiones basadas en los positivos, negativos y total de casos. En el modelo propuesto se propuso que las métricas deben ser iguales o superiores al 75% y de acuerdo con lo observado en la Tabla 2 se cumplió el objetivo.

Al momento de realizar la primera validación (matriz de confusión y métricas de efectividad), surgió un problema que llegamos a resolver, pero consideramos óptimo comentar. Inicialmente decidimos aplicar la técnica de aumento de data establecida en la Figura 1 a todo el set de datos. Sin embargo, no tomamos en cuenta la posibilidad de la creación de un sesgo o mayoría en una de las clases, lo que posteriormente provocó bajos resultados en las métricas de efectividad.

Al aplicar el aumento de data obtuvimos una relación de 1 a 10 entre imágenes de melanoma y no-melanoma. Esto creó una diferencia significativa entre las clases, lo que afectó nuestros resultados de evaluación. Para evitar el problema se decidió realizar el aumento de data a las imágenes de melanoma y unas cuantas de no-melanoma; siempre verificando que obtengamos la misma cantidad de data en ambas clases.

Por otro lado, con respecto a la encuesta realizada a los doctores; obtuvimos un promedio de 4.00 en el cuestionario, lo cual indica una apreciación positiva respecto al proyecto. Cabe resaltar que, también se realizó una pregunta abierta con el

objeto de obtener recomendaciones para el modelo. En esta obtuvimos opiniones y comentarios variados por los doctores profesionales, lo cual nos apoyan brindándonos puntos de mejora desde la perspectiva de un paciente. Por ejemplo, nos brindaron comentarios acerca de ser más sutiles al momento de brindar el resultado, palabras más entendibles en el formulario, entre otros. Las sugerencias fueron analizadas y aplicadas en la aplicación web de prueba. Además de ello, sus opiniones nos brindaron mayor empatía y consciencia desde la perspectiva de un paciente.

V. CONCLUSIÓN

En este estudio se ha demostrado la eficacia del algoritmo SVM en la detección de melanoma a partir de imágenes médicas. Esto es respaldado por los resultados de las métricas de efectividad obtenidas, que se mantuvieron por sobre el 75%.

Para poder hacer esto posible nos apoyamos del método ABCD, el cual es utilizado actualmente por dermatólogos y que nosotras acoplamos para que sea usado por el modelo. Ello permitió que el modelo evalúe de manera similar a la de un especialista.

Además, este proyecto ha permitido verificar la posibilidad de utilizar el modelo en aplicaciones médicas; lo cual puede apoyar a la solución de la detección temprana del melanoma al convertirse en una herramienta de soporte para la atención médica.

Consideramos que existen dos puntos importantes que podrían aplicarse a futuro para mejorar el modelo: El primero es el despliegue del modelo en un servicio de la nube que permita el aprendizaje continuo o aprendizaje en línea. Esto permitiría que el modelo se actualice constantemente con nuevos datos, a medida que los usuarios ingresen más imágenes en las diversas implementaciones (por ejemplo, aplicaciones desplegadas que invoquen al modelo por medio de un endpoint o punto de conexión). De esta manera, con el pasar del tiempo, el modelo mejorará su capacidad de detección, dando resultados más precisos y actualizados.

El segundo punto de mejora a futuro es el entrenar un modelo específico para la identificación y segmentación de las lesiones cutáneas. Ya que hemos aplicado una técnica basada en el mayor agrupamiento de píxeles y color, para identificar el área como la lesión y recortarla. Este paso es crítico ya que, un recorte incorrecto de la imagen puede resultar en falsos positivos o negativos. Por lo tanto, consideramos sumamente beneficioso entrenar un segundo modelo centrado en la identificación de las lesiones cutáneas en las imágenes. Esto ayudaría a reducir las predicciones erróneas y, en general, mejorar la precisión del modelo.

