

**UNIVERSIDAD CATÓLICA SANTO TORIBIO DE MOGROVEJO
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA DE SISTEMAS Y COMPUTACIÓN**



**SISTEMA INTELIGENTE PARA LA IDENTIFICACIÓN DE
DERMATOFITOSIS EN PACIENTES DE UN CENTRO
DERMATOLÓGICO DE LA CIUDAD DE CHICLAYO**

**TESIS PARA OPTAR EL TÍTULO DE
INGENIERO DE SISTEMAS Y COMPUTACIÓN**

AUTOR

JHEINER REAÑO COVEÑAS

ASESOR

RICARDO DAVID IMÁN ESPINOZA

<https://orcid.org/0000-0003-0409-8773>

Chiclayo, 2021

**SISTEMA INTELIGENTE PARA LA IDENTIFICACIÓN DE
DERMATOFITOSIS EN PACIENTES DE UN CENTRO
DERMATOLÓGICO DE LA CIUDAD DE CHICLAYO**

PRESENTADA POR:
JHEINER REAÑO COVEÑAS

A la Facultad de Ingeniería de la
Universidad Católica Santo Toribio de Mogrovejo
para optar el título de

INGENIERO DE SISTEMAS Y COMPUTACIÓN

APROBADA POR:

Mariana Chavarry Chankay
PRESIDENTE

Jury Yesenia Aquino Trujillo
SECRETARIO

Ricardo David Iman Espinoza
VOCAL

Dedicatoria

A mi abuela, quien en vida siempre me apoyó en cada uno de mis sueños.

A mi madre y mi hermana por su amor incondicional.

Agradecimientos

A mi asesor de tesis el Ing. Iman Espinoza Ricardo, por su dedicación y su apoyo para guiar mis ideas en todo este proceso de investigación.

Índice

Resumen	5
Abstract	6
Introducción	7
Revisión de literatura	9
Materiales y métodos.....	15
Resultados y discusión.....	18
Conclusiones.....	31
Recomendaciones.....	32
Referencias	34
Anexos.....	38

Resumen

La presente investigación demuestra que un sistema inteligente (SI) elaborado en base a un modelo de machine learning ha solucionado los problemas de identificación de dermatofitosis en un centro dermatológico, brindando aportes tales como la gestión de información oportuna para la atención de los pacientes, registro de tratamientos y visualización del proceso evolutivo de la enfermedad. Se planteó como objetivo principal desarrollar un SI para la identificación de dermatofitosis en pacientes de un centro dermatológico de la ciudad de Chiclayo. El SI permitirá a través de imágenes identificar la enfermedad y gestionar la información de los pacientes que sufran esta anomalía y no puedan acceder a un especialista. Con la problemática suscitada se realizó las entrevistas correspondientes al especialista de la empresa en estudio y se llegó a desarrollar el SI empleando la metodología XP integrada con técnicas de inteligencia artificial (IA). Al ser la propuesta un sistema web se empleó HTML y para el estilo del front-end se utilizó el framework Bootstrap, el dinamismo de las interfaces fue complementado por JavaScript. En el back-end se emplearon los lenguajes de programación PHP y Python, como gestor de base de datos MySQL. El algoritmo empleado fue Convolutional Neural Networks, gracias al cual luego se entrenó el modelo de machine learning y se alcanzó una especificidad de 83.33% y una sensibilidad de 88.89%. Finalmente, se obtuvo de los usuarios una alta puntuación de aceptación para la utilidad y usabilidad del SI.

Palabras claves: sistema inteligente, machine learning, inteligencia artificial, dermatología, dermatofitosis, diagnóstico por imágenes.

Abstract

The present research shows that an intelligent system (IS) developed based on a machine learning model has solved the problems of identification of dermatophytosis in a dermatological center, providing contributions such as the management of timely information for patient care, registration of treatments and visualization of the evolutionary process of the disease. The main objective was to develop an IS for the identification of dermatophytosis in patients from a dermatological center in the city of Chiclayo. The IS will allow images to identify the disease and manage the information of patients who suffer from this anomaly and cannot access a specialist. With the problems raised, the corresponding interviews with the specialist of the company under study were conducted and the IS was developed using the XP methodology integrated with artificial intelligence (AI) techniques. As the proposal was a web system, HTML and the Bootstrap framework was used for the front-end style, the dynamism of the interfaces was complemented by JavaScript. On the back-end, the PHP and Python programming languages were used, as the MySQL database manager. The algorithm used was Convolutional Neural Networks, thanks to which the machine learning model was later trained and a specificity of 83.33% and a sensitivity of 88.89% were reached. Finally, a high acceptance score for the usefulness and usability of the IS was obtained from the specialists.

Keywords: intelligent system, machine learning, artificial intelligence, dermatology, dermatophytosis, diagnostic imaging

Introducción

La dermatofitosis (conocida también como tiña) son infecciones que se manifiestan de manera superficial. Estas infecciones son causadas por hongos del tipo dermatofitos que atacan a los tejidos de la piel [1]. Este tipo de anomalías epidérmicas están esparcidas en todo el mundo, con mayor frecuencia en las zonas cuyos climas son cálidos y húmedos. Este mal no distingue raza, sexo o edad, todas las personas están propensas a adquirirlo. La Organización Mundial de la Salud (OMS) ha calculado una frecuencia global de micosis superficial de 20 a 25% del total de la población, siendo los dermatofitos responsables de 5 a 10%. La manera en la que una persona puede contagiarse es por estar en contacto con animales domésticos, que presentan alguna infección [2].

Un estudio realizado por Boncompte *et. al.* [3] en noviembre de 2008 (post verano) en España indicó, que las dermatofitosis forman el 67.2% de los casos de micosis. Si se hace un enfoque a Sudamérica respecto a los niveles de infección por dermatofitosis, por ejemplo, tenemos a Uruguay [4] país en el cual entre los años 1990 y 1997 se estudiaron 3,141 pacientes de los cuales se identificaron 220 casos de dermatofitosis representando el 59.9% de las micosis superficiales. Otro ejemplo es el presentado en Venezuela, para el año 2010 [5], las dermatofitosis llegaron a representar el 60% de las micosis de tipo superficial.

En el Perú también se da estos escenarios, en Ayacucho de acuerdo con Romero *et. al.* [6] el 68% de los estudiantes analizados del centro educativo “San Juan de la Frontera” presentaron dermatofitosis en el año 2010. En el norte del Perú también se han presentado casos de dermatofitosis; en 1998 (año en se produjo el fenómeno del niño) según el estudio descrito por Cárdenas *et. al.* [7] se analizó a pacientes con diagnóstico de dermatofitosis que acudieron a consulta externa del servicio de dermatología del Hospital Regional Docente de Trujillo. Se obtuvo como resultado un total de 44 casos de tiñas capitis, de los cuáles 29 (65.9%) fueron adquiridos por féminas y los otros 15 (34.1%) correspondieron al sexo masculino.

El biólogo Ventura en su artículo Dermatofitosis por *Microsporum canis* [8] manifiesta que, en el departamento de Lambayeque, se presentan casos de dermatofitosis del tipo corporis y capitis. Resultados más a detalle de estos casos son expuestos en la investigación realizada por Bernilla Samamé *et. al.* [9], el cual indica que, en el Hospital Regional Lambayeque, en los últimos 3 años, los casos de infecciones fúngicas han ido en aumento, en el cual el 15% estuvo representado por dermatofitosis en el 2015.

El poder diferenciar estas anomalías muchas veces depende de la experiencia del médico a cargo, dado que el entorno puede alterar los síntomas que presenta la enfermedad. Esto es debido a que los ambientes donde transcurren con mayor frecuencia los pacientes son totalmente distintos al ambiente donde es evaluada la anomalía. Del mismo modo influyen factores tales como la humedad, luminosidad y temperatura. Por tal motivo hay que considerar las variaciones que se puedan presentar al examinar una infección de la piel para brindar un adecuado diagnóstico. También en su desesperación, los pacientes suelen automedicarse, según la Dra. Pajuelo [10] más del 50% de los peruanos lo hace, pero no saben a ciencia cierta qué es lo que tienen, agravando la situación de la enfermedad.

Actualmente en el centro dermatológico de estudio, el proceso para diagnosticar cualquier tipo de anomalía de la piel se lleva a cabo de manera “tradicional”, y después de realizarse el levantamiento de información, a través de entrevistas, se puede concluir que mínimamente para poder determinar el diagnóstico final sobre estos trastornos de la piel se necesitan quince

minutos desde que se llega al centro dermatológico, generando retraso e inclusive postergación en la atención de los pacientes. También uno de los colaboradores del centro dermatológico manifestó una desorganización del material multimedia y de los datos registrados del paciente; lo que dificulta el seguimiento o reactivar un tratamiento para un paciente determinado.

La presente tesis se inició poniendo en manifiesto que en nuestra región Lambayeque y alrededores esta anomalía epidérmica es concurrente y en la mayoría de veces es confundida por las características visuales que presenta, este desconcierto está directamente relacionado con la experiencia del especialista. Ante esta realidad, se formuló lo siguiente, que el proceso de identificación de dermatofitosis genera una gran demanda de la capacidad visual por parte de los expertos dermatólogos, por lo que existen resultados equívocos.

Frente a lo planteado y la necesidad de profundizar el problema, se realizó la investigación del tipo desarrollo tecnológico. Para ello, se determinó desarrollar un sistema inteligente para la identificación de dermatofitosis en pacientes de un centro dermatológico de la ciudad de Chiclayo, considerando las siguientes fases: Planificación, Diseño, Desarrollo y Pruebas; para ello se tuvo que identificar el algoritmo idóneo de la red neuronal artificial para el análisis de las imágenes, alcanzar un alto grado de especificidad del sistema inteligente para evidenciar la confiabilidad del mismo, alcanzar un alto grado de sensibilidad del sistema inteligente para evidenciar la confiabilidad del mismo y finalmente obtener de los usuarios una alta puntuación de aceptación para la utilidad y usabilidad del sistema inteligente.

El desarrollo del presente trabajo proporciona un aporte teórico de mucha importancia para la investigación haciendo uso de técnicas de inteligencia artificial (IA), específicamente en el área de sistemas inteligentes y su aplicación en el sector salud. El sistema inteligente (SI) permitió la identificación preliminar de la enfermedad dermatofitosis, donde era necesario debido a que existen variedades de la misma, tal como lo manifiesta el profesor de dermatología y micología Roberto Arenas Guzmán en su libro *Micología médica ilustrada* [11] en el que nos detalla que estas tiñas pueden aparecer en diferentes partes del organismo, por diversos hongos y, por ende, la medicación es distinta. El dermatólogo necesita ser apoyado para determinar con mayor precisión si el paciente presenta esta anomalía epidérmica para brindarle un adecuado tratamiento.

La justificación científica de este trabajo se basa en que existen pocas aplicaciones de IA en el área de medicina en la región Lambayeque. Tampoco existe la puesta en práctica de la telemedicina enfocada en problemas de la piel. En el centro dermatológico de estudio, como al igual que otros centros, el proceso de diagnóstico se realiza de manera “tradicional”.

El desarrollo de esta investigación se justifica socialmente porque la puesta en marcha de este SI beneficia a las comunidades que son propensas a este tipo de enfermedades dermatológicas que no son atendidas a tiempo. Del mismo modo los dermatólogos con esta herramienta tienen como resultado del proceso de anamnesis la identificación de dermatofitosis, respuesta dada en menor tiempo y con mayor exactitud para prevenir el avance paulatino de este trastorno de la piel.

La presente tesis tiene por justificación tecnológica el desarrollo de un sistema inteligente que permita identificar la anomalía de dermatofitosis, para ello el sistema evaluará pixel por pixel, gracias a un modelo de machine learning previamente entrenado, cada imagen que los usuarios deseen determinar si presentan características propias de dermatofitosis. El dermatólogo dará su aprobación a los resultados y luego podrá asignar a través del sistema inteligente la cantidad de sesiones del tratamiento y el intervalo de días que existirá entre ellos.

Los pacientes desde sus hogares haciendo uso de internet podrán registrar la imagen correspondiente a la sesión de acuerdo a la fecha que se le indique.

Revisión de literatura

Antecedentes

Domínguez en su trabajo de tesis [12] empleó técnicas de aprendizaje de máquina de soporte vectorial (SVM) y árboles de decisiones para detectar cáncer de la piel en base a un número de características que presenten los melanomas. Este sistema vinculó técnicas de machine learning con procesamiento digital de imágenes que compara las características extraídas de las imágenes y las analiza con una base de datos, de esta manera se determina la exactitud de los resultados. Como conclusión el autor sostiene que el sistema SVM presentó un 98.1% de sensibilidad, un 65.2% de especificidad y un 80.1% de exactitud (precisión) tras trabajar con 28 características del melanoma. Mientras que el árbol de decisión tras realizar el mismo análisis de clasificación obtuvo, un 86.1% de sensibilidad, un 85.5% de especificidad y un 72.7% de exactitud (precisión). La relación con esta investigación es la manera de identificar la capacidad predelictiva de sistemas que asistente en entornos de dermatología.

En los antecedentes nacionales se ha considerado la tesis realizada por Coronado [13] quien presentó un método de reconocimiento de imágenes no dermatoscópicas, basado en redes neuronales convolutivas (RNC) y un método de clasificación de imágenes basado en autocodificadores. Gracias a esta integración se obtuvieron las siguientes conclusiones: los autocodificadores es un método novedoso para la detección de cáncer de piel y que ha logrado mayor precisión (1.56% más de la lograda solo con RNC). También se logró realizar el repositorio de imágenes con casos de enfermedades de piel gracias a instituciones públicas y a repositorios de imágenes compartidas por el estado del arte. Finalmente, se desarrolló un método para la extracción de características de imágenes y a partir de ellas poder clasificarlas. Este antecedente se ha considerado por las técnicas de tratamiento de imágenes y utiliza un tipo de red neural especial para ello.

