



UNIVERSIDAD CÉSAR VALLEJO

**FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**

Algoritmo para el diagnóstico preliminar de melanoma cutáneo
basado en redes neuronales, Naive Bayes y árboles de decisión

TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:
Ingeniero de Sistemas

AUTORES:

Alarcon Vela, Víctor Miguel (ORCID: 0000-0003-2821-2171)

Murga Aguilar, Daisy Magaly (ORCID: 0000-0001-8593-4643)

ASESOR:

Dr. Alfaro Paredes, Emigdio Antonio (ORCID: 0000-0002-0309-9195)

LÍNEA DE INVESTIGACIÓN:

Sistema de información y comunicaciones

LÍNEA DE RESPONSABILIDAD SOCIAL UNIVERSITARIA:

Promoción de la salud, nutrición y salud alimentaria

LIMA – PERÚ

2020

Dedicatoria

Esta investigación está dedicada a nuestros padres por inspirarnos a ser mejores personas, alentarnos y apoyarnos incondicionalmente en cada uno de nuestros logros profesionales.

Agradecimiento

A nuestro asesor, el Dr. Emigdio Alfaro Paredes, por guiarnos en la elaboración de la investigación, brindarnos de su tiempo, conocimiento y paciencia.

ÍNDICE DE CONTENIDOS

Carátula.....	i
Dedicatoria	ii
Agradecimiento	iii
Índice de contenidos	iv
Índice de tablas	vi
Índice de figuras	vii
Índice de anexos	viii
Índice de abreviaturas	ix
Resumen.....	xi
Abstract.....	xii
I. INTRODUCCIÓN	1
II. MARCO TEÓRICO.....	13
III. METODOLOGÍA.....	20
3.1 Tipo y diseño de investigación	21
3.2 Variables y operacionalización	22
3.3 Población, muestra y muestreo	23
3.4 Técnicas e instrumentos de recolección de datos.....	24
3.5 Procedimientos.....	25
3.6 Métodos de análisis de datos.....	25
3.7 Aspectos éticos	26
VI. RESULTADOS.....	28
4.1. Cálculo de los indicadores.....	29
4.1.1. Cálculo de los indicadores con 3 mil fotografías con el algoritmo de redes neuronales	29
4.1.2. Cálculo de los indicadores con 3 mil fotografías con el algoritmo de Naive Bayes	30
4.1.3. Cálculo de los indicadores con 3 mil fotografías con el algoritmo de árbol de decisiones	31
4.2. Prueba de hipótesis	33
4.2.1. Hipótesis específica HE1	33

4.2.2 Hipótesis específica HE2	33
4.2.3. Hipótesis específica HE3	34
4.2.4. Hipótesis específica HE4	34
4.2.5 Hipótesis específica HE5	34
4.2.6. Hipótesis específica HE6	35
4.2.7. Hipótesis específica HE7	35
4.2.8. Hipótesis específica HE8	35
4.2.9. Hipótesis específica HE9	36
4.2.10. Hipótesis específica HE10	36
4.2.11. Hipótesis específica HE11	36
4.2.12. Hipótesis específica HE12	37
4.2.13. Hipótesis específica HE13	37
4.2.14. Hipótesis específica HE14	37
4.2.15. Hipótesis específica HE15	38
4.3. Hipótesis general	38
4.4. Resumen de las comprobaciones de las hipótesis	38
V. DISCUSIÓN	40
VI. CONCLUSIONES	49
VII. RECOMENDACIONES	52
REFERENCIAS	56
ANEXOS	65

Índice de tablas

Tabla 1 Criterios de inclusión y exclusión de la población	23
Tabla 2 Tipo y cantidad de imágenes dermatoscópicas.....	24
Tabla 3 Matriz de confusión – diagnóstico con 3 mil fotografías dermatoscópicas fotografías con el algoritmo de redes neuronales.....	29
Tabla 4 Matriz de confusión – diagnóstico con 3 mil fotografías dermatoscópicas fotografías con el algoritmo de Naive Bayes	30
Tabla 5 Matriz de confusión – diagnóstico con 3 mil fotografías dermatoscópicas fotografías con el algoritmo de árbol de decisiones.	31
Tabla 6 Matriz de confusión – diagnóstico con 3 mil fotografías dermatoscópicas fotografías con el algoritmo fusionado.....	32
Tabla 7 Comparación en porcentaje de los indicadores de sensibilidad, especificidad, precisión, exactitud y tiempo entre los algoritmos redes neuronales (RN), Naive Bayes (NB), árbol de decisiones (AD) y algoritmo fusionado (AF)	33
Tabla 8 Tabla resumen de las hipótesis.....	39
Tabla 9 Matriz de operacionalización de variables.....	66
Tabla 10 Matriz de consistencia	67

Índice de figuras

Figura 1 Pantalla principal del sistema.....	73
Figura 2 Pantalla de la galería.....	73
Figura 3 Pantalla para la predicción del diagnóstico	74
Figura 4 Pantalla de estadística de resultados.....	74
Figura 5 Pseudocódigo del algoritmo de árbol de decisiones	75
Figura 6 Flujograma del algoritmo de árbol de decisiones	76
Figura 7 Pseudocódigo del algoritmo de redes neuronales	77
Figura 8 Flujograma del algoritmo de redes neuronales	78
Figura 9 Pseudocódigo del algoritmo de Naive Bayes.....	79
Figura 10 Flujograma del algoritmo de Naive Bayes.....	80
Figura 11 Pseudocódigo del algoritmo fusionado.....	81
Figura 12 Flujograma del algoritmo fusionado	82
Figura 13 Arquitectura tecnológica.....	83

Resumen

En esta investigación se incluyó el desarrollo e implementación de un algoritmo fusionado para el diagnóstico preliminar de melanoma cutáneo, ya que la detección temprana de esta enfermedad es un avance significativo en el tratamiento. El objetivo de la investigación fue determinar la precisión diagnóstica del algoritmo fusionado en comparación a los resultados obtenidos por los algoritmos de árbol de decisiones, Naive Bayes y redes neuronales. Se consideró la sensibilidad, la especificidad, la precisión, la exactitud y el tiempo del diagnóstico. Se utilizó la ficha de registro para comparar la precisión diagnóstica del algoritmo fusionado con relación a los otros tres algoritmos.

Se utilizó librerías gratuitas del lenguaje de programación Python, el tipo de estudio fue aplicado de enfoque cuantitativo y el diseño fue pre-experimental de post test, en el cual se consideró un total de 3 mil fotografías dermatoscópicas entre nevus y melanoma para el entrenamiento de los algoritmos. Se utilizó la ficha de registro para medir la precisión diagnóstica del algoritmo fusionado en comparación a la precisión obtenida por los algoritmos de árbol de decisiones, Naive Bayes y redes neuronales.

Los resultados fueron satisfactorios ya que la sensibilidad, la especificidad, la precisión y la exactitud del algoritmo fusionado fueron mayores a las obtenidas por los algoritmos Naive Bayes y redes neuronales; sin embargo, no fueron mayores a las obtenidas con el algoritmo de árboles de decisiones. Se recomendó agregar un algoritmo más orientado a clasificación, por ejemplo, el algoritmo K-Means, con el fin de mejorar los resultados logrados con el algoritmo fusionado para una futura investigación.

Palabras Clave: Naïve Bayes, árboles de decisión, algoritmo fusionado, diagnóstico preliminar, precisión.