REFERENCIAS

[1] Organización Mundial de la Salud, "Ultraviolet radiation." Accessed: Apr. 10, 2023. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/ultraviolet-radiation>

[2] Organización Mundial de la Salud, "La aplicación SunSmart Global UV ayuda a protegerse de los peligros de la exposición al sol y promueve la salud pública." Accessed: Apr. 14, 2023. [Online]. Available: <https://www.who.int/es/news/item/21-06-2022-sunsmart-global-uv-app-helps-protect-you-from-the-dangers-of-the-sun-and-promotes-public-health>

[3] S. Escobar, "PRÁCTICAS DE PREVENCIÓN FRENTE A LOS EFECTOS DE LA RADIACIÓN ULTRAVIOLETA EN AGRICULTORES DE LA COOPERATIVA CENFROCAFE," 2022.

[4] La República, "Perú ocupa el primer lugar de radiación solar más alto en el mundo, según la Liga contra el cáncer | cancer en la piel | Sociedad | La República." Accessed: Aug. 28, 2023. [Online]. Available: <https://larepublica.pe/sociedad/2020/02/26/liga-contra-el-cancer-peru-ocupa-el-primer-lugar-de-radiacion-solar-mas-alto-en-el-mundo-cancer-en-la-piel>

[5] P. Del Fiore *et al.*, "Altitude Effect on Cutaneous Melanoma Epidemiology in the Veneto Region (Northern Italy): A Pilot Study," *Life* 2022, Vol. 12, Page 745, vol. 12, no. 5, p. 745, 2022, doi: 10.3390/LIFE12050745.

[6] W. Ramos *et al.*, "Exposure to Atmospheric Ozone Disruption and Altitude Over 3500 m.a.s.l. are Associated with a Higher Prevalence of Photodermatoses in Pediatric Population of High-Altitude in Peru," *Clinical*, 2022, doi: 10.2147/CCID.S374884.

[7] American Cancer Society, "¿Qué es el cáncer de piel tipo melanoma?" Accessed: Mar. 29, 2023. [Online]. Available: <https://www.cancer.org/es/cancer/cancer-de-piel-tipo-melanoma/acerca/que-es-melanoma.html>

[8] American Cancer Society, "Melanoma Skin Cancer Statistics." Accessed: Mar. 24, 2023. [Online]. Available: <https://www.cancer.org/cancer/melanoma-skin-cancer/about/key-statistics.html>

[9] Instituto Nacional del Cáncer, "Estadísticas del cáncer - NCI." Accessed: Sep. 10, 2022. [Online]. Available: <https://www.cancer.gov/espanol/cancer/naturaleza/estadisticas>

[10] El Peruano, "EsSalud reporta 1,877 casos de melanoma y otros tumores de piel durante el 2022." Accessed: Jun. 22, 2023. [Online]. Available: <https://www.elperuano.pe/noticia/203327-essalud-reporta-1877-casos-de-melanoma-y-otros-tumores-de-piel-durante-el-2022>

[11] Ministerio de Salud, "Día del lunar: Cada año en el Perú, se diagnostican 1300 nuevos casos de cáncer de piel tipo melanoma - Noticias - Ministerio de Salud - Gobierno del Perú," *Plataforma digital única del Estado Peruano*, 2022. Accessed: Sep. 10, 2022. [Online]. Available: <https://www.gob.pe/institucion/minsa/noticias/581732-dia-del-lunar-cada-ano-en-el-peru-se-diagnostican-1300-nuevos-casos-de-cancer-de-piel-tipo-melanoma>

[12] K. Córdova and M. Ochoa, "EFECTIVIDAD DE LA INTERVENCIÓN EDUCATIVA PARA MEJORAR LOS CONOCIMIENTOS, ACTITUDES Y PRÁCTICAS SOBRE LA PREVENCIÓN DE CÁNCER DE PIEL EN NIÑOS Y ADOLESCENTES," 2019.

[13] D. Xolisile *et al.*, "Delays to Cancer Care, Exploring the Factors Associated with Barriers to Accessing Comprehensive Cancer Care in Eswatini: A Qualitative Study," *Asian Pacific Journal of Cancer Care*, vol. 7, no. 3, pp. 499–507, 2022, doi: 10.31557/APJCC.2022.7.3.499-507.

[14] P. Badri, V. Baracos, S. Ganatra, H. Lai, F. Samim, and M. Amin, "Retrospective study of factors associated with late detection of oral cancer in alberta: A qualitative study," *PLoS One*, vol. 17, no. 4, p. e0266558, 2022, doi: 10.1371/JOURNAL.PONE.0266558.