Según Gamboa [14], en su investigación plantea que las micosis superficiales son infecciones frecuentes y es muy importante el diagnosticarlas a tiempo, para lograr tal cometido, este autor desarrolló una aplicación móvil basada en la metodología Mobile-D y técnicas de comparación y clasificación de imágenes digitales (Algoritmo Backpropagation). En cuanto a los resultados, se realizó la prueba de normalidad de cada indicador de sensibilidad y especificidad usando el software Statistical Package for the Social Sciences - SPSS. Esta investigación presentó como conclusión que el valor porcentual varía de 62.4639% (antes de la implementación de la aplicación móvil) a 83.6244% (después de aplicar el sistema) por lo que se demuestra que se registró un incremento en la sensibilidad del diagnóstico preliminar; también se obtuvo un aumento en cuanto a la especificidad del diagnóstico preliminar de 50.1967% a 83.3328%; es decir, para el diagnóstico preliminar mediante fotografías digitales se registró un incremento de 21.1605% en cuanto a sensibilidad, y de 33.1361% en cuanto a especificidad. Esta tesis presenta una serie de algoritmos que son aplicados al sector salud por lo que servirá de guía para realizar la selección de un algoritmo para el desarrollo de la presente investigación.

En los antecedentes locales se tiene a la investigación realizada por Rodríguez [15] quien presentó un modelo de gestión de riesgos de tecnologías de la información ajustando este último a las necesidades de la empresa de estudio. El modelo en mención contempló el análisis del sector y del contexto de la organización, del mismo modo identificó los activos, las amenazas

y las vulnerabilidades que implican las propuestas tecnológicas. Para comprobar la confiabilidad de los instrumentos empleados en este estudio, estos fueron sometidos a un análisis estadístico. De igual manera para demostrar la validez y aplicabilidad del modelo asociado al uso de tecnología, este fue evaluado por expertos. Rodríguez estableció un procedimiento para la determinación de los procesos críticos en la organización que constituyen parte fundamental en la continuidad del negocio. El nivel de aceptación del servicio web propuesto fue de “muy bueno” según el coeficiente alfa de Cronbach empleado. Esta tesis ha sido considerada con el fin de poder determinar las técnicas y métodos para determinar el nivel de aceptación de una propuesta relacionada con tecnologías de información.

Otro antecedente local es el presentado por Vásquez [16] quien en su informe de tesis planteó elaborar un algoritmo de visión por computadora para detectar huevos de *Trichuris trichiura*, analizando imágenes microscópicas de muestras coprológicas con alta sensibilidad y precisión; para concretar esto, el autor usó 1000 imágenes, de las cuales empleó el 70% para el entrenamiento del algoritmo y el 30 % restante para validar el funcionamiento del mismo. Estas imágenes tenían como tamaño 65 x 65 píxeles extraídas de 30 imágenes. Vásquez elaboró programas en empleando el lenguaje de programación Python y se apoyó de librerías, tales como *imutils*, *OpenCV*, *argparse*, *Scikit-learn*, *cPickle*, *Matplotlib* y *Numpy* para obtener las imágenes redimensionadas, así como también el poder graficar histogramas, probar y guardar el clasificador con diferentes vectores de características. Como conclusión de esta investigación, se presentó que usando el algoritmo del vecino más cercano con métrica Manhattan y un vecino para la clasificación, se alcanzó una sensibilidad de 99,35% y la precisión del mismo fue de 96.1%. La relación que existe con esta investigación son las librerías empleadas para poder dar el tratamiento previo a las imágenes antes de que estas sean analizadas por la red neuronal y también por la manera de mostrar gráficamente los resultados antes, durante y después del entrenamiento de la red artificial.

Finalmente se ha considerado como antecedente local el presentado por Santos [17] quien describe la aplicación de un algoritmo de planificación, integrado con una aplicación móvil y web responsiva con lo que se redujo las demoras en la atención de las solicitudes de los clientes de la empresa de estudio. Esta propuesta logró mejorar la elaboración de reportes de solicitudes que no eran aceptadas generando insatisfacción de los clientes. La metodología utilizada para el desarrollo de software fue Extreme Programming (XP) permitiendo una interacción ágil y fácil entre el equipo desarrollador y la empresa. Como conclusión de esta investigación se logró aumentar la satisfacción de los usuarios en un 78.67% gracias a una encuesta aplicada a los clientes de la empresa estudiada tras realizar la implementación de la aplicación móvil y web. Esta tesis fue considerada por dos razones, la primera es porque se trabajó con una metodología ágil aplicada en un sistema web, y la segunda es la relación que tiene con nuestro cuarto objetivo específico, ya que el autor aplicó una encuesta para poder determinar la satisfacción y por ende la aceptación de su propuesta tecnológica.

Marco teórico

Inteligencia artificial

El desarrollo de las grandes empresas tecnológicas a acelerado un proceso que tendrá un gran impacto en las vidas de las personas. Las máquinas tienen más capacidad que lo humanos para reconocer patrones, algo que será muy útil en el diagnóstico de las enfermedades. La creciente aplicación de la IA en la salud ha propenso un gran interés de investigación en las últimas décadas. Actualmente, se habla bastante de la disciplina de IA, pero muy pocos saben

qué realmente abarca. Para Palma y Marín [18] la disciplina en mención, se relaciona con el análisis y el diseño sistemas autónomos capaces de desenvolver un comportamiento inteligente. Para que un agente actúe inteligentemente éste debe primero percibir su entorno, posteriormente procesar lo percibido para poder elegir cómo actuar, en base a algún principio de racionalidad, y como consecuencia cumplir con la realización de un determinado objetivo. Los autores en mención destacan que este tipo de agentes también pueden interactuar con otros agentes o sistemas, ya sean estos humanos o artificiales.

La IA con la computación convencional, guardan mucha relación, ya que pueden realizar lo mismo, si se consideran los principios básicos de IA, los cuales son: el modelar formalizar, programar e implementar sistemas que interactúen con su entorno de manera no trivial. Pero la gran diferencia radica en que para que algo sea computable la información que se recibe debe ser clara, completa, precisa e inequívoca, cosa que no sucede con IA, ya que la información que muchas veces se recibe es incompleta, poco clara, poco precisa y con alto grado de dudas. Tenemos por ejemplo algunos factores que sí considera IA: la percepción, el razonamiento creativo, la comprensión, entre muchas otras. Para esta investigación se tendrá en cuenta el factor de la percepción al analizar las imágenes.

Sistemas inteligentes

La presente investigación tiene como producto final la elaboración de sistema inteligente para el apoyo de la identificación de dermatofitosis a través de la percepción que se tengan sobre las características de las imágenes, simulando la revisión visual que realiza el especialista de dermatología como parte de la fase de anamnesis; de esta manera se pone en práctica lo descrito por Obregón y Fragala [19] quienes manifiestan que un SI es el producto de las investigaciones de IA con otras ramas de la ingeniería de la computación y estas se interrelacionan con otras disciplinas profesionales, es decir, un agente que posee la capacidad de imitar el comportamiento humano. En el ámbito de la medicina los sistemas inteligentes son aplicados como asistentes para el diagnóstico de enfermedades. Ahora la pregunta que resalta es ¿cómo estos sistemas son capaces de realizar lo mencionado anteriormente? Se sabe que los sistemas inteligentes realizan búsquedas y optimizaciones junto con capacidades de aprendizaje. Al existir diferentes categorías de sistemas inteligentes (ver fig. 1) Hopgood, A. [20] manifiesta que también existen diferentes tipos de aprendizaje destacando de entre ellos el aprendizaje automático, el cual puede ser un aprendizaje supervisado, no supervisado y de refuerzo. La elección del tipo de aprendizaje se modela en el diseño del SI y va a depender directamente de la solución que se abarque. Hopgood recalca que los sistemas inteligentes también realizan tareas complejas automatizadas que no son posibles por el paradigma informático tradicional. Los sistemas expertos, los agentes inteligentes y los sistemas basados en el conocimiento son ejemplos de sistemas inteligentes como a continuación se detalla.

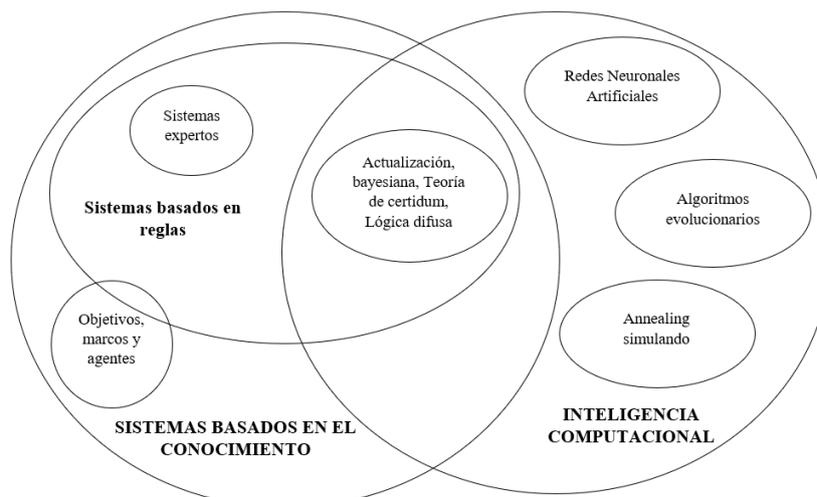


Fig. 1. Categorías de SI de Hopgood [20]

Machine Learning

La identificación visual de las características de dermatofitosis es una toma de decisión que se realiza bajo la subjetividad del especialista e involucra cierto grado de incertidumbre, por ello es de mucha importancia que se aplique un conjunto de métodos que pueden detectar automáticamente patrones en los datos y luego se use los patrones descubiertos para predecir nuevos datos y concretar mejores decisiones. A este conjunto de métodos Murphy [21] asocia al aprendizaje automático o machine learning (ML) que forma parte del inmenso mundo de IA. El autor en mención propone que para resolver estos problemas de predicción se relacione ML con la teoría de probabilidad específicamente con el campo de la estadística.

Para la aplicación de ML es importante la elección del algoritmo que mejor se acople con el objetivo que se busca alcanzar, para ello Bishop [22] recalca la importancia de esta elección en su libro “Pattern Recognition and Machine Learning”, en el cual también sintetiza el funcionamiento de ML indicando que el resultado de ejecutar el algoritmo de aprendizaje automático puede expresarse como una función $y(x)$ que toma una nueva imagen de dígito x como entrada y que genera un vector de salida y , codificado de la misma manera que los vectores objetivo. La forma precisa de la función $y(x)$ se determina durante la fase de entrenamiento, también conocida como la fase de aprendizaje, sobre la base de los datos de entrenamiento. Una vez entrenado el modelo, este puede determinar la identidad de nuevas imágenes de dígitos (conjunto de prueba). La capacidad de categorizar correctamente nuevos ejemplos que difieren de los utilizados para el entrenamiento se conoce como generalización. En aplicaciones prácticas, la variabilidad de los vectores de entrada será tan evidente que los datos de entrenamiento pueden comprender solo una pequeña fracción de todos los posibles vectores de entrada, por lo que la generalización es un objetivo central en el reconocimiento de patrones.

Deep Learning

Es necesario resaltar que para reconocer patrones en imágenes se tiene que aplicar técnicas de Deep Learning (DL) enfocadas en la clasificación de imágenes, pero para poder profundizar en esas técnicas es necesario el conocer en qué consiste ML. En efecto tenemos que el aprendizaje profundo o DL es un subcampo del aprendizaje automático relacionado con algoritmos inspirados en la estructura y función del cerebro llamadas redes neuronales artificiales (RNA). Y sus aplicaciones, según el artículo A Fast Learning Algorithm for Deep

Belief Nets descrito por Hinton *et. al.* [23], son más comunes de lo que hoy en día se conoce. El aprendizaje profundo está recibiendo mucha atención últimamente y por una buena razón; se está logrando resultados que antes no eran posibles con los algoritmos tradicionales de computación.

En DL, un modelo de computadora aprende a realizar tareas de clasificación directamente a partir de texto, sonido o imágenes. Los modelos de DL pueden lograr una precisión de vanguardia, que a veces supera el rendimiento a nivel humano. Los modelos se entrenan utilizando un gran conjunto de datos etiquetados y arquitecturas de redes neuronales que pueden contener entre dos o más capas [20].

Red neuronal artificial

Parte fundamental del SI de esta propuesta es el poder analizar las características visuales de las imágenes de las anomalías de los pacientes, es decir, tener un razonamiento como lo tendría un dermatólogo, para tal propósito se elaborará una red neuronal artificial (RNA) la cuál recibe este nombre porque está inspirado en el modelo de procesamiento de información que realiza el cerebro humano. La red de neuronas está conformada por más de una neurona las cuales trabajan de manera conjunta para resolver un problema en particular. Desde 1943 las redes neuronales se basan en el modelo matemático propuesto por McCulloch y Pitts [24] en el cual se describe que cada neurona tiene como input a conjunto de datos y una única salida. Adicionalmente, al igual que el cerebro humano que posee conexiones interneuronales con diferentes intensidades, en una RNA también se simula esta conexión y la intensidad viene dada por los pesos sinápticos. La RNA emula el funcionamiento del cerebro humano poniendo en práctica modelos matemáticos. A continuación, se muestra la figura del modelo neuronal donde se aprecia que cada entrada se ve afectada por un peso sináptico.

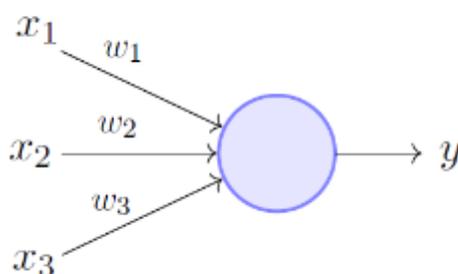


Fig. 2. Modelo matemático de McCulloch y Pitts [24]

Dermatofitosis

La dermatofitosis es una anomalía epidérmica, también conocida como tiña o tinea, que es causada principalmente por infecciones bacterianas, hongos de tipo dermatofitos (hongos queratinofílicos). Estos perjudican a prácticamente a todo el cuerpo ya que se manifiestan en zonas donde la queratina esté presente: piel, uñas y pelo [2]. Cuando la dermatofitosis afecta a la dermis, esta cambia de aspecto en comparación a la piel sana, afectando la estética de quien la padece. Entre variaciones en la piel pueden presentar en primera instancia manchas, pápulas, pústulas y urticaria. Ya cuando se tiene de dos a cinco días estas presencias cambian y suelen aparecer costras, hendiduras, fisuras, laceraciones, caspa y ulcera. A esto se le acompaña picor, comezón y dolor [25].