Abstract

This research included the development and implementation of a fused algorithm for the preliminary diagnosis of cutaneous melanoma, since early detection of this disease is a significant advance in treatment. The objective of the research was to determine the diagnostic accuracy of the merged algorithm compared to the results obtained by the Decision Tree, Naive Bayes and Neural Network algorithms. Sensitivity, specificity, precision, accuracy and diagnosis time were considered. The registration form was used to compare the diagnostic accuracy of the merged algorithm in relation to the other three algorithms.

Free libraries of the Python programming language were used. The type of study was applied with a quantitative approach and the design was pre-experimental post-test, in which a total of 3 thousand dermoscopy photographs between nevus and melanoma were considered for the training of the algorithms. The registration form was used to measure the diagnostic accuracy of the algorithm fused in comparison to the accuracy obtained by the Decision Trees, Naive Bayes and Neural Networks algorithms.

The results were satisfactory due to that the sensitivity, specificity, precision, and accuracy of the fused algorithm were higher than those obtained by Naive Bayes algorithms and neural networks; however, they were not higher than those obtained with the decision tree algorithm. Adding a more classification-oriented algorithm, for example, the K-Means algorithm in order to improve the results achieved with the merged algorithm was recommended for future research.

Keywords: Naïve Bayes, decision trees, fused algorithm, preliminary diagnosis, precision.

I. INTRODUCCIÓN

En este capítulo se presenta la realidad problemática que se desglosa en dos puntos importantes, la importancia de la detección temprana del cáncer de piel de tipo melanoma y el diagnóstico preliminar a través de fotografías digitales. Esta investigación se justificó de manera teórica, tecnológica y social para su desarrollo. El problema de la investigación fue el siguiente: ¿Cuál fue el efecto del algoritmo fusionado basado en los algoritmos de Naive Bayes, árbol de decisiones y redes neuronales en la precisión diagnóstica preliminar de melanoma cutáneo?

Asimismo, el objetivo de la investigación fue determinar la precisión diagnóstica que obtuvo el algoritmo fusionado en el diagnóstico preliminar de melanoma cutáneo con relación a los algoritmos redes neuronales, Naive Bayes y árbol de decisiones. Los objetivos específicos estuvieron enfocados en contrastar los indicadores del algoritmo fusionado, con los otros 3 algoritmos. De igual manera la hipótesis general fue: “La precisión obtenida por el algoritmo fusionado es mayor a la precisión obtenida por los algoritmos, redes neuronales, Naive Bayes y árbol de decisiones”, de lo cual se determinaron las hipótesis específicas en función a los indicadores de la precisión diagnóstica. Iglesias et al. (2019) mencionaron que el cáncer de piel corresponde a las principales neoplasias malignas en el mundo, y el porcentaje de afectados se ha intensificado en los últimos años (p. 434). La exposición frecuente a los rayos UV representa uno de los factores principales para la aparición y desarrollo de cualquier tipo de cáncer de piel (Iglesias et al., 2019, p. 434).

Ayala (2020) indicó que el director general de la OMS señaló que cada año se reportan en el mundo 132,000 casos de melanoma maligno (el cáncer de piel más dañino que existe) y fallecen aproximadamente 66,000 personas por causa de este y otros tipos de cáncer de piel (p. 5). El melanoma cutáneo no es el tipo de cáncer de piel más común, sin embargo, representa aproximadamente el 4% con relación al porcentaje total de cáncer de piel en el mundo (Ayala, 2020, p. 5).

Ayala (2020) señaló que en el Perú el 5% de pacientes tiene cáncer de piel de tipo melanoma mortal, según un informe emitido por el INEN. Se necesita quimioterapia, inmunoterapia y medicamentos biológicos. Además, el costo del

tratamiento oscila entre 100 mil y 300 mil soles. De 10 pacientes con esta enfermedad, tres fallecen anualmente (p. 12). Al igual que en todas las enfermedades existentes, la detección temprana significa un gran avance para el tratamiento, por ello resulta importante el desarrollo de herramientas que apoyen la labor desarrollada por el dermatólogo (Ayala, 2020, p. 12).

Ayala (2020) mencionó que el melanoma cutáneo es una forma mortal de cáncer de piel y es responsable del 75% de todas las muertes por cáncer de piel (p. 35). Si se diagnostica y trata en sus primeras etapas puede ser tratado, pero si el diagnóstico no se realiza en etapas tempranas, el melanoma puede extenderse más profundamente en la piel y a otras partes de la piel cuerpo (Ayala, 2020, p. 35). Su propagación a otras partes más allá de la piel puede ser peligrosa ya que es difícil de tratar (Ayala, 2020, p. 35).

Pizarro, Hoell, Araya y Araya (2019) denominaron que el cuadro clínico realizado por el dermatólogo se ve afectado por el constante cambio a través del tiempo; la aplicación de las nuevas técnicas y herramientas ha cambiado nuestros protocolos de tratamiento y detección de melanoma; gracias a estos cambios se encontró a la vanguardia de la inmunología, la terapia génica o la telemedicina (p. 434). Además, López (2016) evaluó la precisión obtenida por un sistema web para la detección preliminar de melanoma a través de fotografías digitales usando los algoritmos redes neuronales y Naive Bayes, los cuales mostraron el resultado obtenido de 89% de precisión (p. 12).

A continuación, se exponen las justificaciones de la investigación, las cuales son: social, teórica y tecnológica. Se sabe que la justificación teórica de una investigación está vinculada a la exploración de conocimiento que tiene el investigador para llenar el vacío de conocimiento que se manifiesta en el ambiente académico y científico (Murrugarra et al., 2020, p. 110). Esta investigación se realizó con la intención de aportar al conocimiento que ya existe sobre los algoritmos usados para el diagnóstico preliminar de melanoma a través de fotografías digitales, cuyos resultados se podrían incorporar como conocimiento para futuras investigaciones.

Murrugarra, Lora, Cabrejos, Mucha y Fernández (2020) mencionaron que los datos que se obtienen en las investigaciones cada vez son más amplios ya que los investigadores de sistemas de información tienen la facilidad y oportunidades para que generen una nueva teoría (p. 120). Asimismo, Murrugarra et al. (2020) añadieron que la investigación y el desarrollo de esta tecnología para el diagnóstico a través de fotografías digitales es importante para fortalecer el conocimiento que existe en la comunidad científica (p. 122).

Esta investigación contribuyó tecnológicamente por ser una herramienta para el diagnóstico preliminar de melanoma cutáneo, ya que permitió el realizar una comparativa entre la precisión de diagnóstico que obtuvieron los algoritmos, brindando información instantánea sobre el diagnóstico de cada fotografía digital lo cual aporta a la tendencia actual de crecimiento tecnológico para el diagnóstico y tratamiento de enfermedades. Al respecto, Iglesias et al. (2019) concluyeron que el conocimiento de toda investigación es importante y se deben aprovechar al máximo en los avances tecnológicos (p. 38).

Desde un punto social, la población fue beneficiada ya que la investigación contribuyó al conocimiento realizando una comparativa sobre el rendimiento de un algoritmo fusionado basado en los algoritmos árbol de decisiones, Naive Bayes y redes neuronales, el cual podría ser utilizado en futuras investigaciones sobre diagnóstico preliminar de melanoma en favor de la población. Al respecto, Pizarro et al. (2019) calificaron que los sistemas de gestión de salud, basados en algoritmos de diagnóstico pueden ayudar a la población en el diagnóstico temprano de cáncer de piel de tipo melanoma, lo cual es muy conveniente en el tratamiento del paciente (p. 103).