[15] Instituto Peruano de Economía, "El costo de unificar la salud." Accessed: Jun. 06, 2023. [Online]. Available: <https://www.ipe.org.pe/porta/el-costo-de-unificar-la-salud/>

- [16] M. Costabel, "The Peruvian Poor Can't Breathe in the Pandemic." Accessed: Jun. 06, 2023. [Online]. Available: <https://foreignpolicy.com/2020/10/06/peru-coronavirus-covid-pandemic-oxygen-health-care/>
- [17] M. Rehman *et al.*, "Machine learning based skin lesion segmentation method with novel borders and hair removal techniques," *PLoS One*, vol. 17, no. 11 November, Nov. 2022, doi: 10.1371/journal.pone.0275781.
- [18] Z. Sanchez, A. Alva, M. Zimic, and C. Del Carpio, "An algorithm for characterizing skin moles using image processing and machine learning," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 11, no. 4, pp. 3539–3550, 2021, doi: 10.11591/ijece.v11i4.pp3539-3550.
- [19] M. Bistron and Z. Piotrowski, "Comparison of Machine Learning Algorithms Used for Skin Cancer Diagnosis," *Applied Sciences* 2022, Vol. 12, Page 9960, vol. 12, no. 19, p. 9960, Oct. 2022, doi: 10.3390/APP12199960.
- [20] "A machine learning approach to automatic detection of irregularity in skin lesion border using dermoscopic images." Accessed: Apr. 19, 2023. [Online]. Available: <https://scopus.upc.elogim.com/record/display.uri?eid=2-s2.0-85120305564&origin=resultslist&sort=plf-f&src=s&st1=A+machine+learning+approach+to+automatic+detection+of+irregularity+in+skin+lesion+border+using+dermoscopic+images&sid=138441c6a6db7f5bfaf0a9fdd8b2b894&sot=b&sdt=b&sl=166&s=TITLE-ABS-KEY%28A+machine+learning+approach+to+automatic+detection+of+irregularity+in+skin+lesion+border+using+dermoscopic+images%29+AND+PUBYEAR+%3e+2015+AND+PUBYEAR+%3e+2015&relpos=0&citeCnt=28&searchTerm=>
- [21] S. Santhosh and N. S. Ramaiah, "Cloud-Based Software Development Lifecycle: A Simplified Algorithm for Cloud Service Provider Evaluation with Metric Analysis," *Big Data Mining and Analytics*, vol. 6, no. 2, pp. 127–138, 2023, doi: 10.26599/BDMA.2022.9020016.
- [22] U. Bhimavarapu and G. Battineni, "Skin Lesion Analysis for Melanoma Detection Using the Novel Deep Learning Model Fuzzy GC-SCNN," *Healthcare* 2022, Vol. 10, Page 962, vol. 10, no. 5, p. 962, 2022, doi: 10.3390/HEALTHCARE10050962.
- [23] A. Althnian *et al.*, "Impact of Dataset Size on Classification Performance: An Empirical Evaluation in the Medical Domain," *Multidisciplinary Digital Publishing Institute*, vol. 11, no. 2, pp. 1–18, Jan. 2021, doi: 10.3390/APP11020796.
- [24] M. A. Hashmani, S. M. Jameel, S. S. H. Rizvi, and S. Shukla, "An adaptive federated machine learning-based intelligent system for skin disease detection: A step toward an intelligent dermoscopy device," *Applied Sciences (Switzerland)*, vol. 11, no. 5, pp. 1–19, Mar. 2021, doi: 10.3390/APP11052145.
- [25] C. Nikou *et al.*, "An Effective Skin Cancer Classification Mechanism via Medical Vision Transformer," *Sensors*, 2022, doi: 10.3390/s22114008.
- [26] D. N. H. Thanh, V. B. S. Prasath, L. M. Hieu, and N. N. Hien, "Melanoma Skin Cancer Detection Method Based on Adaptive Principal Curvature, Colour Normalisation and Feature Extraction with the ABCD Rule," *J Digit Imaging*, vol. 33, no. 3, pp. 574–585, Jun. 2020, doi: 10.1007/S10278-019-00316-X.