Diagnóstico dermatológico

En la investigación realizada por Díaz *et. al* [26] nos detalla que el diagnóstico de una enfermedad de la piel es una tarea fundamental que todo médico debe saber realizar, ya que de esta depende el tratamiento que se aplicará a dicha enfermedad. No es una tarea fácil ya que involucra el saber comunicar lo que se ha analizado y el detallar el cómo se llevará a cabo. Para que un diagnóstico sea aceptado como válido es necesario que este tenga como base a datos seguros, de lo contrario los resultados serán erróneos porque el razonamiento no se está tomando sobre hechos precisos o nociones exactas. Es por ello que Jameson, Larry *et. al* [27] manifiesta que la calidad de las observaciones que se empleen en una deducción, va a ser el punto clave para determinar la validez de esta.

Especificidad

Es común que cuando se hace referencia a un diagnóstico de carácter clínico, describan a la especificidad como un factor relacionado directamente con la fiabilidad del mismo. Para conocer de manera concreta lo significa especificidad, se ha tomado como referencia a lo descrito por Salech *et. al.* [28] quienes manifiestan que la especificidad de un diagnóstico es el porcentaje de personas que no tienen una condición determinada que son identificadas por el ensayo como negativas para la condición, es decir, se divide todos los pacientes evaluados cuyo resultado es verdaderamente negativo (verdadero negativo) y la suma de este mismo valor de verdaderos negativos con el número de evaluaciones en los que su resultado fue positivo, sin embargo, este resultado era erróneo (falso positivo). La fórmula para determinar el porcentaje de especificidad es el siguiente:

$$Especificidad = \frac{VN}{VN + FP} \times 100$$

En donde: VN (Verdaderos Negativos) y FP (Falsos Positivos).

Sensibilidad

Para que se confirme la fiabilidad de cualquier instrumento o método empleado para realizar un diagnóstico y, por ende, hallar la bondad del mismo, es importante tener en consideración el grado de sensibilidad de los resultados que este brinde. La sensibilidad según Sánchez [29] es la razón de todos los pacientes evaluados cuyo resultado es verdaderamente positivo (verdadero positivo) y la suma de este mismo valor de verdaderos positivos con el número de evaluaciones en los que su resultado fue negativo, sin embargo, este resultado fue erróneo (falso negativo). Sintetizando, la sensibilidad de un test es la probabilidad de que un paciente presente una anomalía tras un resultado positivo. La fórmula para determinar el porcentaje de sensibilidad es el siguiente:

$$Sensibilidad = \frac{VP}{VP + FN} \times 100$$

En donde: VP (Verdaderos Positivos) y FN (Falsos Negativos).

Tanto la especificidad como la sensibilidad son considerados como parámetros para determinar la bondad de una prueba diagnóstica, es por ello que el doctor en ciencias médicas, Vizcaíno [30] analiza la importancia del cálculo de estos dos indicadores y propone una escala para poder determinar el nivel en el que se encuentran los resultados de los mismos. A continuación, se presenta una tabla adaptada en base a lo mencionado por Vizcaíno.

TABLA I CLASIFICACIÓN DE SENSIBILIDAD Y ESPECIFICIDAD

Clasificación	Descripción
Excelente	Mayor o igual al 95%
Buena	Entre 80% y 94%
Regular	Entre 50% y 79%
Mala	Menor del 50%

Materiales y métodos

A continuación, se describe el plan metodológico que se utilizó para realizar el estudio, con los que se han obtenido datos válidos y confiables.

Se realizó la investigación del tipo desarrollo tecnológico porque según Cegarra [31] este tipo de investigación tiene como fin el elaborar un artefacto que pueda ser ofrecido en el mercado por los beneficios que ofrece.

Los métodos de investigación empleados son los siguientes:

TABLA II MÉTODOS DE INVESTIGACIÓN

Método	Descripción
Inductivo	Estrategia para el planteamiento de la propuesta de solución al problema
Implementación	Se pondrá en ejecución la propuesta de solución
Testeo	Validar y verificar la propuesta de solución

En la tabla a continuación se muestran las técnicas e instrumentos que emplearán en la recolección de datos.

TABLA III TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS

Técnicas	Instrumentos	Elementos de la población	Propósito
Entrevista	Guía de entrevista (Anexos 09 y 10)	Dermatólogos, secretaria	Conocer: las enfermedades a tratar, como se realiza el proceso del diagnóstico, las enfermedades más frecuentes.
Encuesta	Cuestionario (Anexo 08)	Administrador y dermatólogos	Para obtener el nivel de aceptabilidad del sistema inteligente

Por una parte, para llevar a cabo el software de esta investigación se ha considerado la metodología Extreme Programming (XP) compuesta por las siguientes fases: planificación, diseño, desarrollo y pruebas. Por otra parte, para elaborar el modelo de machine learning se consideró las etapas propuestas por Chollet [32]: definir el objetivo, recolección de la data, modelamiento, entrenar el modelamiento, validar el modelo, predicción e interpretación de resultados.

Los aspectos éticos que se han considerado para la protección y bienestar de los participantes de esta investigación, así como de la seguridad (resguardo) de los datos que son ingresados a SisDerma (sistema producto de esta investigación). En primer lugar, se ha considerado el anti plagio, debido a que el texto de la presente investigación es producto de la redacción del investigador a cargo; la información obtenida de libros, artículos y otras fuentes de información han sido planteadas bajo la técnica de parafraseo y citadas en IEEE, como se aprecia la lista de referencias. En segundo lugar, se ha considerado la privacidad, ya que, en la aplicación de técnicas de recolección de datos, para este caso las entrevistas, que se han realizado para conocer la problemática de la presente investigación y tuvieron la autorización de los miembros de la organización para ser utilizadas con fines académicos. En tercera instancia se ha considerado a la confidencialidad de la información de los pacientes que se registren en SisDerma, ya que solo será accedida por aquellos usuarios que cuenten con los permisos correspondiente, manteniendo la seguridad de la información. Por último, se ha considerado a

la integridad de la información brindada por los colaboradores del centro dermatológico de estudio tendrá una divulgación académica, la misma que no ha sido alterada para el beneficio propio. En cuanto los datos registrados en SisDerma, estos se mantendrán íntegros debido a que el sistema no permite la modificación de datos a usuarios no autorizados.

A continuación, se muestra la matriz de consistencia

TABLA IV MATRIZ DE CONSISTENCIA

<u>FORMULACIÓN DEL PROBLEMA</u>		<u>MÉTODO DE INVESTIGACIÓN</u>		
El proceso de identificación de dermatofitosis genera una gran demanda de la capacidad visual por parte de los expertos dermatólogos, por lo que existen resultados equívocos.		<u>TIPO DE INVESTIGACIÓN</u> Desarrollo tecnológico		
<u>OBJETIVO GENERAL</u>	<u>MÉTODO</u>	<u>DESCRIPCIÓN</u>		
Desarrollar un sistema inteligente para la identificación de dermatofitosis en pacientes de un centro dermatológico de la ciudad de Chiclayo	Inductivo	Estrategia para el planteamiento de la propuesta de solución al problema		
	Implementación	Se pondrá en ejecución la propuesta de solución		
	Testeo	Validar y verificar la propuesta de solución		
	<u>TÉCNICAS</u>	<u>INSTRUMENTOS</u>	<u>ELEMENTOS DE LA POBLACIÓN</u>	<u>PROPÓSITO</u>
	Entrevista	Guía de entrevista (Anexos 09 y 10)	Dermatólogos, secretaria	Conocer: las enfermedades a tratar, como se realiza el proceso del diagnóstico, las enfermedades más frecuentes.
	Encuesta	Formato de encuesta (Anexo 08)	Administrador y dermatólogos	Para obtener el nivel de aceptabilidad del sistema inteligente
<u>OBJETIVOS ESPECÍFICOS</u>	<u>DESCRIPCIÓN DEL LOGRO DE LOS OBJETIVOS ESPECÍFICOS</u>	<u>INDICADORES</u>		
OE 1: Identificar el algoritmo idóneo de la red neuronal artificial para el análisis de las imágenes.	Evaluar los principales tipos de RNA que se aplique para el análisis de imágenes.	Para OE 1: -Tiempo promedio de desarrollo -Grado de reusabilidad -Grado de interoperación		
OE 2: Alcanzar un alto grado de especificidad del sistema inteligente para evidenciar la confiabilidad del mismo.	Tener una alta probabilidad del grado de especificidad significa que un paciente sufra realmente de dermatofitosis tras un resultado negativo.	Para OE 2: -Probabilidad de verdaderos negativos. -Probabilidad de falsos positivos. -Porcentaje de que un paciente sufra realmente de dermatofitosis tras un resultado negativo = $100 \times \# \text{ verdaderos negativos} / (\# \text{ verdaderos negativos} + \# \text{ falsos positivos})$.		
OE 3: Alcanzar un alto grado de sensibilidad del sistema inteligente para evidenciar la confiabilidad del mismo.	Tener una alta probabilidad del grado de sensibilidad significa que un paciente sufra realmente de dermatofitosis tras un resultado positivo.	Para OE 3: -Probabilidad de verdaderos positivos. -Probabilidad de falsos negativos. -Porcentaje de que un paciente esté realmente enfermo de dermatofitosis tras un resultado positivo = $100 \times \# \text{ verdaderos positivos} / (\# \text{ verdaderos positivos} + \# \text{ falsos negativos})$		
OE 4: Obtener de los usuarios una alta puntuación de aceptación para la utilidad y usabilidad del sistema inteligente.	Estudiar la respuesta de los usuarios frente a la tecnología implementada considerando el modelo TAM	Para OE 4: -Nivel de utilidad percibida del sistema -Nivel de facilidad del uso percibida del sistema		

Resultados y discusión

Planificación

Al emplear la metodología XP, las primeras actividades en el proceso de desarrollo del sistema, es tener comunicación directa con el cliente y comenzar a definir una serie de historias de usuarios (similares a los casos de uso), para describir la funcionalidad del software que se va a construir.

Definir historias de usuarios

En base a los requerimientos ya definidos se procede a elaborar las historias de usuarios, los cuales tienen como fin establecer las funcionalidades a detalle del sistema informático. Las prioridades asignadas son acordes al criterio que las historias de usuarios tienen en el desarrollo del sistema. En tal sentido tenemos que para el criterio de indispensable se le ha asignado una prioridad de 10, para el criterio de esencial una prioridad de 9, para el criterio de obligatorio una prioridad de 8, para necesario una prioridad de 6 y por último para el criterio de conveniente se asignó una prioridad de 4.

Se llegaron a identificar catorce historias de usuarios y en la siguiente tabla se puede apreciar la prioridad asignada a cada una de ellas.

TABLA V HISTORIAS DE USUARIOS

ID	Descripción	Prioridad
HU-01	Registro de usuarios	10
HU-02	Validar usuario	10
HU-03	Cerrar sesión	10
HU-04	Cargar imagen	10
HU-05	Previsualización de imagen	10
HU-06	Registrar tratamiento	10
HU-07	Gestionar administrador (Insertar, listar, modificar, eliminar)	9
HU-08	Gestionar paciente (Insertar, listar, modificar, eliminar)	9
HU-09	Gestionar dermatólogo (Insertar, listar, modificar, eliminar)	9
HU-10	Gestionar imagen (Insertar, listar, modificar, eliminar)	9
HU-11	Ver estado de usuarios	8
HU-12	Cambiar estado usuario	8
HU-13	Ver proceso evolutivo	6
HU-14	Reporte estadístico	4

Diseño

Con la finalidad de mantener una coherencia en cada uno de los elementos que serán empleados en el sistema, la metodología en uso propone realizar tarjetas CRC (Class, Responsibilities and Collaboration), así mismo el tener en cuenta la arquitectura del sistema y sintetizar toda la información de los entes en el diseño de la base de datos.

Definir tarjetas CRC

Las tarjetas consideradas en este apartado corresponden a cada una de las historias de usuarios ya definidas.

TABLA VI TARJETAS CRC

ID	Descripción
TCRC-01	Registro de usuarios
TCRC -02	Validar usuario
TCRC -03	Cerrar sesión
TCRC -04	El paciente pueda Cargar imagen
TCRC -05	Previsualización de imagen
TCRC -06	Registrar tratamiento
TCRC -07	Gestionar administrador
TCRC -08	Gestionar paciente
TCRC -09	Gestionar dermatólogo
TCRC -10	Gestionar imagen
TCRC -11	Ver estado de usuarios
TCRC -12	Cambiar estado usuario
TCRC -13	Ver proceso evolutivo
TCRC -14	Reporte estadístico

Arquitectura del sistema

La arquitectura que se consideró en la implementación del producto acreditable es la siguiente.

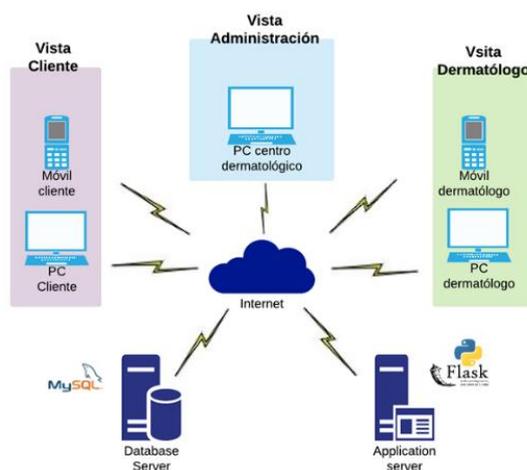


Fig. 3. Arquitectura lógica del SI

- ✓ **Servidor de base de datos:** es donde se encontrará alojada la información de los pacientes.
- ✓ **Internet:** medio por el cual se podrá acceder a los servidores.
- ✓ **Servidor de aplicaciones:** lugar donde se encontrará alojado la aplicación del SI.
- ✓ **PC / Móvil Dermatólogo:** dispositivo por el cual el especialista va a poder visualizar los resultados brindados por el SI, fuera del centro dermatológico.
- ✓ **PC centro dermatológico:** dispositivo por el cual el especialista, cuando se encuentre en el centro dermatológico, visualizará los resultados brindados por el SI.
- ✓ **PC / Móvil Paciente:** dispositivo que va a permitir que el paciente suba la imagen de la anomalía que presenta.