En relación con la realidad problemática redactada anteriormente, se planteó el problema general y los problemas específicos de la investigación. El problema general de la investigación fue: ¿Cuál fue el efecto del algoritmo fusionado basado en los algoritmos de Naive Bayes, árboles de decisiones y redes neuronales en la precisión diagnóstica preliminar de melanoma cutáneo? Los problemas específicos de la investigación fueron los siguientes:

- **PE1:** ¿Cuál fue el efecto del algoritmo fusionado basado en los algoritmos de Naive Bayes, árbol de decisiones y redes neuronales en la sensibilidad del diagnóstico preliminar de melanoma cutáneo?
- **PE2:** ¿Cuál fue el efecto del algoritmo fusionado basado en los algoritmos de Naive Bayes, árbol de decisiones y redes neuronales en la especificidad del diagnóstico preliminar de melanoma cutáneo?
- **PE3:** ¿Cuál fue el efecto del algoritmo fusionado basado en los algoritmos de Naive Bayes, árbol de decisiones y redes neuronales en la exactitud del diagnóstico preliminar de melanoma cutáneo?
- **PE4:** ¿Cuál fue el efecto del algoritmo fusionado basado en los algoritmos de Naive Bayes, árbol de decisiones y redes neuronales en la precisión del diagnóstico preliminar de melanoma cutáneo?
- **PE5:** ¿Cuál fue el efecto del algoritmo fusionado basado en los algoritmos de Naive Bayes, árbol de decisiones y redes neuronales en el tiempo del diagnóstico?

Esta investigación se propuso determinar la efectividad de los algoritmos de árboles de decisión, Naive Bayes y redes neuronales, para apoyar el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales, y aportar al conocimiento existente sobre la aplicación del aprendizaje profundo para el diagnóstico preliminar de enfermedades. El avance tecnológico ha supuesto un importante impulso en la generación de datos digitales, el modernizar algoritmos y la madurez del hardware informático; en la era de la tecnología, la innovación exige métodos de diagnóstico que mejoren la atención de los pacientes (Iglesias et al., 2019, p. 434).

Para determinar los objetivos, hipótesis y todos los procesos de la investigación, se ha realizado un proceso metodológico ordenado, utilizando técnicas de investigación cuantitativa orientada y enfocada al análisis. El objetivo general fue determinar qué precisión diagnóstica obtendrá el algoritmo fusionado en el diagnóstico preliminar de melanoma cutáneo en relación con los algoritmos

redes neuronales, Naive Bayes y árbol de decisiones. Los objetivos específicos fueron los siguientes:

- **OE1:** Contrastar la sensibilidad obtendrá por el algoritmo fusionado en el diagnóstico preliminar de melanoma cutáneo en relación con los algoritmos de redes neuronales, Naive Bayes y árbol de decisiones.
- **OE2:** Contrastar la especificidad obtenida por el algoritmo fusionado en el diagnóstico preliminar de melanoma cutáneo en relación con los algoritmos de redes neuronales, Naive Bayes y árbol de decisiones.
- **OE3:** Contrastar la exactitud obtenida por el algoritmo fusionado en el diagnóstico preliminar de melanoma cutáneo con relación a los algoritmos de redes neuronales, Naive Bayes y árbol de decisiones.
- **OE4:** Contrastar la precisión obtenida por el algoritmo fusionado en el diagnóstico preliminar de melanoma cutáneo con relación a los algoritmos de redes neuronales, Naive Bayes y árbol de decisiones.
- **OE5:** Contrastar el tiempo total de clasificación del algoritmo fusionado con relación a los algoritmos de redes neuronales, Naive Bayes y árbol de decisiones.

La hipótesis general planteada para la presente investigación fue: “La sensibilidad, especificidad, precisión, exactitud y tiempo de clasificación del algoritmo fusionado no mejoraron con respecto a los algoritmos árboles de decisión, Naive Bayes y redes neuronales”. Las hipótesis específicas planteadas para la presente investigación fueron:

- **HE1:** La sensibilidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo redes neuronales en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Abbes y Sellami (2019) demostraron en su investigación Malignant Melanoma Detection based on Machine learning techniques, un aumento en la sensibilidad en su algoritmo fusionado (redes neuronales y Fuzzy C-Means) donde se obtuvo un 90.1% a comparación del 61.6% de redes

neuronales por separado (p. 55). Además, Tejada y Gonzales (2020) evidenciaron una sensibilidad de 83.22% con el algoritmo de redes neuronales utilizando fotografías de ISIC (p. 84).

- **HE2:** La sensibilidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo Naive bayes en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Khan, Saeed, Muazzam, Mehmood y Khan (2019) mencionaron en su investigación “Detección de distintos tipos de cáncer mediante redes neuronales artificiales” que con un algoritmo fusionado basado en los algoritmos SVM, vecinos cercanos, Naive Bayes y árbol de decisiones, se obtuvo una sensibilidad de 97% a comparación del 78% de Naive Bayes usado independientemente (p. 41). Además, cabe mencionar que Gutiérrez, Margain y Ramírez (2017) obtuvieron un incremento de 94.84% a 97.85% en el resultado de la sensibilidad del algoritmo fusionado basado en el Naive bayes y SVM (p. 305).

- **HE3:** La sensibilidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo árbol de decisiones en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Thepade, Ramnani, y Mandhare (2020) indicaron en su estudio “Uso del aprendizaje automático en el diagnóstico del melanoma” que el algoritmo fusionado basado en SVM, árbol de decisiones y bosque aleatorio obtuvo una sensibilidad de 84.51% a comparación de 72.58% del árbol de decisiones independientemente (p. 3432).

Khan et al. (2019) elaboraron un algoritmo fusionado basado en SVM, vecinos cercanos, Naive Bayes y árbol de decisiones obtuvo una sensibilidad de 97% a comparación del 72% que se obtuvo en sensibilidad con el árbol de decisiones ejecutado independientemente (p. 141).

Además, cabe mencionar que Banerjee, Kumar, Chakraborty, Das, y Bag (2020) demostraron una mejoraría en la sensibilidad con su algoritmo fusionado basado en árbol de decisiones, SVM y vecinos cercanos ya que

obtuvieron un 94.22% a comparación del 90.67% que inicialmente se obtuvo de la ejecución del algoritmo de árbol de decisiones por separado (p. 22).

- **HE4:** La especificidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo redes neuronales en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Abbes et al. (2019) mencionaron en su investigación “Sistema de ayuda al diagnóstico para la detección temprana de melanomas” lograron un aumento en la especificidad en su algoritmo fusionado (redes neuronales y Fuzzy C-Means) con un 84.4% a comparación del 75.8% de redes neuronales por separado (p. 55). Adicionalmente, Fariña (2016) obtuvieron un 80.76% de especificidad después de realizar varias pruebas en su proyecto para diagnosticar melanoma con el algoritmo de redes neuronales (p.40).

- **HE5:** La especificidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo Naive bayes en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Khan et al. (2019) demostraron en su estudio “Performance analysis of ANN and Naive- Bayes classification algorithm for data classification” en el cual se realizó un algoritmo fusionado basado en los algoritmos SVM, vecinos cercanos, Naive Bayes y árbol de decisiones. Se obtuvo una sensibilidad de 93% a comparación del 67% de Naive Bayes independientemente (p. 90141). Adicionalmente, Gutiérrez et al. (2017) demostraron un incremento de 86.16% a 90.15% el resultado de la especificidad del algoritmo fusionado basado en el Naive Bayes, que independientemente del algoritmo antes mencionado neto (p. 306).