- [27] S. İlkin, T. H. Gençtürk, F. Kaya Gülağız, H. Özcan, M. A. Altuncu, and S. Şahin, "hybSVM: Bacterial colony optimization algorithm based SVM for malignant melanoma detection," *Engineering Science and Technology, an International Journal*, vol. 24, no. 5, pp. 1059–1071, 2021, doi: 10.1016/J.JESTCH.2021.02.002.
- [28] L. Sun and S. Li, "A Study of Breast Cancer Classification Algorithms by Fusing Machine Learning and Deep Learning," *Applied Sciences* 2023, Vol. 13, Page 3097, vol. 13, no. 5, p. 3097, Feb. 2023, doi: 10.3390/APP13053097.
- [29] I. A. Alfi, M. M. Rahman, M. Shorfuazzaman, and A. Nazir, "A Non-Invasive Interpretable Diagnosis of Melanoma Skin Cancer Using Deep Learning and Ensemble Stacking of Machine Learning Models," *Diagnostics (Basel)*, vol. 12, no. 3, Mar. 2022, doi: 10.3390/DIAGNOSTICS12030726.
- [30] B. Mahesh, "Machine Learning Algorithms-A Review," *International Journal of Science and Research*, 2020, doi: 10.21275/ART20203995.
- [31] Entel, "¿Qué es y cómo funciona el reconocimiento de imágenes? | Entel Comunidad Empresas." Accessed: Mar. 29, 2023. [Online]. Available: <https://ce.entel.cl/articulos/reconocimiento-de-imagenes/>
- [32] M. M. Mijwil, "Skin cancer disease images classification using deeplearning solutions," *Multimed Tools Appl*, vol. 80, pp. 26255–26271, 2021, doi: 10.1007/s11042-021-10952-7.
- [33] M. Nawaz *et al.*, "Melanoma localization and classification through faster region-based convolutional neural network and SVM," *Multimed Tools Appl*, vol. 80, no. 19, pp. 28953–28974, Aug. 2021, doi: 10.1007/S11042-021-11120-7/METRICS.
- [34] J. Y. Wang, E. B. Wang, and S. M. Swetter, "What Is Melanoma?," *JAMA*, vol. 329, no. 11, pp. 948–948, 2023, doi: 10.1001/JAMA.2022.24888.
- [35] American Cancer Society, "¿Qué es el cáncer de piel tipo melanoma?" Accessed: Sep. 10, 2022. [Online]. Available: <https://www.cancer.org/es/cancer/cancer-de-piel-tipo-melanoma/acerca/que-es-melanoma.html>
- [36] HC Marbella International Hospital. "ABCDE del Melanoma ." Accessed: Nov. 03, 2023. [Online]. Available: <https://www.hcmarbella.com/es/abcde-del-melanoma/>
- [37] Beaumont Health, "ABCDE Assessment for Melanoma." Accessed: May 30, 2023. [Online]. Available: <https://www.beaumont.org/conditions/melanoma/abcde's-of-melanoma>
- [38] S. Martinez Congales, "Estudio de características morfológicas e inmunohistoquímicas del tumor primario predictivas de metástasis en ganglio centinela," Universidad Autonoma de Barcelona, Barcelona, 2007.
- [39] J. Wainer and P. Fonseca, "How to tune the RBF SVM hyperparameters? An empirical evaluation of 18 search algorithms," *Artif Intell Rev*, vol. 54, no. 6, pp. 4771–4797, Aug. 2021, doi: 10.1007/S10462-021-10011-5/METRICS.
- [40] S. Bechelli and J. Delhommelle, "Machine Learning and Deep Learning Algorithms for Skin Cancer Classification from Dermoscopic Images," *Bioengineering*, 2022, doi: 10.3390/bioengineering9030097.
- [41] T. Lotti, M. Tirant, and U. Wollina, *Clinical Cases in Dermatology. in Clinical Cases in Dermatology*. Cham: Springer International Publishing, 2020. doi: 10.1007/978-3-030-50820-3.