Desarrollo

En el *Anexo N° 07* se detalla la distribución de cada historia de usuario de acuerdo a las iteraciones consideradas en el desarrollo de esta investigación.

Por cada historia de usuario se elaboró su correspondiente tarjeta CRC y las interfaces relacionadas con la misma. A continuación, se demuestra lo mencionado con la HU-04 Cargar imagen.

HU-04 Cargar imagen: esta historia de usuario comprende la validación del tipo de imágenes que el paciente, dermatólogo o administrado cargue al sistema, posterior a ello, la imagen será procesada en el servidor y por ende ser almacenada junto a su predicción para que luego el dermatólogo confirme el valor.

TABLA VII HU-04: CARGAR IMAGEN

HISTORIA DE USUARIO	
Número: 4	Usuario: Todos
Nombre historia: Cargar imagen	
Prioridad en negocio: Baja	Riesgo en desarrollo: Media
Puntos estimados: 5	Iteración asignada: 2
Programador responsable: Jheiner Reaño Coveñas	
Descripción: Se busca validar el tipo de archivo que el usuario cargue para que el sistema puede predecirlo	
Observaciones: Cuando se elija un formato inválido el sistema mandará una alerta	

Para esta historia de usuario corresponde la siguiente tarjeta CRC

TABLA VIII TCRC-04: CARGAR IMAGEN

Cargar imagen	
Responsabilidades	Colaboradores
Validar tipo de archivo	Ninguno
Predecir imagen	
Observaciones: El sistema cuando detecte un formato inválido dará aviso del mismo	

Las interfaces relacionadas con esta historia de usuario serán presentadas en la etapa 7: Interpretación del modelo, de la metodología general de machine learning (figuras 8,9,10).

Pruebas

Pruebas de caja negra

Durante esta etapa se han realizado cinco pruebas de este tipo a las siguientes funcionalidades del sistema: gestionar administrador, gestionar dermatólogo, gestionar paciente, gestionar tratamiento y gestionar imagen, el desarrollo de esta última prueba de caja negra se muestra en el *Anexo N° 01*.

Pruebas de caja blanca

Las funcionalidades de SisDerma con pruebas más a fondo son las siguientes: predecir imagen, validar usuario, validar campos, crear usuario, insertar dermatólogo y cambiar estado de usuario. *Anexo N° 02*, se muestra el desarrollo del caso de predecir imagen.

Etapas para la construcción del modelo de machine learning

Etapa 1: Definir el objetivo

Se definió el problema al que se afrontará el modelo de machine learning. Por ende, se planteó obtener una alta probabilidad de exactitud del modelo para que los resultados predigan correctamente la ausencia o presencia de la enfermedad. Se planteó alcanzar una

probabilidad de precisión mayor o igual a 70% y que el tiempo promedio de respuesta sea menor o igual a cinco minutos. Para lograr este objetivo se requiere que el tipo de aprendizaje del algoritmo del modelo sea del tipo supervisado y que admita como tipo de dato de entrada a una imagen, para que de esta manera el algoritmo que se seleccionará la etapa 4: entrenar el modelo, se encuentre alineado con el problema que se está tratando.

Etapa 2: Recolección de la data

En esta etapa se definió las fuentes de datos: Universidad de Iowa clasificadas [33], Dermnet [34], Dermnetz [35], Kaggle [36] y OpenI [37]. Se llegaron a estas fuentes gracias a la plataforma online Kaggle que realiza competiciones de Data Mining. En primera instancia se llegó a recolectar 538 imágenes, pero al aplicar el protocolo de evaluación Simple hold out validation [32] para el entrenamiento del modelo, los resultados no fueron favorables y se decidió conseguir más imágenes llegando a un total de 1430 con los cuáles se obtuvieron mejores resultados que más adelante se detallarán.

Etapa 3: Modelamiento

Se estableció el protocolo de evaluación, para el entrenamiento se empleó el 80% de las imágenes, esto debido que se trabajó con un número considerable de las mismas (1430), cuando el número de muestras es limitado el porcentaje asignado para el entrenamiento debe ser menor. Para realizar la prueba del modelo Baheti *et. al.* [38] en su artículo nos indica que es recomendable emplear el 10% de la data, sin embargo cuando los parámetros a configurar son varios la autora recomienda emplear un porcentaje mayor para optimizar el rendimiento del modelo, en este caso se tiene siete parámetros (tamaño de la imagen, escala de colores, filtro aplicado, tamaño del filtro, número de capas, batch_size y número de épocas) por lo que se consideró emplear el 15% de las imágenes como conjunto de prueba. El 5% restante se empleó para la validación del modelo.

La preparación de la data consistió en agrupar las imágenes en tres carpetas nombradas como “train”, “test”, “val” referentes a entrenamiento, prueba y validación respectivamente. Cabe mencionar que en cada una de estas carpetas existían dos subcarpetas denominadas “DERMATOFITOSIS” y “NORMAL”, la primera hace referencia a todas las imágenes recolectadas de la enfermedad tratada en esta investigación y en la segunda, a todas las imágenes en donde existe la ausencia de la enfermedad.

En esta actividad se desarrolló el preprocesamiento de las imágenes que ingresarán al modelo. Para ello se generó una función que recorrió la carpeta donde se encontraban las imágenes para el entrenamiento y se empezaron a “leer” cada una de ellas gracias a la librería de visión artificial y aprendizaje automático y código abierto OpenCV [39]. Posteriormente, como las imágenes obtenidas en los diferentes data sets se encontraban en diferentes tamaños, se procedió a redimensionarlas, se le asignó una altura de 150 píxeles y un ancho de 150 píxeles, también se procuró que sigan manteniendo las tres capas de colores con las que ingresan a la función. Del mismo modo como cada imagen contenían píxeles cuyo rango se encontraban entre 0 y 255, se procuró estandarizar que cada imagen contenga píxeles cuyos valores se encuentren entre 0 y 1, esto con la intención de optimizar el tiempo de procesamiento de cada una de ellas en el modelo propuesto.

Etapa 4: Entrenar el modelo

En esta etapa se hizo uso del set de datos de entrenamiento para ejecutar nuestro modelo y se deberá analizar qué mejoras aplicar para la etapa 6 de predicción. En primer lugar, se aplicó el protocolo de evaluación, del total de imágenes recolectadas (1430) se procedió a aplicar los porcentajes correspondientes para determinar cuántas imágenes ingresarán al entrenamiento, cuántas servirán para probar el modelo y del mismo modo determinar cuántas nos va a servir para simular un escenario real.

TABLA IX APLICACIÓN DE PROTOCOLO DE EVALUACIÓN

	Entrenamiento (80%)	Prueba (15%)	Validación (5%)
Normal	572	107	36
Dermatofitosis	572	107	36

Una vez cerciorado la cantidad de las imágenes (572 para cada clase) que formarán parte del entrenamiento se procede a aplicar el algoritmo seleccionado.

Dentro de las primeras fases para poder desarrollar esta investigación, era necesario poder seleccionar un algoritmo adecuado basado en machine learning y para ello se ha comparado los principales algoritmos, en base a 5 criterios, de los cuales los tres primeros tienen como base los factores de calidad de software propuestos por McCall [40] y los dos restantes corresponden a las características propias del tipo de software que se está desarrollando. Los criterios son los siguientes: el tiempo promedio de implementación (C1), el grado de reusabilidad (C2), la interoperación para integrar el algoritmo a otros sistemas (C3), el tipo de aprendizaje debe ser supervisado (C4) y si el algoritmo permite en su capa inicial el ingreso de píxeles de una imagen (C5). A cada uno de estos criterios se le atribuye un peso (desde P1 hasta P5) como coeficiente. Estos pesos son en base a la prioridad que cada criterio tiene en este proyecto en comparación con los demás. En el *Anexo N° 03*, se muestra el listado de los criterios ordenados desde mayor a menor prioridad junto a sus coeficientes asignados. En el *Anexo N° 04*, se detalla la escala de valores empleada para obtener la puntuación de la comparación de los algoritmos.

En la siguiente tabla se aprecia la comparación de los siete principales algoritmos con su respectiva sumatoria de los productos de los puntajes obtenidos en cada criterio por el peso correspondiente.

TABLA X COMPARACIÓN DE ALGORITMOS

Algoritmos	Criterios					Total $\sum_{i=1}^5 C_i * P_i$
	C1	C2	C3	C4	C5	
	P1=0.2	P2=0.1	P3=0,1	P4=0.3	P5=0.3	
1.Regresión Lineal	1	2	3	3	1	1.9
2.Clustering K-Means	2	1	3	1	1	1.4
3.Bayesian Network	2	1	3	1	3	2
4.Kohonen's self-organizing maps	1	1	3	1	3	1.8
5.Convolutional Neural Networks	2	3	3	3	3	2.8
6.Hopfield Network	2	1	3	1	3	2
7.Long Short Term Memory Neural Networks	1	2	3	3	3	2.5

Como se puede apreciar el algoritmo que mayor puntaje obtuvo (2.8) fue Convolutional Neural Networks, con el cual se trabajó en este proyecto. Este tipo de red tiene como entrada los píxeles de una imagen, la cuál va a pasar por cada una de las capas que se implementen y en cada una de estas capas la imagen original recibe la aplicación de una máscara, el resultado de cada capa depende de la máscara, la cual

produce distintos resultados, como salida de la capa final se tienen a las clases que se desea evaluar, para este trabajo se consideraron dos clases “DERMATOFITOSIS” y “NORMAL”. Entre las aplicaciones de esta red tenemos: detección y/o categorización de objetos, clasificación de escenas y la clasificación de imágenes, esto es gracias al aprendizaje supervisado que tiene esta red neuronal [41].

Una vez definido el algoritmo de tipo convolucional que tendrá nuestro modelo, se optó con trabajar con la librería Keras, la cual se puede describir como un facilitador para plantear soluciones a problemas relacionados con el aprendizaje profundo y manipulación de modelos de redes neuronales convolucionales, cabe mencionar que esta librería está escrita en lenguaje de programación Python el cual ha sido el lenguaje base para la construcción del modelo. A su vez, se importó la librería de Tensorflow que es una de la más importantes en cuanto a aprendizaje profundo (deep learning) se refiere [42]. El modelo empezó declarándose con la clase Sequential, la cual agrupó en una pila lineal las capas iniciales de nuestro modelo. Con el método add se adicionaron las capas quienes invocaron a las redes convolucionales de Keras que ya están incluidas en Tensorflow (Conv2D) y se ajustó a lo que estamos buscando, pasándole ciertos parámetros, en este caso se aplicó un filtro de 64, con un tamaño de 3 x 3. También se incluyó la función de activación relu, la cuál es aplicada cuando se tiene trato de imágenes como es nuestro caso. Y por último se le adicionó la forma que espera nuestro modelo, como vimos en el pre procesado de imágenes redimensionaron las mismas a un tamaño de 150 x 150, pues esta misma forma debe ser nuestro dato de entrada, adicionándole la dimensión de los tres colores.

Luego de recorrer la imagen de entrada, se procede a aplicar otro recorrido al mapa de características que resulte de la capa anterior, pero en este caso aplicando la técnica de Max Pooling con el método MaxPooling2D, para este caso se especificó una tupla con las dimensiones de 2 x 2, con la cual se extraerán las características principales de todo el recorrido. Logrando de esta manera tener nuestro primer paso de convolución pooling. Ahora como lo que intenta con este modelo es que se puedan diferenciar las características que contengan las imágenes y poder determinar a partir de ello si se tiene o no Dermatitis, se ha planteado agregar dos pasos de convolución pooling, similares con el mencionado anteriormente, con la diferencia de que ya no se le indica el tamaño de entrada, ya que estas capas estarían recibiendo los resultados del primer paso de convolución pooling. Posteriormente se agregó solo una capa de convolución (sin max pooling) y se procedió a aplicar el método Flatten con la intención de “aplanar”, es decir, obtener solo una fila de todos los píxeles que nos arroje el paso de convolución pooling número tres, quedando de esta manera preparado para ser la entrada de una red neuronal tradicional densamente conectada.

Finalmente, ya se declaró una capa de salida con solo dos neuronas, las cuales indicarán las probabilidades de que una persona tenga o no la anomalía en su piel y para lograr ellos se aplicó en esta capa la función de activación softmax. Todo lo anteriormente mencionado es la estructura que tendrá nuestro modelo, para una mayor comprensión visual se tomó como referencia la estructura descrita por Maher [43] con la diferencia de que a lo que él llama por separado capa de convolución y capa de pooling, en este informe se describen a ambas capas como paso de convolución pooling, pero la funcionalidad sigue siendo la misma. Cabe mencionar también que el total de neuronas densamente conectadas en la penúltima capa será de 64.

Luego una vez que se tenga definida la estructura de nuestro modelo, se procede a compilarlos. Para ello se hizo uso del optimizador de aprendizaje Adam; como función de pérdida se ha empleado `sparse_categorical_crossentropy` ya que las etiquetas correspondientes a cada una de las imágenes se encuentran en un array plano de ceros y unos donde cero corresponde a la etiqueta `NORMAL` y uno a la etiqueta `DERMATOFITOSIS`. En cuanto a las métricas empleadas se ha considerado la precisión. En esta tarea también se guardarán los logs que se generen en cada una de las épocas, esto con la intención que en la tarea de revisión de resultados se pueda graficar gracias a la herramienta de visualización de TensorBoard el comportamiento de nuestro entrenamiento por época. Ya como último proceso de esta activa se tiene propiamente el entrenamiento del modelo, donde se envía como parámetro el set de entrenamiento ya transformado en etapas anteriores, seguido del set de etiquetas. También se le incorporó un `batch_size` equivalente a 32 (en un inicio se probó con 100 pero los resultados no fueron favorables), esto quiere decir que nuestra red aprenderá de las imágenes de muestra en grupos de 32 en 32, así hasta agotar todas las muestras. Aquí también se definen las épocas que el modelo entrenará, esta hipervariable en un inicio fue de 10, pero se pudo apreciar de que la precisión iba creciendo cada vez más y se optó por duplicarlas y dejar un valor de 20 épocas. De esta variable depende que tanto demore o no el entrenamiento de tu modelo. Para este caso se empleó el recurso de la GPU proporcionada por Google Colab, para que este proceso de entrenamiento sea menor en la medida que se pueda.