- **HE6:** La especificidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo árbol de decisiones en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Thepade et al. (2020) indicaron con su estudio “Uso del aprendizaje automático en el diagnóstico del melanoma” que su algoritmo fusionado basado en los algoritmos SVM, árbol de decisiones y bosque aleatorio obtuvo una especificidad de 80.51% a comparación de 73.34% del árbol de decisiones independientemente (p. 12). Adicionalmente, Khan et al. (2019) demostraron que el algoritmo fusionado basado en SVM, vecinos cercanos, Naive Bayes y árbol de decisiones logró una especificidad de 97% a comparación del 60% de árbol de decisiones independientemente (p. 90141). Asimismo, Banerjee et al. (2020) obtuvieron una mejoraría en especificidad con su algoritmo fusionado (árbol de decisiones, SVM y vecinos cercanos) con 98.13% a comparación del 92.03% del árbol de decisiones por separado (p. 22).

- **HE7:** La exactitud del algoritmo fusionado fue mayor a la obtenida por el algoritmo redes neuronales en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Abbes et al. (2019) demostraron en su investigación “Redes neuronales Convolucionales en la identificación de melanomas benignos y malignos” un aumento en la exactitud en su algoritmo fusionado basado en los algoritmos redes neuronales y Fuzzy C-Means, con un 87.5% a diferencia del 71.7% de redes neuronales por separado (p. 55). Asimismo, Tejada et al. (2020) demostraron una exactitud de 88.87% con el algoritmo de redes neuronales con fotos de la galería de ISIC (p. 84).

- **HE8:** La exactitud del algoritmo fusionado fue mayor al obtenido por el algoritmo Naive bayes en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Khan et al. (2019) mencionaron que en su investigación “Performance analysis of ANN and Naive- Bayes classification algorithm for data classification” su algoritmo fusionado basado en SVM, vecinos cercanos, Naive Bayes y árbol de decisiones obtuvo una exactitud de 94% a comparación del 76% de Naive Bayes independientemente (p. 90141). Asimismo, Gutiérrez et al. (2017) obtuvieron un incremento de 90.36% a

93.64% en el resultado de la exactitud del algoritmo fusionado basado en el Naive Bayes, que al ejecutar independientemente el algoritmo de Naive Bayes (p. 307).

- **HE9:** La exactitud del algoritmo fusionado fue mayor al obtenido por el algoritmo árbol de decisiones en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Khan et al. (2019) indicaron que en su estudio de algoritmo fusionado (SVM, vecinos cercanos, Naive Bayes, árbol de decisiones) obtuvo una exactitud de 97% a comparación del 66% de árbol de decisiones ejecutado independientemente (p.141). También, Banerjee et al. (2020) demostraron una mejoraría en exactitud con su algoritmo fusionado (árbol de decisiones, SVM, vecinos cercanos) con 95% a comparación del 99% del árbol de decisiones por separado (p. 22).

- **HE10:** La precisión del algoritmo fusionado fue mayor al obtenido por el algoritmo redes neuronales en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Arasi, El-Dahshan, El-Horbaty, y Salem (2016) obtuvieron una mejor precisión en el rango de 90% a 97.5% con el algoritmo fusionado (redes neuronales, SVM y KNN) a comparación de los algoritmos de redes neuronales por separados en el detector para melanomas malignos (p. 7). Adicionalmente, Rangel, Ruiz, García, y Cervantes (2019) mencionaron que el algoritmo de redes neuronales obtuvo un 80% de precisión con imágenes dermatoscópicas (p. 26).

- **HE11:** La precisión del algoritmo fusionado fue mayor al obtenido por el algoritmo Naive Bayes en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Khan et al. (2019) demostraron que en su estudio de algoritmo fusionado (SVM, vecinos cercanos, Naive Bayes, árbol de decisiones) obtuvo una precisión de 95% a comparación del 73% de Naive Bayes

independientemente (p.141). Además, Gutiérrez et al. (2017) demostraron un incremento de 90.21% a 93.65% el resultado de la precisión del algoritmo fusionado basado en el Naive bayes, que independientemente del algoritmo antes mencionado por separado (p. 308).

- **HE12:** La precisión del algoritmo fusionado fue mayor al obtenido por el algoritmo árbol de decisiones en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Thepade et al. (2020) indicaron que en su estudio de algoritmo fusionado (SVM, árbol de decisiones, bosque aleatorio) obtuvo una precisión de 82.1% a comparación de 74.36% del árbol de decisiones independientemente (p. 9). Adicionalmente, Khan et al. (2019) demostraron que el algoritmo fusionado (SVM, vecinos cercanos, Naive Bayes, árbol de decisiones) con una precisión de 97% a comparación del 73% de árbol de decisiones independientemente (p.90141).

Conjuntamente, Banerjee et al. (2020) demostraron una mejoraría en precisión con su algoritmo fusionado (árbol de decisiones, SVM, vecinos cercanos) con 94.64% a comparación del 80% del árbol de decisiones por separado (p. 22).

- **HE13:** El tiempo de clasificación del algoritmo fusionado fue menor al obtenido por el algoritmo redes neuronales en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Redmon y Angelova (2015) señalaron que la detección como un problema de regresión, ejecutando redes neuronales prueba el tiempo real para predecir, esta corre a 45 fotogramas por segundo, con alrededor de 25 milisegundos de latencia y, como un plus de este, logra más del doble de la precisión media de otros sistemas (p. 56). También Ulloa (2018) señaló que el algoritmo de redes neuronales puede tener un tiempo de 171 ms de predicción con un tamaño de 3,570 datos por evaluar (p. 8).

- **HE14:** El tiempo de clasificación del algoritmo fusionado fue menor al obtenido por el algoritmo Naive Bayes en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Monja (2020) evaluó respecto al indicador tiempo, la cual compararon los algoritmos de Naive Bayes y series de tiempo, Naive Bayes obtuvo un nivel de exactitud mayor a comparación de series de tiempo de 23 ms de MAPE de Naive Bayes, el 14 ms de MAPE de series de tiempo (p. 39). Conjuntamente, Zamorano (2018) mencionó que el tiempo de predicción del Naive Bayes de decisiones tiene un promedio de 16 ms (p. 104).

- **HE15:** El tiempo de clasificación del algoritmo fusionado fue menor al obtenido por el algoritmo árbol de decisiones en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales.

Banerjee et al. (2020) demostraron una mejoraría en el tiempo de respuesta de su algoritmo fusionado (árbol de decisiones, SVM y vecinos cercanos) con 12.4 segundos a comparación de los 15.21 segundos del árbol de decisiones por separado (p. 22). Además, Zamorano (2018) mencionó que el tiempo de predicción del algoritmo de árbol de decisiones tiene un promedio de 9 ms (p. 106).

II. MARCO TEÓRICO

En este capítulo se muestra los antecedentes relacionados a la investigación con estudios nacionales e internacionales donde revelan los beneficios de utilizar algoritmos de Machine Learning para el diagnóstico dermatológico para cáncer de piel de tipo melanoma, como herramienta de apoyo a las técnicas de diagnóstico convencionales, en estos trabajos se detallaron los algoritmos usados en cada investigación, los procesos para la clasificación de las imágenes dermatoscópicas, los conceptos referente al algoritmo, diagnóstico y fórmulas, y los resultado de la sensibilidad y especificidad del diagnóstico.