Una vez que el modelo termine de entrenar, se procedió a revisar los resultados obtenidos, visualizando el comportamiento del mismo gracias a los logs guardados en la etapa anterior y que pueden ser graficados gracias a TensorBoard. Cabe mencionar que se empleó el método de aprendizaje supervisado activo [44] en el cual el algoritmo inspecciona un conjunto de imágenes sin etiquetar, y los clasifica según cuánto podrían mejorar el rendimiento del algoritmo si estuvieran etiquetados. Posteriormente, el especialista etiqueta los ejemplos de más alto rango, los cuales se añaden al conjunto de data de entrenamiento a partir de los cuales el algoritmo infiere su modelo de clasificación, y el bucle comienza de nuevo hasta que el porcentaje de los resultados tengan una precisión que sobrepase el 80%.

Primer escenario

En este escenario se hizo el entrenamiento con las 538 imágenes conseguidas inicialmente, como se aprecia la data de entrenamiento alcanzando su máxima precisión de 98.78% en la época 20. Mientras que la data de prueba alcanza su máxima precisión de 86.45% en la época 6. Esto indica que a partir de esta época ya no seguirá mejorando la precisión de la misma.

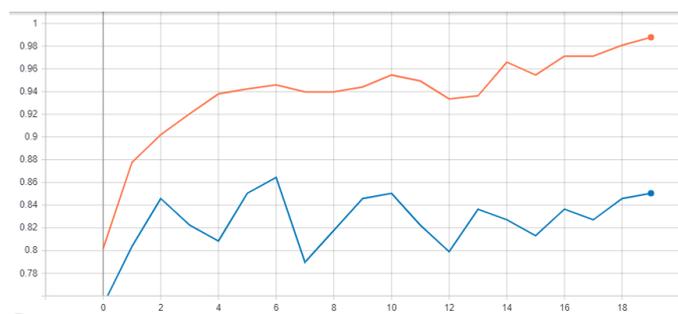


Fig. 4. Primer escenario: Precisión por época

En donde línea naranja representa la data de entrenamiento y la línea azul la data de validación.

De igual forma de este escenario se analizó su valor de pérdida, la cual es mejor cada vez que se aproxime a cero; la data de entrenamiento alcanzó una pérdida mínima de 0.04% en la época 20. Mientras que la data de validación alcanzó una pérdida mínima de 56.05% en la época 3. Esto nos indica que nuestro modelo se encuentra en un sobreajuste, ya que los valores de ambos grupos están yendo en direcciones contrarias.

Segundo escenario

En este segundo escenario se realizó el entrenamiento adicionando 892 imágenes a las conseguidas inicialmente, llegando a un total de 1430. Como se aprecia la data de entrenamiento alcanzando su máxima precisión de 87.5% en la época 20. Mientras que la data de validación alcanza su máxima precisión de 84.58% en la época 15. En promedio se obtuvo que la data de entrenamiento tuvo una precisión de 89.51% y en la data de prueba fue de 84.11%. Esto indica que el comportamiento de ambos grupos ha sido un aprendizaje, no óptimo, pero sí bueno, ya que sus gráficas están encaminadas por la misma ruta.

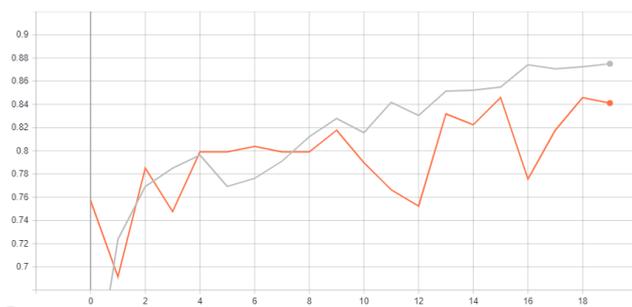


Fig. 5. Segundo escenario: Precisión por época

En donde línea naranja representa la data de entrenamiento y la línea ploma la data de validación.

Del mismo modo también se analizó de este escenario su valor de pérdida, donde la data de entrenamiento alcanzó una pérdida mínima de 26.32% en la época 20 y en esta misma época la data de validación alcanzó una pérdida mínima de 41.23%. Esto nos indica que nuestro modelo ya ha superado el sobre entrenamiento y es capaz de generalizar imágenes extras a las manipuladas en este entrenamiento.

Etapa 5: Validación del modelo

En esta etapa se considera como valores de entrada el set de datos de prueba.

En el *Anexo N° 05*, se muestra los resultados de la precisión obtenida en cada época para la data de validación del modelo.

A continuación, se desarrolló una función para recorrer la carpeta de validación y almacenar su etiqueta en forma binaria, como se ha venido trabajando anteriormente, “0” para ausencia de dermatofitosis y “1” cuando sí se presenta la enfermedad. Del mismo modo, se realizó una función que pueda predecir imágenes de manera grupal, de donde se sabría el valor predicho por el modelo gracias a la extensión de Python llamada Numpy, dando forma de vector a una simple lista; cabe mencionar que esta extensión posee un método (argmax) que permite obtener el máximo índice que contiene el máximo valor. Para este caso los resultados que arroja el modelo son justamente de este tipo y cuyo valor

en la posición cero, corresponde a la probabilidad de que la imagen no sea dermatofitosis, y la posición uno, de que sí lo sea. Por este motivo es que inicialmente se guardaron las etiquetas de forma binaria para cuando se proceda a realizar la comparación en la matriz de confusión, la función pueda comparar uno a uno las posiciones de los vectores que contienen los valores verídicos y los valores predichos por el modelo. La siguiente figura representa los valores que el sistema predijo para la data de prueba. Se introdujeron 214 imágenes (107 para cada tipo). A continuación, se aprecian los valores de verdaderos positivos y verdaderos negativos que arrojó el modelo. A su vez, se puede visualizar los falsos negativos y falsos positivos. Estos valores nos ayudarán a obtener el grado de sensibilidad y especificidad del sistema.

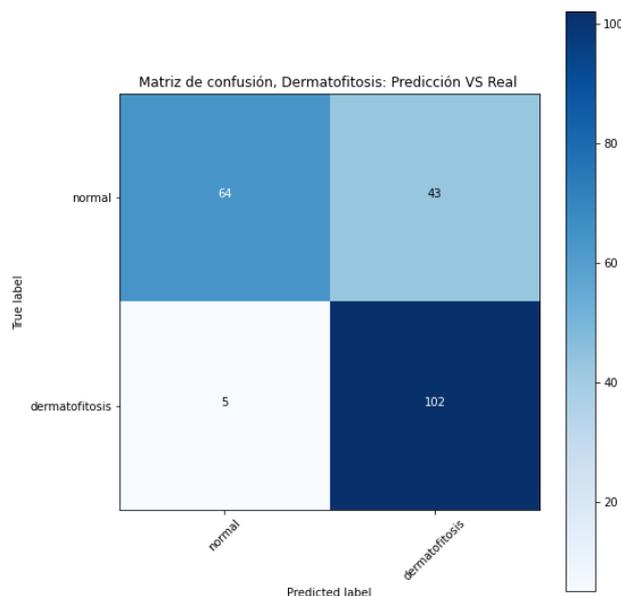


Fig. 6. Matriz de confusión: validación

Esta matriz nos indica que nuestro modelo alcanzó para las imágenes de validación una sensibilidad de 95.45%, una especificidad de 59.81% y una precisión de 77.88%

Luego se procedió a configurar los parámetros, quedando en los valores finales lo siguientes: el tamaño de la imagen fue de 150 x 150, la escala de colores fue de 3 RGB, el filtro aplicado fue de 64, el tamaño del filtro fue de 3 x 3, el número de capas fue de 9, el batch_size fue de 32 y el número de épocas de 20. Solucionando de esta manera el problema de overfitting que en términos simples Chollet [32] manifiesta que es el sobre entrenamiento de una red neuronal, es decir, cuando el modelo no puede generalizar predicciones para datos nuevos “memorizando” solo las imágenes con las que fue entrenado.

Etapa 6: Predicción

Se aplicó el algoritmo a la data de validación. Para este caso se contó con 72 imágenes las cuáles se utilizaron para simular un escenario real de predicción, este número de imágenes corresponden al 5% del total de imágenes que se llegaron a recolectar. A continuación, se muestra la matriz de confusión con los resultados obtenidos a partir de las 72 imágenes ingresadas al modelo simulando un escenario real.

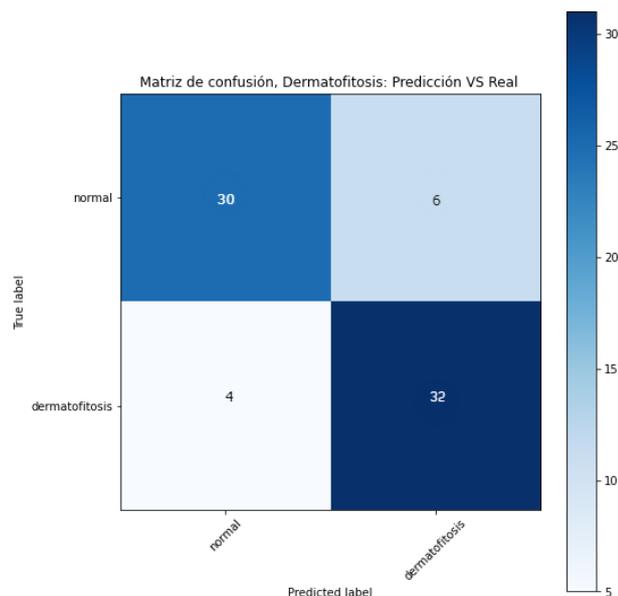


Fig. 7. Matriz de confusión: predicción

Esta matriz nos indica que nuestro modelo tuvo para las imágenes de prueba los siguientes valores:

$$\begin{aligned} \text{Especificidad} &= \frac{30}{30 + 6} \times 100 \\ &= 83.33\% \end{aligned}$$

$$\begin{aligned} \text{Sensibilidad} &= \frac{32}{32 + 4} \times 100 \\ &= 88.89\% \end{aligned}$$

Resultados que según el especialista Vizcaíno [30] pueden ser clasificados como buenos, alcanzando de esta manera el cumplimiento de los objetivos específicos 2 y 3 de esta investigación.

Como interpretación final de las matrices mostradas en las figuras 6 y 7, se puede afirmar que nuestro modelo tiene una mejor predicción para imágenes que sí tienen características de dermatofitosis ya que la sensibilidad promedio fue de 92.11%. En cuanto a la especificidad es considerada también como buena porque sobrepasa el 80% recomendado por la OPS. La precisión en el primer escenario fue de 77.57% y en el segundo, 86.11%.

Etapas 7: Interpretación del modelo

En esta última etapa se busca que los resultados del sistema inteligente sean comprendidos con facilidad integrándose de ser conveniente con otro sistema. Para este caso el desarrollado en el apartado de Metodología de software complementario: XP.

Se integró satisfactoriamente el modelo entrenado en Python con la plataforma web. El medio de comunicación fue a través de http utilizando el método POST. Cabe mencionar la aplicación de Python fue alojada en una máquina virtual que poseía el servidor de Ubuntu. La cuál recibe al form data que contiene un input de tipo file con el identificador de "foto". Gracias a este identificador la aplicación de Python sabe que valor tomar y poder procesar la imagen, para luego predecir si se trata de una imagen que contiene características de dermatofitosis o no. Lo que nos proporciona esta aplicación son los valores que serán guardados en el atributo de diagnóstico de la imagen en la base de datos; cabe mencionar que este valor es de pre diagnóstico, el dermatólogo tiene la opción de actualizar si así lo amerita. A continuación, se presenta una prueba de esta integración.

El usuario podrá seleccionar la imagen que desea que el sistema prediga para que el dermatólogo posteriormente asigne un tratamiento. Cabe mencionar que el sistema aceptará formatos digitales tales como: JPEG, JPG y PNG; y es el dermatólogo quien indicará a los pacientes que las imágenes que se suban al sistema deben ser a color.

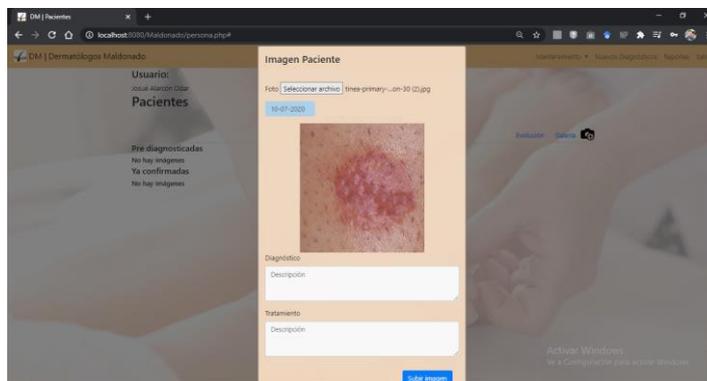


Fig. 8. Confirmar imagen

En este apartado el usuario se cerciorará si la imagen seleccionada es correcta, de ser así, se procede a subir la imagen al sistema.

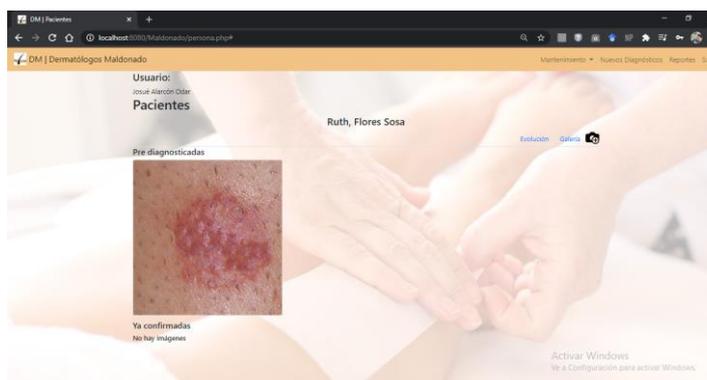


Fig. 9. Imagen pre diagnosticada

Esta imagen representa la vista de la galería del paciente, se pueden apreciar dos secciones de la misma. La primera es la sección de imágenes pre diagnosticadas, en la cual se mostrarán todas las imágenes que ya han sido diagnosticadas por SisDerma pero que aún no han sido confirmadas por el especialista. La segunda es la sección de imágenes ya confirmadas, en la cual se mostrarán todas las imágenes que el dermatólogo ya confirmó y se le asignó un tratamiento.

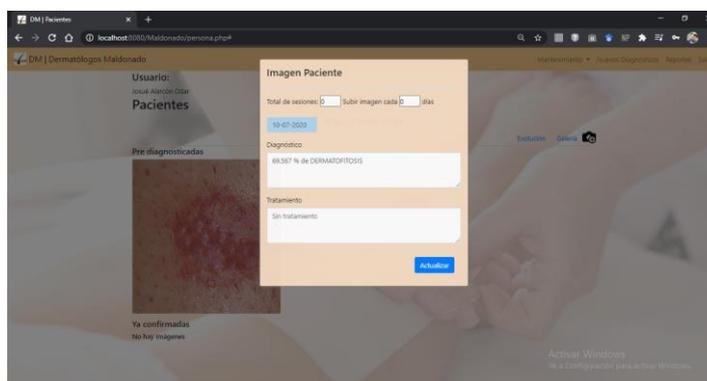


Fig. 10. Resultado de la predicción

Esta vista corresponde al dermatólogo cuando ya está revisando los resultados de SisDerma y está por asignar un tratamiento, el cuál incluirá el total de sesiones que abarcará y el periodo en días en que se llevarán a cabo cada sesión (intervalo de días).

Obtener de los usuarios una alta puntuación de aceptación para la utilidad y usabilidad del sistema inteligente

Con el propósito de validar el grado de aceptación de la solución de la presente investigación, se ha decidido aplicar el modelo de aceptación tecnológica (TAM) propuesto por Davis [45] con el cual se busca conocer las perspectivas de los dermatólogos en cuanto a la utilidad y facilidad de uso percibida del sistema inteligente propuesto. El instrumento de validación de especialistas empleado se muestra a detalle en el *Anexo N° 08*.

Para concretar el análisis de las seis primeras preguntas realizadas, vinculadas con el factor de utilidad y las seis preguntas siguientes con el factor usabilidad, se procedió a establecer un puntaje cuyo rango es de 1 a 7 a cada una de ellas. Calculando el promedio de del factor analizado, se obtuvo 6 como valor mínimo y 42 como valor máximo. En seguida se muestran los quintiles hallados, los mismos que tuvieron un intervalo de 7.2, junto a su valoración.

TABLA XI UTILIDAD Y USABILIDAD PERCIBIDA: VALORACIÓN

Quintil	Valoración utilidad	Valoración usabilidad
Q1	Nada útil	Muy difícil
Q2	Poco útil	Difícil
Q3	Indiferente	Indiferente
Q4	Bastante útil	Fácil
Q5	Muy útil	Muy fácil

Tras aplicar el instrumento de aceptación tecnológica a los especialistas del del centro de dermatológico en estudio, se obtuvo un puntaje promedio de 37 puntos para el factor utilidad, que representa un 88.10% del puntaje máximo que se pudo alcanzar, y 35 puntos para el factor usabilidad, que representa el 83.33% del puntaje máximo. Estos valores se encuentran en el quintil número 5 cuya valoración representa que el sistema es muy útil y fácil de usar según la perspectiva de los dermatólogos. Los valores obtenidos se resumen en el *Anexo N° 06*. En mérito de los resultados, se puede afirmar que se obtuvo de los usuarios una alta puntuación de aceptación para la utilidad y usabilidad del sistema inteligente.

Discusión

En la presente investigación con el fin de identificar el algoritmo idóneo de la red neuronal artificial para el análisis de las imágenes, los resultados tras realizar la comparativa de los principales algoritmos de redes neuronales se obtuvo un puntaje de 2.8, siendo este el más alto y le correspondió a la red neuronal convolucional; esto significa que es el algoritmo que mejor se ajusta a la problemática que se quiere afrontar. Este tipo de algoritmo fue empleado por Coronado [13] quien en su modelo realizó una clasificación de imágenes, pero que, a diferencia de esta investigación, este autor se apoyó de autocodificadores debido a los recursos con los que contaba. Analizando estos algoritmos empleados, se puede manifestar que el algoritmo de red neuronal convolucional es adecuado para tratar problemas en donde este de por medio la clasificación de imágenes, sobre todo en donde se necesite que el aprendizaje de la red

sea del tipo supervisado, y que esta puede ser apoyada de otras técnicas, tal como es el caso de Coronado.

Con respecto a alcanzar un alto grado de especificidad del sistema inteligente para evidenciar la confiabilidad del mismo, se presentaron los resultados obtenidos, tras realizar el entrenamiento de la red neuronal convolucional y evaluar las imágenes de predicción, 5% del total de imágenes analizadas, se obtuvo que la probabilidad de verdaderos negativos fue de 0.8333 y la probabilidad de falsos negativos fue de 0.1667. Estos valores contribuyeron a que el porcentaje de especificidad alcance un valor de 83.33%, por tal efecto este valor nos indica que de un total de 36 imágenes consideradas bajo la etiqueta de "normal" SisDerma logró predecir de manera acertada 30 de ellas; el porcentaje arrojado en estas imágenes indican que no tiene características de dermatofitosis, errando solo en 6 imágenes que las predijo como positivo a dermatofitosis. De manera similar el autor Domínguez [12] en su trabajo de investigación logró clasificar imágenes para identificar cáncer de la piel en base a las características de melanomas, para ello aplicó una máquina de soporte vectorial (SVM) con la que logró alcanzar una especificidad de 65.2%, al mismo tiempo este autor trabajó con árboles de decisiones con lo cual alcanzó una especificidad de 85.5%. Este autor empleó un aprendizaje supervisado, en el cuál fue aumentado el número de características e indicando a su modelo de machine learning para analizarlas y obtener los resultados acordes a su nivel de investigación; en nuestro caso también fue un aprendizaje supervisado, pero solo para etiquetar las imágenes ya sea como "dermatofitosis" o "normal". Recapitulando, como análisis reflexivo podemos manifestar que la capacidad para detectar la ausencia de una anomalía a partir del análisis de imágenes digitales con un modelo en cuyo aprendizaje influye la participación del especialista, los árboles de decisión pueden ser una buena opción, pero si lo que se busca es que la misma red aprenda de manera automática las todas características que las imágenes puedan presentar, las redes artificiales convolucionales, por los resultados han demostrado tener un alto grado de especificidad. Además, estas últimas optimizan el tiempo tanto del entrenamiento como el tiempo del especialista.

En relación con alcanzar un alto grado de sensibilidad del sistema inteligente para evidenciar la confiabilidad del mismo, se pudo encontrar que los resultados obtenidos tras realizar el entrenamiento de la red neuronal convolucional y evaluar las imágenes de predicción, 5% del total de imágenes analizadas, se obtuvo que la probabilidad de verdaderos positivos fue de 0.8889 y la probabilidad de falsos positivos fue de 0.1111. Estos valores contribuyeron a que el porcentaje de sensibilidad alcanzado sea de 88.89%; este último valor alcanzado nos indica que de un total de 36 imágenes consideradas bajo la etiqueta de "dermatofitosis" SisDerma logró predecir de manera acertada 32 imágenes, el porcentaje arrojado en estas indican que sí tiene características de dermatofitosis; errando solo en 4 imágenes que las predijo como negativo a dermatofitosis. De forma semejante tenemos los resultados presentados por la autora Gamboa [14], quien logró diagnosticar micosis superficiales de manera preliminar a partir de imágenes digitales, para lo cual también trabajó con una red neuronal convolucional y se realizó el entrenamiento con 900 imágenes. La sensibilidad alcanzada en esta investigación fue de 83.6244% tras analizar un total de 36 pacientes, de los cuáles 18 presentaban anomalías epidérmicas. A diferencia de nuestra investigación, con la que se contó con un total de 1143 imágenes solo para el entrenamiento y para nuestro escenario de predicción se decidió contar con 72 imágenes (redondeo del 5% del total) alcanzando con ello una precisión de 86.11%. El nivel de precisión se ve influenciado por otros factores, tal como

es el tamaño de la imagen redimensiona antes de ingresar al modelo y por ende la cantidad de píxeles que se analizarán. Para nuestro caso el redimensionamiento de la imagen fue a 150 x 150 píxeles; mientras que, para Vásquez [16], quien analizó imágenes dermatoscópicas, consideró adecuado trabajar con un redimensionamiento de 65 x 65 píxeles, gracias a lo cual pudo obtener una precisión de 96.1%. En virtud de los resultados podemos manifestar que, si se busca alcanzar una alta probabilidad de clasificar correctamente a un individuo enfermo a partir de imágenes digitales, las redes artificiales convolucionales son una buena opción; y mientras más imágenes sean introducidas en el entrenamiento y menor sea la cantidad de píxeles para analizar, mayor precisión se tendrá en los resultados, ya que el aprendizaje de este tipo de red es supervisado.

Con motivo de obtener de los usuarios una alta puntuación de aceptación para la utilidad y usabilidad del sistema inteligente se aplicó el modelo de aceptación tecnológica para conocer la percepción de los especialistas, a partir del cual, podemos evidenciar que cada uno de los puntajes obtenidos se ubican en el quintil más alto identificado correspondiente al factor analizado. En primer lugar, el puntaje obtenido para el factor de utilidad fue de 37 puntos, que representan el 88.10% del puntaje máximo (42). En segundo lugar, el puntaje correspondiente al factor de usabilidad fue de 35 puntos, que representan el 83.33% del puntaje máximo (42). Al encontrarse los valores hallados en el sector más alto de los quintiles identificados, se puede indicar que SisDerma logró alcanzar, referente al factor de utilidad, una calificación de "muy útil", es decir, los especialistas consideran que, con la puesta en marcha de este sistema, se optimizaría el proceso de identificar la anomalía de dermatofitosis y el seguimiento al tratamiento de la misma. También SisDerma logró alcanzar, referente al factor de usabilidad, una calificación de "muy fácil", con lo que se puede interpretar que para los especialistas es extremadamente probable el fácil aprendizaje y uso del sistema propuesto. Estos hallazgos se ven reforzados por lo descrito por Davis [44] quien afirma que con el modelo TAM se puede evaluar la satisfacción de los individuos frente a una propuesta de carácter tecnológica en base a dos factores: utilidad y usabilidad. Existen muchas formas de poder determinar la asimilación de una propuesta tecnológica, muestra de ello es la empleada por el autor Rodríguez [15] quien en su investigación logró que expertos aceptaran su propuesta a través del coeficiente de alfa de Cronbach, con lo que alcanzó un nivel de confiabilidad de "muy buena" con un puntaje de 0.841. Por su parte, Santos [17] a través del método Servqual, que posee 5 dimensiones (sensibilidad, fiabilidad, seguridad, empatía y elementos tangible) diferentes a las del modelo TAM (utilidad y usabilidad), concluyó que el 78.67% de los clientes están satisfechos con la implementación del software que él desarrolló. Recopilando lo planteado se afirma que toda propuesta tecnológica debe ser validada e indiferente del método empleado para poder determinar el grado de aceptación y asimilación, estos deben estar en un nivel admisible, de acuerdo a la problemática abordada. De esta manera el investigador podrá tener una retroalimentación de su propuesta, y si los valores obtenidos no son favorables, se debe mejorar lo desarrollado hasta alcanzar un mejor nivel.

Conclusiones

Mediante el desarrollo del sistema inteligente para identificar dermatofitosis en pacientes de un centro dermatológico de la ciudad de Chiclayo, en la presente tesis se concluye.

Mediante la comparación de los principales algoritmos de machine learning se pudo identificar el algoritmo idóneo de la red neuronal artificial para el análisis de las imágenes. El algoritmo empleado fue Convolutional Neural Networks, el cual alcanzó un puntaje de 2.8, y según los criterios aplicados en la comparación, este tipo de algoritmo se ajustó más a la solución de la problemática tratada.

Luego de realizar la predicción, en la sección de metodología general de machine, donde se trabajó con 72 imágenes, que representan el 5% de las 1430 imágenes empleadas en esta investigación, con las cuales se simuló un escenario real donde el sistema inteligente alcanzó una especificidad de 83.33%, evidenciando la confiabilidad del mismo tras un resultado negativo ya que de este conjunto de imágenes 36 no tenían características de dermatofitosis y el sistema acertó en 30 de ellas clasificándolas con un porcentaje de no dermatofitosis.

Igualmente, en el escenario ya mencionado de las 72 imágenes, 36 correspondían a dermatofitosis, en las cuales el sistema inteligente pudo predecir correctamente 32 imágenes, es decir, se consiguió que la probabilidad de verdaderos positivos fuera de 0.8889 y la probabilidad de falsos positivos fuese de 0.1111. Con estos valores se alcanzó un 88.89% de sensibilidad, evidenciando la confiabilidad de SisDerma tras un resultado positivo.

Finalmente, podemos concluir en virtud de los resultados obtenidos por el modelo de aceptación tecnológica TAM, que SisDerma, según la utilidad percibida de los especialistas del centro de dermatológico de estudio, obtuvo una alta puntuación, 37 puntos de un máximo de 42 (88.10%) y este puntaje se encuentra ubicado en el quintil número 5, por lo cual se afirma que SisDerma es considerada muy útil por los especialistas. Producto de la aplicación del modelo TAM, también se recogió la usabilidad percibida de los especialistas, la cual alcanzó un puntaje de 35 puntos que representan el 83.33% del total máximo (42); puntaje cuya ubicación se encuentra en el sector más alto de los quintiles identificados, a partir de lo cual se puede sintetizar que para los dermatólogos SisDerma es muy fácil de usar.

Recomendaciones

Tras haber culminado esta investigación y el desarrollo del sistema inteligente para identificar dermatofitosis en pacientes de un centro dermatológico de la ciudad de Chiclayo; a partir de esto surgen muchas posibles investigaciones futuras para las cuales se recomienda.

Para mejorar los resultados obtenidos en la presente investigación, en un proyecto de mayor envergadura de tiempo, se recomienda usar una segmentación previa al entrenamiento de las imágenes para obtener una mejor clasificación de las mismas, del mismo modo se aconseja probar un número mayor de capas y épocas de la red neuronal artificial durante su entrenamiento, sin llegar a caer en el problema de overfitting (sobre entrenamiento); de esta manera la precisión de los resultados podría mejorar al momento de validar las imágenes.