Rangel et al. (2019) mencionaron que su investigación que tuvo como objetivo el colaborar con un resultado mucho más eficaz en el diagnóstico preliminar de cáncer de piel tipo melanoma, en el diseño metodológico usaron tres técnicas y cada una de ellas, con una RNC (red neuronal convolucional) en la primera técnica se usaron 1,200 fotografías de melanoma para su clasificación, a la mitad de ellas le añadieron metadatos (edad, sexo, ubicación del melanoma, etc.) (p. 16).

En la segunda técnica, se utilizó OpenCV para quitar la piel de las fotografías, y analizaron 400 fotografías, finalmente en su tercera técnica, se asignaron parámetros de medición como longitud, altura, filtros para analizar y clasificar 1,200 imágenes (Rangel et al., 2019, p. 16). Se concluyó que se puede obtener un mejor resultado utilizando la metadata de las imágenes, por lo cual llegaron a la conclusión que la red neuronal no requiere de un preprocesamiento en las imágenes para tener un mejor resultado, sino usar la mayor cantidad de imágenes para el entrenamiento del sistema, se obtuvo 92.54% de precisión en el diagnóstico; para futuras investigaciones recomiendan usar CNN ya entrenadas, para llegar al nivel de entrenamiento clínico (Rangel et al., 2019, p. 19).

González, Jofre, Podlipnik, y Comalia (2020) demostraron que las limitaciones actuales del uso del aprendizaje automático para el diagnóstico de melanoma; el objetivo principal fue mencionar las limitaciones existentes del uso de fotografías digitales para el diagnóstico de enfermedades (p. 314). Se utilizaron 2,849 imágenes de tumores cutáneos de alta calidad obtenidas desde

2010 al 2014, el cual cada imagen fue calificada según las condiciones del Machine Learning (González et al., 2020, p. 313).

Con esto pudieron concluir que ML se convertirá en una gran herramienta para los dermatólogos, puesto que el sistema tuvo más del 96% de coincidencia de decisión que el dermatólogo especialista, pero las limitaciones no permiten superar grandes expectativas, de la data de 2,849 imágenes, se concluyó que sólo 900 de ellas, estaban aptas para usarlas en el proceso de entrenamiento (González et al., 2020, p. 314). Para investigaciones futuras, indican usar una base de datos de imágenes más numerosa para poder superar esas limitaciones (González et al., 2020, p. 315).

Serrano (2017) evaluó un sistema que detecta este tipo de cáncer a edad temprana de su evolución. Se planteó el desarrollo del sistema con el software Matlab, este sistema se encargó de clasificar las imágenes extrayendo características mediante redes neuronales y así clasificar en melanomas benignos o malignos; adicionalmente, el resultado de precisión fue de 92.3% y sobre los clasificadores se puede concluir que los algoritmos máquinas de vectores soporte y vecinos cercanos próximos son muy parejos en los resultados, a comparación del árbol de decisiones que no se obtuvieron los resultados estimados (p. 15). Además, Solano (2017) recomendó usar mayor número de datos médicos para mejores resultados en el diagnóstico (p. 12).

Mejía y Alzate (2016) mencionaron que dentro de su metodología usaron técnicas de segmentación por color y características discriminantes según los tipos de anormalidad, en cada célula detectada; se logró un 96% de precisión, resultado con el cual indican superar el resultado en su literatura (p. 31). Además, Mejía et al. (2016) recomendaron para trabajos futuros el uso de una data de imágenes microscópicas mayor, a fin de lograr que el entrenamiento de la red neuronal sea más intenso y la clasificación, más acertada (p. 33).

Rastgoo, García, Morel, y Marzani (2015) indicaron que su objetivo principal fue desarrollar un marco automático para la diferenciación del melanoma de los nevus displásicos; en su metodología ellos propusieron la combinación y comparación de varias características de textura, color y forma

basadas en la regla ABCDE del melanoma (p. 44). Se logró obtener una sensibilidad del 96% y especificidad del 70%; para trabajos futuros, recomendaron brindar tratamiento previo a las imágenes a fin de eliminar las no aptas para el análisis de la base, y así poder obtener un resultado de especificidad más preciso (Rastgoo et al., 2015, p. 44).

Coronado (2018) señaló que su objetivo en el desarrollo una red neuronal para la detección de cáncer en la piel mediante fotos no dermatológicas, se utilizaron 900 imágenes para el entrenamiento y validación del sistema; se concluyó que su método elaborado si cumple clasificando la enfermedad cutánea, pero esta no llegó a mejorar el diagnóstico de dicha enfermedad, obtuvo un 52% de precisión (p. 7). Asimismo, Coronado (2018) recomendó que para los trabajos futuros desarrollar un método para la extracción de patrones en imágenes de cáncer de piel, y también recomienda usar una mayor cantidad de imágenes para el aprendizaje del sistema (p. 7).

Campos y Mundaca (2016) indicaron que el objetivo de su investigación fue encontrar la técnica más precisa para el diagnóstico de melanoma, la investigación es considerada por su metodología como cuasi experimental, para el entrenamiento utilizaron imágenes de la página web www.dermquest.com, obtuvieron una precisión diagnóstica del 87.33% (p. 5). Guerequeta y Vallecillo (2000) mencionaron que el algoritmo es un método preciso que puede resolver algún problema; la algoritmia es uno de los pilares de la programación y su relevancia se muestra en el desarrollo de cualquier aplicación, más allá de la mera construcción de programas (p. 19).

En relación con las tecnologías mencionadas y utilizadas en la investigación se puede mencionar al clasificador de Naive Bayes. Al respecto, Ramos (2019) mencionó que las redes bayesianas se utilizan más para tareas de clasificación, dentro de las redes bayesianas hay gráficos acíclicos dirigidos que tienen un solo padre (que representa el nodo no observado) y varios hijos (correspondientes a los nodos observados) con una fuerte suposición de independencia entre los nodos hijos en el contexto de su padre (p. 10).

Sobre el clasificador de árbol de decisiones se menciona al respecto, Ramírez y Grandón (2018) que la clasificación basada en árboles de decisión (CBAD) es probablemente una de las técnicas de minería de datos (MD) más utilizadas, como parte de un grupo de modelos analíticos orientados a realizar predicciones, esta técnica no paramétrica clasifica una población en un modelo de segmentos de tipo ramas que construyen un árbol invertido, y luego este modelo se utiliza para predecir una variable objetivo (p. 4).

Las principales ventajas se asocian a que puede manejar eficientemente grandes y complejos conjuntos de datos, y a su vez, es fácil de usar y sus resultados sencillos de entender (Ramírez et al., 2018, p. 4). También se menciona del clasificador de redes neuronales. Al respecto, Sánchez (2015) mencionó que una red neuronal artificial es un conjunto de algoritmos matemáticos que procesan información y encuentran relaciones no lineales entre el conjunto de datos (p. 117).

Los especialistas de la RAE (2020) mencionaron que el diagnóstico es una recolección de datos para poder analizarlo y así evaluar problemas que se presentan; en la medicina un diagnóstico determina los caracteres de una enfermedad mediante evaluaciones de los signos que presenta (π 3-4). Por otro lado, los especialistas de la RAE (2020) indicaron que el término preliminar es una acción que antepone o antecede ante una situación (π 1).

Capurro y Abella (2007) indicaron que las fases o etapas que realiza para un diagnóstico correcto son los siguientes: generación de hipótesis diagnósticas (Se plantea una hipótesis de la enfermedad que podría tener el paciente) refinamiento de las hipótesis diagnósticas (en esta etapa se ejecuta evaluaciones para corroborar la hipótesis planteada en el paso anterior) y verificación del diagnóstico (en este paso se confirma las hipótesis mediante un descarte, a esto se le denomina “umbrales de decisión”, y así llegar a la conclusión de las hipótesis planteadas) (p. 3).