En una investigación, cuya problemática abarque más de una anomalía epidérmica, se recomienda contar con al menos mil imágenes por cada salida que se tendrá en la última capa de la red neuronal.

Debido a la demanda y avance tecnológico de los celulares, se recomienda agregar una interfaz de aplicación móvil que permita aprovechar los recursos del algoritmo desarrollado en esta investigación y tener una versión of line para subir y procesar imágenes, aprovechando las cualidades nativas de los dispositivos móviles.

Referencias

- [1] C. Figueroas, «Micosis superficiales: diagnóstico y tratamiento,» Barcelona, 2008.
- [2] L. Sánchez, R. Matos y H. Kumakawa, «Infecciones micóticas superficiales,» *Dermatología peruana*, vol. XIX, n° 3, pp. 226-266, 2009 [En línea]. Disponible en: https://sisbib.unmsm.edu.pe/bvrevistas/dermatologia/v19_n3/pdf/a09v19n3.pdf. [Accedido: 12-jul-2020]
- [3] E. Boncompte, M. Algueró, S. Videla y J. Forn, «Contribución al estudio de las dermatomicosis en Cataluña,» *Revista Iberoamericana de Micología*, vol. XIV, pp. 26-28, 1997 [En línea]. Disponible en: https://www.researchgate.net/publication/239531412_Contribucion_al_estudio_de_las_dermatomicosis_en_Cataluna. [Accedido: 12-jul-2020]
- [4] R. Ballesté, N. Fernández, M. Nélica, B. Xavier, Z. Arteta, M. Mernes y E. Gezuele, «Dermatofitosis en población asistida en el Instituto de Higiene,» *Revista Médica del Uruguay*, vol. XVI, pp. 232-242, 2000 [En línea]. Disponible en: <https://www.smu.org.uy/publicaciones/rmu/2000v3/art7.pdf>. [Accedido: 12-jul-2020]
- [5] D. Martínez, R. Hernández, P. Alvarado y M. Mendoza, «Las micosis en Venezuela: casuística de los Grupos de Trabajo en Micología (1984-2010),» *Revista Iberoamericana de Micología*, vol. XXX, n° 1, p. 40, 2013 [En línea]. Disponible en: <http://www.reviberoammicol.com/2013-30/039046.pdf>. [Accedido: 20-jul-2020]
- [6] S. Romero y R. Guevara, «Dermatofitosis en estudiantes de la Institución Educativa "San Juan de la Frontera", Ayacucho, 2010,» *Revista Peruana de Epidemiología*, vol. XV, n° 1, pp. 65-68, 2011 [En línea]. Disponible en: <https://www.redalyc.org/articulo.oa?id=203119644011>. [Accedido: 12-jul-2020]
- [7] A. Cárdenas, L. Tincopa, W. Fernández, J. Valverde y H. Agip, «Tiña capitis, frecuencia de agentes etiológicos,» *Dermatología peruana*, vol. XI, n° 1, pp. 15-18, 2001 [En línea]. Disponible en: https://sisbib.unmsm.edu.pe/bvrevistas/dermatologia/v11_n1/ti%C3%B1a%20capitis.htm. [Accedido: 20-jul-2020]
- [8] R. Ventura, «Dermatofitosis por *Microsporum canis*,» *Revista Experiencia en Medicina del Hospital Regional Lambayeque*, vol. II, n° 3, p. 113, 2016. [En línea]. Disponible en: <http://rem.hrlamb.gob.pe/index.php/REM/article/view/56/52>. [Accedido: 20-jul-2020]
- [9] Y. Bernilla y R. Herna, «Efecto Inhibitorio in vitro de Terbinafina y Fluconazol sobre *Trichophyton rubrum* y *Microsporum canis*, Hospital Regional Lambayeque,» Lambayeque, 2018 [En línea]. Disponible en: <https://repositorio.unprg.edu.pe/handle/20.500.12893/3356>. [Accedido: 20-jul-2020]

- [10] «Conexión Vida,» Conexión Vida, 13 Mayo 2019. [En línea]. Available: <https://conexionvida.net.pe/2019/05/13/automedicacion/>. [Último acceso: 17 Setiembre 2020].
- [11] R. Arenas, «Dermatofitosis,» de *Micología médica ilustrada*, Tercera ed., México D.F, McGraw-Hill. Interamericana. Editores S.A, 2008, pp. 72-77.
- [12] R. Domínguez, «Detección de cáncer de piel asistido por ordenador con especialización en melanomas,» Sangolquí, 2018.
- [13] R. Coronado, «Reconocimiento de patrones en imágenes no dermatoscópicas para la detección de enfermedades malignas en la piel, utilizando redes neuronales convolutivas y autocodificadores,» Arequipa, 2018.
- [14] J. Gamboa, «Aplicación móvil para el diagnóstico preliminar de micosis superficiales a través de fotografías digitales,» Lima, 2018.
- [15] J. Rodríguez, «Modelo de Gestión de Riesgos de Tecnologías de la información como apoyo en la continuidad del negocio en una empresa que brinda software como servicio,» Chiclayo, 2019.
- [16] E. Vásquez, «Algoritmo para detección de huevos de *Trichuris trichiura* en imágenes microscópicas de muestras coprológicas - Hospital Regional de Lambayeque - 2019,» Lambayeque, 2020.
- [17] L. Santos, «Aplicación móvil y web responsiva utilizando el algoritmo de planificación basado en prioridades para apoyar en la atención de solicitudes del servicio delivery en la lavandería Quin,» Chiclayo, 2018.
- [18] J. Palma y R. Marín, «Inteligencia Artificial. Métodos, técnicas y aplicaciones.,» de *Inteligencia Artificial. Métodos, técnicas y aplicaciones.*, Madrid, McGraw-Hill/Interamericana de España, S.A.U, 2008, pp. 3-5.
- [19] N. Obregón y F. Federico, «Sistemas inteligente, ingeniería e hidroeinformática,» *Revista Ciencia e Ingeniería Neogranadina*, n° 13, pp. 71-79, 2003 [En línea]. Disponible en: <https://revistas.unimilitar.edu.co/index.php/rcin/article/view/1339/1068>. [Accedido: 10-ago-2020]
- [20] A. Hopgood, *Intelligent systems for engineers and scientists*, Londres: CRC Press, 2012.
- [21] K. Murphy, *Machine Learning: A Probabilistic Perspective*, Londres: MIT Press, 2012.
- [22] C. Bishop, *Pattern Recognition and Machine Learning*, Singapur: Springer, 2006.
- [23] G. Hinton, S. Osindero y Y. Teh, «A Fast Learning Algorithm for Deep Belief Nets,» *Neural Comput*, vol. XVIII, n° 7, p. 1527-1554, 2006 [En línea]. Disponible en: <https://www.cs.toronto.edu/~hinton/absps/fastnc.pdf>. [Accedido: 10-ago-2020]
- [24] W. McCulloch y W. Pitts, «A logical calculus of the ideas immanent in nervous activity,» *Bulletin of Mathematical Biophysics*, vol. V, n° 4, pp. 115-133, 1943 [En línea]. Disponible en: <https://www.cs.cmu.edu/~epxing/Class/10715/reading/McCulloch.and.Pitts.pdf>. [Accedido: 10-ago-2020]

- [25] J. Suárez, L. Colín, A. Mejía, J. Ambriz y J. García, «Una aproximación al diagnóstico de enfermedades de la piel por medio de aprendizaje profundo,» *Revista Aristas: Investigación básica y aplicada*, vol. VI, nº 12, pp. 13-16, 2018 [En línea]. Disponible en: <http://fcqi.tij.uabc.mx/usuarios/revistaaristas/numeros/N12/articulos/13-16.pdf>. [Accedido: 10-ago-2020]
- [26] J. Díaz, B. Gallego y L. Aracelys, «El diagnóstico médico: bases y procedimientos,» *Revista Cubana de Medicina General Integral*, vol. XXII, nº 1, 2006 [En línea]. Disponible en: <http://scielo.sld.cu/pdf/mgi/v22n1/mgi07106.pdf>. [Accedido: 10-ago-2020]
- [27] L. Jameson, A. Fauci, D. Kasper, S. Hauser, D. Longo y J. Loscalzo, Harrison. Principios de Medicina Interna, 20a ed., Santa Fe: McGraw-Hill Global Education Holdings LLC, 2018.
- [28] F. Salech, V. Mery, F. Larrondo y G. Rada, «Estudios que evalúan un test diagnóstico: interpretando sus resultados,» *Revista Médica Chile*, vol. CXXXVI, nº 9, pp. 1203-1208, 2008 [En línea]. Disponible en: <https://scielo.conicyt.cl/pdf/rmc/v136n9/art18.pdf>. [Accedido: 10-ago-2020]
- [29] T. Sánchez y A. Noel, «¿Son la sensibilidad y la especificidad medidas obsoletas para determinar la bondad de una prueba diagnóstica?,» *Revista Facultad Nacional de Salud Pública*, vol. XX, nº 1, pp. 149-159, 2002 [En línea]. Disponible en: <https://www.redalyc.org/pdf/120/12020113.pdf>. [Accedido: 15-ago-2020]
- [30] G. Vizcaíno, «Importancia del cálculo de la sensibilidad, la especificidad y otros parámetros estadísticos en el uso de las pruebas de diagnóstico clínico y de laboratorio,» *Medicina & Laboratorio*, vol. XXIII, nº 7, pp. 365-386, 2017. [En línea]. Disponible en: <https://medicinaylaboratorio.com/index.php/myl/article/view/34/27>. [Accedido: 15-ago-2020]
- [31] J. Cegarra, Metodología de la investigación científica y tecnológica, Ediciones Díaz de Santos, 2011, p. 125.
- [32] F. Chollet, Deep Learning with Python, New York: Manning Publications Co., 2018.
- [33] U. d. Iowa, «Health Care,» Universidad de Iowa, 2020. [En línea]. Available: <https://medicine.uiowa.edu/dermatology/education/clinical-skin-disease-images>. [Último acceso: 15 Mayo 2020].
- [34] Dermnet, «Dermnet,» Dermnet Skin Disease Atlas, 2020. [En línea]. Available: <http://www.dermnet.com/>. [Último acceso: 15 Mayo 2020].
- [35] Dermnetnz, «Dermnetnz.org,» Dermnetnz, 2020. [En línea]. Available: <https://dermnetnz.org/image-library/>. [Último acceso: 18 Mayo 2020].
- [36] Kaggle, «Kaggle,» Kaggle, 2020. [En línea]. Available: <https://www.kaggle.com/datasets>. [Último acceso: 15 Mayo 2020].
- [37] Openi, «Openi,» Openi.nlm, 2020. [En línea]. Available: <https://openi.nlm.nih.gov/>. [Último acceso: 18 Mayo 2020].
- [38] P. Baheti, M. Sikka, V. Arya y R. Rajesh, «Federated Learning on Distributed Medical Records for Detection of Lung Nodules,» *VISIGRAPP*, vol. XV, pp. 445-451, 2020. [En línea]. Available: <https://n9.cl/7t4s1>. [Último acceso: 10 Setiembre 2020].

- [39] Opencv, «Opencv,» Opencv.org, 2020. [En línea]. Available: <https://opencv.org/>. [Último acceso: 1 Junio 2020].
- [40] J. McCall, P. Richards y C. Walters, *Factors in Software Quality*, New York: General Electric Company, 1977.
- [41] D. Bermejo, R. San José y M. Ledesma, «Detección y clasificación de enfisema pulmonar en imágenes de TAC mediante Redes Neuronales Convolucionales Multiescala,» de *XXXIV Congreso Anual de la Sociedad Española de Ingeniería Biomédica*, Valencia, 2016.
- [42] M. Abadi, P. Barham, A. Davis y J. Dean, «TensorFlow: A System for Large-Scale,» Savannah,GA, 2016.
- [43] M. Maher, «Medium,» Medium, 19 Enero 2019. [En línea]. Available: <https://medium.com/analytics-vidhya/understanding-a-mouse-is-like-smelling-the-color-9-fe74534f4579>. [Último acceso: 10 Junio 2020].
- [44] B. Settles, «Active Learning Literature Survey,» Wisconsin, 2009.
- [45] F. Davis, «Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology,» *MIS Quarterly*, vol. XIII, nº 3, p. 319, 1989 . [En línea]. Disponible en: <https://www.jstor.org/stable/249008>. [Accedido: 23-ago-2020].

Anexos

Anexo N° 01. Prueba de caja negra: Gestionar imagen

CASO N° 01: PCN-01: Gestionar imagen

TABLA XII CAJA NEGRA: GESTIONAR IMAGEN

Pruebas de caja negra		Fecha: 03/07/2020		
Elemento de prueba		Procedimiento: Procedimiento interno		
Nombre: Registrar imagen				
N°	Tipo de prueba	Datos de prueba	Resultado Esperado	Cumple
1	Funcional	Archivo de imagen vacío	No guardar información	Sí
2	Funcional	Formato de fecha incorrecto	No aceptar valores	Sí
4	Funcional	Validación en edición de datos	Cumplir con Resultado Esperado N° 1, y 2.	Sí
5	Comunicación	Al dar clic en el botón Subir imagen	Establecer comunicación con la base de datos e insertar en la tabla correspondiente. Mensaje de confirmación.	Sí
6	Comunicación	Al dar clic en el botón Editar	Establecer la comunicación con la base de datos y modificar en las tablas correspondientes. Mensaje de confirmación.	Sí
7	Comunicación	Al dar clic en el botón Eliminar	Establecer la comunicación con la base de datos y elimina la información correspondiente.	Sí

Anexo N° 02. Prueba de caja blanca: Predecir imagen

CASO N° 01: PCB-01: Predecir imagen

TABLA XIII CAJA BLANCA: PREDECIR IMAGEN

FORMATO DE CASOS DE PRUEBA	
Tipo de prueba:	Unitaria (caja blanca) del método predecir imagen.
Objetivo:	Validar que el sistema pueda procesar y arrojar una predicción dada una imagen.
CASO N° 01: PCB-01: Predecir imagen	
Descripción:	Datos correctos: imagen a color. Datos incorrectos: formato digital distinto a JPEG, JPG y PNG
Entradas:	Imagen
Salida esperada:	Mostrar resultado de la predicción (se tiene o no dermatofitosis)

Fragmento de código

```

18  model_path='modelo3.h5' ← I
19
20  def verificar_enfermedad(image): ← 1
21      #cargamos el modelo
22      modelo= load_model(model_path) ← 2
23      #redimensionar imagen y predecimos img
24      prediccion=predecir_imagen(image, modelo) ← 3
25
26      #Interpretación de resultados
27      resp=interpretar_resultados(prediccion) ← 4
28
29      return resp ← F
30
31  #Función para cargar el modelo
32  def load_model(model_path): ← 2.0
33      """
34      cargar modelo ya hecho desde la ruta dada
35      """
36      #print(f"cargando el modelo desde la ruta: {model_path}")
37  A  model = tf.keras.models.load_model(model_path) ← 2.1
38      return model ← 2.2
41  def predecir_imagen(image_par,modelo_par): ← 3.0
42
43      img=Image.open(image_par) ← 3.1
44      #convertir imagen a numpy array con las dimensiones necesarias
45      img = img.convert(mode='RGB')
46      img = np.array(img)
47      img = img / 255.0
48      img=cv2.resize(img,(150,150))
49      img=(np.expand_dims(img,0))
50      data=np.array(img)
51      #data_Reshaped = data.reshape(150,150)
52      data_Reshaped = data.reshape(len(data),150,150,3)
53      modelo_par.summary
54  B  res=modelo_par.predict(data_Reshaped) ← 3.3
55      return res ← 3.4
56
57  #Función para interpretar resultados
58
59  def interpretar_resultados(prediccion): ← 4.0
60  C  if prediccion[0][0]>prediccion[0][1]: ← 4.1
61      res_valor=prediccion[0][0]*100
62      res_valor="{:.3f}".format(res_valor) ← 4.2
63      res=str(res_valor)+" de NO DERMATOFITOSIS"
64  D  elif prediccion[0][0]<prediccion[0][1]: ← 4.3
65      res_valor=prediccion[0][1]*100
66      res_valor="{:.3f}".format(res_valor) ← 4.4
67      res=str(res_valor)+" de DERMATOFITOSIS"
68      else:
69  4.5  res="50 de probabilidad de TENER o NO Dermatoftosis. Se sugiere analizar la imagen"
70      return res ← 4.6

```

Fig. 11. Fragmento de código: predecir imagen

Este código lo que realiza es el análisis de la imagen que el usuario ingresa a SisDerma. Del mismo modo comprueba que el modelo de machine learning exista y que el tipo de imagen ingresada sea de un formato válido (JPEG, JPG y PNG). Finalmente se analiza la imagen gracias al método predict del modelo entrenado y se interpretan los valores arrojados.

Grafo de flujo

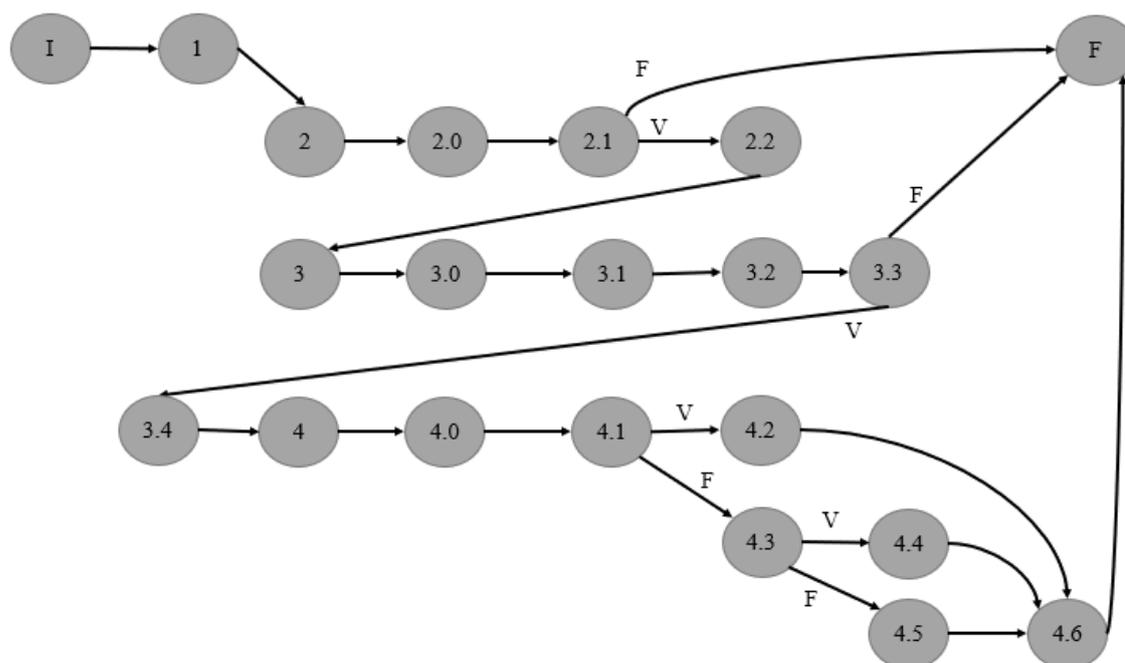


Fig. 12. Grafo de flujo: predecir imagen

Este grafo representa la secuencia que se sigue para que un usuario pueda obtener los resultados de SisDerma. Para este caso el nodo 2.1 implica que exista el modelo de machine learning, si no existe el sistema mostrará un mensaje de que no se encontró el modelo. Una vez que se cargue el modelo se procede a realizar la predicción de la imagen (nodo 3). En el nodo 3.3 SisDerma predicará la imagen, si no retorna valor alguno el sistema mandará un mensaje de que se ha tenido problemas al predecir la imagen, por lo contrario si sí se retorna un valor, el algoritmo prosigue al nodo 4 donde se interpreta lo retornado. En el nodo 4.1 se evalúa si el valor devuelto, si no posee características de dermatofitosis se procede a concatenar el valor con el texto “de NO DERMATOFITOSIS” (nodo 4.2), caso contrario se procede al nodo 4.3 donde se evalúa si el valor está relacionado con la enfermedad, de ser verdadero se agrega el texto “de DERMATOFITOSIS” al valor retornado (nodo 4.4); de lo contrario se procede a pasar al nodo 4.5 donde se agrega al resultado el texto de “50 de probabilidad de TENE o NO Dermatofitosis. Se sugiere analizar la imagen”. Por último se retorna el valor con el texto adicionado según sea el caso.

Complejidad ciclomática

$$VG = \text{Aristas} - \text{nodos} + 2 = 24 - 21 + 2 = 5$$

TABLA XIV COMPLEJIDAD CICLOMÁTICA: VALIDAR USUARIO

Camino	Entrada	Salida
1, 2, 2.0,2.1, 2.2, 3, 3.0, 3.1, 3.2, 3.3, 3.4, 4, 4.0, 4.1, 4.2, 4.6, F	A=true, B= true, C= true	Ejecución con éxito. Administrador o dermatólogo visualiza el valor de la predicción de NO DERMATOFITOSIS.
1, 2, 2.0,2.1, 2.2, 3, 3.0, 3.1, 3.2, 3.3, 3.4, 4, 4.0, 4.1, 4.3, 4.4, 4.6, F	A=true, B= true, C= false, D=true	Ejecución con éxito. Administrador o dermatólogo visualiza el valor de la predicción de DERMATOFITOSIS.
1, 2, 2.0,2.1, 2.2, 3, 3.0, 3.1, 3.2, 3.3, 3.4, 4, 4.0, 4.1, 4.3, 4.5, 4.6, F	A=true, B= true, C= false, D=false	Ejecución con éxito. Administrador o dermatólogo visualiza “50 de probabilidad de TENE o NO Dermatofitosis. Se sugiere analizar la imagen”.
1, 2, 2.0,2.1, 2.2, 3, 3.0, 3.1, 3.2, 3.3, F	A=true, B= false	Mensaje que indica que no se ha podido predecir la imagen.
1, 2, 2.0, 2.1, F	A=false	Mensaje que indica problemas con el modelo entrenado.

Anexo N° 03. Selección de algoritmo: criterios

Criterio	Coficiente	Valor
C4-Aprendizaje	P4	0.3
C5-Input image	P5	0.3
C1-Tiempo	P1	0.2
C3- Interoperación	P3	0.1
C2- Reusabilidad	P2	0.1

Anexo N° 04. Selección de algoritmo: escala de valores

Calificativo		Calificativo	
C1, C2, C3	Puntaje	C4, C5	Puntaje
Bajo	3	Cumple	3
Medio	2	No Cumple	1
Alto	1		

Anexo N° 05. Validación del modelo: prisión por época

Época	Precisión
1	0.7570
2	0.6916
3	0.7850
4	0.7477
5	0.7991
6	0.7991
7	0.8037
8	0.7991
9	0.7991
10	0.8178
11	0.7897
12	0.7664
13	0.7523
14	0.8318
15	0.8224
16	0.8458
17	0.7757
18	0.8178
19	0.8458
20	0.8411

Anexo N° 06. Utilidad y usabilidad percibida: resumen

Ítem	Valor utilidad	Valor usabilidad
PP	37	35
%	88.10%	83.33%
QL	Q5	Q5
Resultado	Muy útil	Muy fácil

Anexo N° 07. Iteraciones

ID	Descripción	Iteración		
		1	2	3
HU-01	Registro de usuarios	X		
HU-02	Validar usuario	X		
HU-03	Cerrar sesión	X		
HU-04	Cargar imagen.		X	
HU-05	Previsualización de imagen		X	
HU-06	Registrar tratamiento		X	
HU-07	Gestionar administrador (Insertar, listar, modificar, eliminar)	X		
HU-08	Gestionar paciente (Insertar, listar, modificar, eliminar)	X		
HU-09	Gestionar dermatólogo (Insertar, listar, modificar, eliminar)	X		
HU-10	Gestionar imagen (Insertar, listar, modificar, eliminar)	X		
HU-11	Ver estado de usuarios			X
HU-12	Cambiar estado usuario			X
HU-13	Ver proceso evolutivo			X
HU-14	Reporte estadístico			X

Anexo N° 08. Formato de encuesta TAM

PARTICIPANTE:

OBJETIVOS: Conocer la percepción de los usuarios en cuanto a la aceptación del sistema inteligente.

- **Utilidad percibida**

Indicador

Índice alto= Muy útil

Índice bajo= No útil

Escala tipo Likert de 7 puntos

	1	2	3	4	5	6	7	
Improbable	Extremadamente	Bastante	Ligeramente	Ninguno	Ligeramente	Bastante	Extremadamente	Probable

Questionario

Por favor marque con una [X] según corresponda.

	Calificación						
1. Usando SISDERMA en mi trabajo me permitiría realizar tareas más rápidamente.	1	2	3	4	5	6	7
2. Usando SISDERMA mejoraría mi actuación en el trabajo.	1	2	3	4	5	6	7
3. Usando SISDERMA aumentaría mi productividad.	1	2	3	4	5	6	7
4. Usando SISDERMA mejoraría mi efectividad en el trabajo.	1	2	3	4	5	6	7
5. Usando SISDERMA me facilitaría hacer mi trabajo.	1	2	3	4	5	6	7
6. Encontraría a SISDERMA útil en mi trabajo.	1	2	3	4	5	6	7

- **Facilidad de uso percibida**

Indicador

Índice alto= Fácil

Índice bajo= Difícil

Escala tipo Likert de 7 puntos

	1	2	3	4	5	6	7	
Improbable	Extremadamente	Bastante	Ligeramente	Ninguno	Ligeramente	bastante	extremadamente	Probable

Questionario

Por favor marque con una [X] según corresponda.

	Calificación						
	1	2	3	4	5	6	7
1. Aprender a utilizar SISDERMA es fácil para mí.							
2. Me resulta fácil hacer que SISDERMA haga lo que quiero que haga.							
3. Mi interacción con SISDERMA es clara y entendible.							
4. Encuentro que SISDERMA es flexible para interactuar.							
5. Sería fácil para mí llegar a ser hábil al usar SISDERMA.							
6. Encuentro que SISDERMA es fácil de usar.							

**ANEXO N° 09. GUÍA DE ENTREVISTA 01: CONOCER LA REALIDAD DE LA
EMPRESA**

PARTICIPANTE: Dr. Winston Maldonado García

ENTREVISTADOR: Jheiner Reaño Coveñas

OBJETIVOS: Conocer la realidad de la empresa

FECHA: 5 de septiembre de 2019

PREGUNTAS:

- 1.- ¿Lugar de procedencia de sus pacientes?
- 2.- ¿Cuáles son las anomalías epidérmicas más frecuentes que ha tratado?
- 3.- ¿Las características, de cada anomalía, visualmente hablando, son similares o muy diferentes entre sí?
- 4.- ¿La dermatología se puede analizar con imágenes?
- 5.- ¿Influye cómo se toma la foto?
- 6.- ¿Utiliza algún dispositivo tecnológico que colabore en su trabajo?
- 7.- ¿Emplea algún tipo de software o aplicación para diagnosticar las anomalías?

**ANEXO N° 10. GUÍA DE ENTREVISTA 02: CONOCER EL PROCESO DEL
NEGOCIO**

PARTICIPANTE: Mirian Monteza Espinoza (secretaria)

ENTREVISTADOR: Jheiner Reaño Coveñas

OBJETIVOS: Conocer más el proceso del negocio.

FECHA: 1 de octubre de 2019

PREGUNTAS:

- 1.- ¿Son frecuentes las tiñas en este centro dermatológico?
- 2.- ¿Cómo inicia proceso para diagnosticar una enfermedad?
- 3.- Usted como secretaria ¿Tiene acceso a las fotos que envían los pacientes?
- 4.- Si el paciente vuelve al centro dermatológico ¿Es sencillo para usted buscar la imagen tomada con anterioridad?
- 5.- ¿Cómo se realiza el análisis de la enfermedad?
- 6.- ¿Cuánto tiempo hay aproximadamente desde este centro a la Laboratorios Linares?
- 7.- ¿Porque no se da ese análisis patológico en este centro?
- 8.- ¿Qué otros procesos dermatológicos se realizan?
- 9.- ¿En la biopsia que elementos o instrumentos se utilizan?
- 10.-¿Cuándo lo usan el microscopio?