La precisión del diagnóstico ayuda a evaluar los resultados. Por lo tanto, Zipes, Libby, Bonow, Mann, y Tomaselli (2019) concluyeron que la precisión del diagnóstico es el porcentaje de resultados verdaderos de la prueba (verdaderos

positivos totales, más verdaderos negativos totales) entre todas las pruebas realizadas; en la precisión diagnóstica influyen, además, los criterios utilizados para determinar si se ha alcanzado un nivel de esfuerzo adecuado (p. 79).

La sensibilidad es el porcentaje de sujetos con una enfermedad que presentan resultados anómalos en la prueba (Zipes, et al., 2019, p. 79). Por otro lado, es la medición para poder identificar quién tiene la enfermedad a tratar (Celentano y Szko, 2019, p. 93). Además, la especificidad se define como el porcentaje de personas sin enfermedad que presentan resultados normales en la prueba (Zipes, et al., 2019, p. 80). Por otro lado, es la medición para poder identificar quién no tiene la enfermedad a tratar (Celentano et al., 2019, p. 93).

Castañeda y Eljure (2016) mencionaron que el cáncer de piel es uno de los tumores con mayor incidencia en el ser humano, por lo que se le debe de dar la importancia que se merece en la enseñanza del médico general, ya que en la mayoría de los casos es prevenible y curable; existen dos tipos de cáncer de piel: el no melanoma y el melanoma (p.7). El pronóstico de curación dependerá de la detección precoz y la correcta extirpación; refirieron que el melanoma es el cáncer cutáneo más peligroso, se origina en los melanocitos (células productoras de pigmento) (Castañeda et al., 2016, p. 7).

Los factores de riesgo del melanoma son: piel blanca, historia de quemadura solar, exposición excesiva a luz UV, vivir en lugares con mayor, múltiples nevus y nevus atípicos, historia familiar de melanoma, inmunosupresión, edad (Castañeda et al., 2016, p. 9). Los signos tempranos de melanoma quedan resumidos en el acrónimo ABCDE donde: A de asimetría, B = bordes irregulares o mal definidos, C de color heterogéneo, D de diámetro mayor a 6 mm, E de evolución, cualquier cambio en el tamaño, forma, color o la aparición de algún signo como sangrado, ulceración o la referencia de dolor o prurito deben ser considerados signos de alerta (Castañeda et al., 2016, p. 9).

Rangel et al. (2019) mencionaron: “El melanoma maligno es un término similar para llamar al cáncer de piel muy peligroso, esta tiene una tasa de curación si es diagnosticado en una etapa muy temprana” (p. 16).

Adicionalmente, Rangel et al. (2019) indicaron: “El melanoma benigno es simplemente otra palabra para designar un lunar o nevus / nevus, muchas personas tienen un montón de estos en su piel, y si bien representan la posibilidad de cambiar y convertirse en malignos, nunca podrán hacerlo” (p. 17).

III. METODOLOGÍA

En este capítulo se explica que esta investigación fue de tipo aplicada, con enfoque cuantitativo y diseño pre-experimental. También se precisan los indicadores de medición, estos son sensibilidad, especificidad, precisión, exactitud y tiempo. Asimismo, se determinó la población basada en las fotografías dermatoscópicas del repositorio ISIC y los factores para la selección.

Finalmente se realizó aplicación del algoritmo fusionado para la detección de melanoma cutáneo basado en los algoritmos de redes neuronales, Naive Bayes y árbol de decisiones en la muestra. Además, se explicó las técnicas e instrumentos para seleccionar la muestra y elegir la unidad de muestreo e indicar el conjunto de procedimientos y actividades que se realizaron para medir la variable, las dimensiones, los indicadores y analizarlos. Asimismo, se optó por los Códigos de Ética de la Universidad César Vallejo, el Colegio de Ingenieros del Perú y a los principios de la Bioética. A continuación, se detallará lo mencionado.

3.1 Tipo y diseño de investigación

El tipo de investigación es aplicada y corresponde al enfoque cuantitativo, se determinó que corresponde a la investigación aplicada, ya que para el desarrollo del proyecto se utilizaran teorías y algoritmos de aprendizaje profundo ya definidos y usados por distintos autores en el mundo para el diagnóstico de enfermedades (Niño, 2011, p. 29). La investigación aplicada se caracteriza por que busca usar conocimientos ya adquiridos a la vez que se adquieren otros, posteriormente de implementar y sistematizar la práctica basada en investigación (Murillo, 2018, p. 24).

El enfoque de esta investigación fue cuantitativo, ya que se siguió una secuencia de pasos para cada fase, se delimitaron los objetivos, literatura para la recolección de datos, y el marco teórico que contiene investigaciones de diagnóstico de enfermedades basando en deep learning, se planteó las hipótesis y variables con un plan para medirlas, obtener resultados y conclusiones (Niño, 2011, p. 29). El enfoque cuantitativo usa la recolección de datos para probar las hipótesis, se basa en el análisis estadístico y la medición numérica para definir pautas de comportamiento, y demostrar teorías (Hernández y Mendoza, 2017, p. 9).

El diseño de la investigación es pre-experimental, de post prueba con un solo grupo. Se determinó solo una variable: efectividad del algoritmo fusionado basado en los algoritmos de árbol de decisiones, Naive Bayes y redes neuronales. Para obtener los resultados del experimento se seguirán las pautas que corresponden al diseño pre experimental, aplicando post test a un único grupo. Además, Campbell, y Stanley (1973) mencionaron que el diseño de estudio de caso con una sola medición; en este diseño se estudia a un grupo que ha sido sometido (por el experimentador o su ambiente) una variable independiente, existiendo una sola medición posterior (post test) a dicha prueba (p. 54).

3.2 Variables y operacionalización

Se determinó que la variable de la investigación corresponde al enfoque cuantitativo: efectividad del algoritmo fusionado basado en los algoritmos de árboles de decisión, Naive Bayes y redes neuronales (González et al., 2020, p. 313). El procedimiento del algoritmo de diagnóstico preliminar para la detección de melanoma cutáneo es el de clasificar automáticamente imágenes dermatoscópicas a partir del reconocimiento y clasificación de patrones el cual puede alcanzar una precisión diagnóstica similar a la de un dermatólogo. Celentano et al. (2019) mencionaron que la sensibilidad es la medición para poder identificar quién tiene la enfermedad a tratar (p. 93). Además, Celentano et al. (2019) mencionaron que la especificidad es la medición para poder identificar quién no tiene la enfermedad a tratar (p. 93).

Celentano et al. (2015) señalaron que la exactitud es la medición para identificar la cantidad de predicciones positivas que fueron correctas (p. 93). Además, Celentano et al. (2015) mencionaron que la precisión es la medición para determinar la calidad del modelo de clasificación (p. 93). También, González et al. (2020) indicaron que el tiempo es la medición para determinar la demora en clasificación de los algoritmos y que las escalas de medición de esta variable son de razón (p. 315). Como se muestra en la tabla 10 del Anexo 2, con respecto a la definición operacional, esto se fundamenta que se aplicará los resultados de sensibilidad, especificidad, precisión, exactitud y tiempo en la detección de melanoma cutáneo considerando la cantidad a evaluar.

3.3 Población, muestra y muestreo

3.3.1 Población

Se consideró que la población es la totalidad de las imágenes obtenidas del repositorio Archive ISiC Gallery, suman un total de 3 mil fotografías dermatoscópicas, las cuales contienen sus características más relevantes en una meta data (Banerjee et al., 2020, p. 22). En la tabla 1 se señala el criterio de inclusión y exclusión de la población, esto tiene el fin de poder identificar las fotografías dermatoscópicas como melanomas y nevus, ya que estos son casi idénticos pero los melanomas tienen un conjunto de características propias.

Tabla 1 Criterios de inclusión y exclusión de la población

Inclusión:
<ul style="list-style-type: none">Las imágenes definidas como población cumplen con los requerimientos del ABCD del melanoma.
Exclusión:
<ul style="list-style-type: none">Si la imagen no cumple con los requerimientos para ser considerado melanoma o nevus, entonces no deberá ser considerada parte de la población.

3.3.2 Muestra y muestreo

El tamaño de una muestra se define basado de dos criterios: recursos y requerimientos que tenga el análisis de la investigación, por ello una sugerencia es seleccionar la muestra mayor admisible, mientras más representativa sea la muestra, menor será el margen de error (Tovar, 2000, p. 5).

Se define que la muestra de esta investigación lo conforman la totalidad de las imágenes de melanoma y nevus de la galería ISiC (3 mil fotografías digitales), por ello podemos indicar que la muestra es igual a la población. En caso de esta investigación preexperimental será de tipo no probabilístico y la muestra se determinó por conveniencia ya que resulta fundamental el uso total de las fotografías digitales para el entrenamiento de los algoritmos y su validación; además, Niño (2011) concluyó que las muestras seleccionadas buscan representar a la población (p. 57).

Unidad de análisis: La unidad de análisis es cada unidad de las fotografías de melanoma cutáneo y nevus que integran la galería ISIC.

En la tabla 2 se presenta la descripción de la data de las fotos dermatoscópicas de melanomas y nevus.

Tabla 2 Tipo y cantidad de imágenes dermatoscópicas

	Tipo	Muestreo	Muestras
Dataset ISIC	Melanoma	1.632	1.632
	Nevus	1.368	1.368
Total, de imágenes		3.000	

3.4 Técnicas e instrumentos de recolección de datos

Para esta investigación se utiliza como técnica de recolección de datos, el análisis documental, ya que se requiere recopilar información de trabajos ya realizados en el Perú y el mundo, el cual se detalla en el documento de estado del arte, las imágenes de las lesiones de melanoma y la metadata correspondiente a cada fotografía (edad, sexo, medidas del melanoma y ubicación del melanoma).

Como instrumento de recolección de datos, se utilizó la ficha de registro. Al respecto, Fernández (2015) concluyó que: “El seleccionar técnicas e instrumentos para la recolección de datos debe estar sincronizado con las características del estudio que se desea investigar” (p. 43). Al usar la técnica de recolección de datos se debe analizar y considerar la información de las investigaciones que contienen datos de interés relacionados a la investigación (Fernández, 2015, p 43).

Validez de contenido

Ding y Hershberger (2002) mencionaron que la validez de contenido normalmente se evalúa a través de un juicio de expertos, y en muy algunas oportunidades la evaluación está basada en datos empíricos (p. 385). Se considera que la opinión informada de personas con experiencia en el tema, que

son reconocidas por otros profesionales como expertos cualificados, puede dar información, juicios y valoraciones (Ding et al., 2002, p. 385).

La validez para identificar a los pacientes que tienen la enfermedad o no la poseen está constituida por dos componentes las cuales se medirán por medio de la sensibilidad y especificidad respectivamente (Celentano et al., 2015, p.89).

3.5 Procedimientos

Las fotografías digitales de melanoma cutáneo, nevus y su respectiva metadata fueron extraídas de la galería ISIC, las cuales son de uso público para la investigación. La galería se puede visitar en el siguiente enlace: <https://www.isic-archive.com>. Se utilizó la ficha de registro, para analizar y consultar estudios anteriores, el cual fue entregado al especialista para su validación. Los datos registrados en la ficha son:

- Código de fotografía digital
- Ubicación
- Clasificación (diagnóstico)
- Sexo
- Píxeles.

Al tener el algoritmo para el pre-procesamiento de las tres mil fotografías dermatoscópicas se pudo extraer las características de ABCD para detectar los melanomas y nevus. Obtenido la asimetría, bordes irregulares, colores y diámetro se podrá determinar los melanomas de los nevus; sumando estas características se podrá sacar un diagnóstico y poder comparar los resultados de la metadata con el algoritmo; con esos resultados se calculó para poder obtener la sensibilidad, especificidad, exactitud, precisión y el tiempo de los diagnósticos.

3.6 Métodos de análisis de datos

Se analizaron los siguientes indicadores: sensibilidad, especificidad, exactitud, precisión y tiempo. Los resultados obtenidos de la aplicación fueron insertados en las tablas mostradas y se aplicaron sus respectivas fórmulas para obtener los porcentajes de cada indicador con respecto a cada uno de los algoritmos. Se

utilizó la misma aplicación para los cálculos de los indicadores que fueron tabulados en MS Excel.

3.7 Aspectos éticos

Molina y Ramírez (2013) mencionaron que con el avance constante de la ciencia, el hombre tiende a olvidar sus valores y principios, manifestando falta de empatía y criterio, cabe mencionar que la bioética, nace como respuesta hacia aquellas preguntas que se manifiestan en la medicina y biología, procurando siempre que el avance tecnológico no afecte de forma negativa no sólo al hombre, sino también a la vida vegetal y animal (p. 291). Además, Insua (2018) indicó que en los principios de la ética biomédica se menciona la beneficencia, el cual consiste en hacer el bien y se busca la orientación correcta de los tratamientos, para la búsqueda del beneficio del paciente y se ve reflejado en la prevención de enfermedades o restauración de la salud (p. 231).

En el Código de Ética, capítulo III, artículo 29 del Colegio de Ingenieros del Perú se detalla lo siguiente: “El Ingeniero adquiere un compromiso con la comunidad que debe guiar su actividad profesional a fin de contribuir al estricto cumplimiento de sus obligaciones, a la cabal entrega de sus conocimientos y al proceder honrado donde sea requerido profesionalmente, puesto que se acepta el bienestar y la salud de la sociedad sin un interés lucrativo, se reconoce la seguridad de la vida, salud, bienes y bienestar de la población y de la evolución tecnológica de la nación y se cumplió la elevada misión de guardar y mejorar los recursos naturales y urbanos para una mejor calidad de vida de los habitantes” (Colegio de Ingenieros del Perú, 2018, p. 7).

Esta investigación respeta y cumple los principios éticos indicados en el Informe Belmont: (a) beneficencia (se podrá prevenir el melanoma cutáneo mediante el algoritmo, a la vez así poder tener beneficio y evitar un futuro daño a futuros pacientes), (b) no maleficencia (no se ha provocado ningún daño a ningún individuo en el desarrollo del algoritmo), (c) autonomía (todo paciente diagnosticado se verá de manera autónoma con su toma de decisión luego del resultado) y (d) justicia (hay parcialidad en el diagnóstico sin discriminación

alguna). Se respeta la autoría de las fuentes de información utilizadas en esta investigación citando apropiadamente (Ramírez, 2013, p. 27).

Asimismo, se brindó la autorización por escrito para las distintas publicaciones y la fomentación de la autoría responsable indicados en los incisos a y b del artículo 7 (Universidad César Vallejo, 2020, p. 8). Además esta investigación cumple con el artículo 9 y 11 del Código de Ética de Investigación de la Universidad César Vallejo en el cual se mencionan las políticas de anti-plagio, para el cual se utilizó un software que proporciona el índice de similitud con otras fuentes de consulta y sobre la propiedad intelectual respectivamente. (Universidad César Vallejo, 2020, p. 10).

VI. RESULTADOS

En este capítulo se detalla los resultados que se lograron dentro de la investigación haciendo mención en los indicadores precisión, sensibilidad, especificidad, exactitud y tiempo de clasificación. Asimismo, se realizó el procesamiento del dataset-melanoma, del cual se analizó los resultados del algoritmo fusionado en comparación a los algoritmos redes neuronales, árbol de decisiones y Naive Bayes.

4.1. Cálculo de los indicadores

El escenario óptimo requerido es un modelo en el cual los resultados sean de 0 falsos positivos y 0 falsos negativos, sin embargo, ello no sucede en la vida real, ya que en la mayoría de los casos ningún modelo es 100% exacto (Celentano et al., 2015, p. 101). A continuación, se muestran los resultados de las pruebas para los indicadores con el algoritmo fusionado, redes neuronales, Naive Bayes y árbol de decisiones. Esta prueba se realizó con un total de tres mil imágenes.

4.1.1. Cálculo de los indicadores con 3 mil fotografías con el algoritmo de redes neuronales

En la tabla 3 se aprecia los resultados con 3 mil fotografías dermatoscópicas del repositorio ISIC donde se indica que de 2222 verdaderos VP: 1265, FP: 957, y de 778 falsos FN: 411, VN: 367; luego de procesar la data en el aplicativo web con el algoritmo redes neuronales, la matriz de confusión nos mostró el resultado con precisión de 1632 melanomas y 1368 nevus. En esta tabla de matriz de confusión se mostraron los porcentajes de los indicadores sensibilidad, especificidad, precisión, exactitud y tiempo de diagnóstico.

Tabla 3 Matriz de confusión – diagnóstico con 3 mil fotografías dermatoscópicas fotografías con el algoritmo de redes neuronales

		Predicción				
		Verdadero	Falso	total	Prueba de funcionamiento	
Actual	Positivo	1265	367	1632	0.77518747	Melanoma
	Negativo	957	411	1368	0.69960325	Nevus
	total	2,222	778	3000	Tiempo	0.16 ms
Prueba de laboratorio		0.754814549	0.722879495		0.74072106	

Donde:

Del análisis de la matriz de confusión se obtuvo los siguientes resultados:

- Sensibilidad: 75.48%
- Especificidad: 72.28%
- Exactitud: 74.07%
- Precisión: 77.51%
- Tiempo de clasificación: 0.16 ms.

4.1.2. Cálculo de los indicadores con 3 mil fotografías con el algoritmo de Naive Bayes

En la tabla 4 se aprecia los resultados con 3 mil fotografías dermatoscópicas del repositorio ISIC donde se indica que 2078 verdaderos VP: 1081, FP: 998 y de 922 falsos FN: 370, VN: 551; luego de procesar la data en el aplicativo web con el algoritmo Naive Bayes, la matriz de confusión nos mostró el resultado con precisión de 1632 melanomas y 1368 nevus. En esta tabla de matriz de confusión se mostraron los porcentajes de los indicadores sensibilidad, especificidad, precisión, exactitud y tiempo de diagnóstico.

Tabla 4 Matriz de confusión – diagnóstico con 3 mil fotografías dermatoscópicas fotografías con el algoritmo de Naive Bayes

		Predicción			Prueba de funcionamiento	
		Verdadero	Falso	total		
Actual	Positivo	1081	551	1632	0.662095070	Melanoma
	Negativo	998	370	1368	0.729346484	Nevus
	total	2078	922	3000	Tiempo	0.15 ms
Prueba de laboratorio		0.744792008	0.644036656		0.692761715	

Donde:

Del análisis se tiene los siguientes resultados:

- Sensibilidad: 74.50%
- Especificidad: 64.43%
- Exactitud: 69.30%

- Precisión: 66.24%
- Tiempo de clasificación: 0.15 ms

4.1.3. Cálculo de los indicadores con 3 mil fotografías con el algoritmo de árbol de decisiones

En la tabla 5 se aprecia los resultados con 3 mil fotografías dermatoscópicas del repositorio ISIC donde se indica que de 2,885 verdaderos VP: 1544, FP: 88 y de 115 falsos FN: 27, VN: 88 después de procesar la data en el aplicativo web con el algoritmo árbol de decisiones, la matriz de confusión nos mostró el resultado con precisión de 1632 melanomas y 1368 nevus. En esta tabla de matriz de confusión se mostraron los porcentajes de los indicadores sensibilidad, especificidad, precisión, exactitud y tiempo de diagnóstico.

Tabla 5 Matriz de confusión – diagnóstico con 3 mil fotografías dermatoscópicas fotografías con el algoritmo de árbol de decisiones.

		Predicción			Prueba de funcionamiento	
		Verdadero	Falso	total		
Actual	Positivo	1544	88	1632	0.946303491	Melanoma
	Negativo	1341	27	1368	0.980240461	Nevus
	total	2885	115	3000	Tiempo	0.16 ms
Prueba de laboratorio		0.982798092	0.938658406		0.961778749	

Donde:

Del análisis se tiene los siguientes resultados:

- Sensibilidad: 98.28%
- Especificidad: 93.84%
- Exactitud: 96.17%
- Precisión: 94.61%
- Tiempo de clasificación: 0.16 ms

4.1.4. Cálculo de los indicadores con 3 mil fotografías con el algoritmo fusionado

En la tabla 6 se aprecia los resultados con 3 mil fotografías dermatoscópicas del repositorio ISIC donde se indica que 2842 verdaderos VP: 1525, FP: 1317, y 158 falsos FN: 51, VN: 107; luego de realizar la evaluación con el algoritmo mediante la matriz de confusión, se mostró el resultado con precisión de 1632 melanomas y 1368 nevus. En esta tabla de matriz de confusión se indicó los porcentajes de los indicadores sensibilidad, especificidad, precisión, exactitud y tiempo de diagnóstico.

Tabla 6 Matriz de confusión – *diagnóstico con 3 mil fotografías dermatoscópicas fotografías con el algoritmo fusionado*

		Predicción				Prueba de funcionamiento	
		Verdadero	Falso	total			
Actual	Positivo	1525	107	1632	0.934354115	Melanoma	
	Negativo	1317	51	1368	0.962867312	Nevus	
	total	2842	158	3000	Tiempo	0.16 ms	
	Prueba de laboratorio	0.967761188	0.924783168		0.947356133		

Donde:

Del análisis tenemos los siguientes resultados:

- Sensibilidad: 96.76%
- Especificidad: 92.49%
- Exactitud: 94.73%
- Precisión: 93.44%
- Tiempo: 0.16 ms

La tabla 7 mostrará la comparación en porcentaje de los indicadores de sensibilidad, especificidad, precisión, exactitud y tiempo de clasificación entre los algoritmos redes neuronales, Naive Bayes, árbol de decisiones y algoritmo fusionado.

Tabla 7 Comparación en porcentaje de los indicadores de sensibilidad, especificidad, precisión, exactitud y tiempo entre los algoritmos redes neuronales (RN), Naive Bayes (NB), árbol de decisiones (AD) y algoritmo fusionado (AF)

	VP	VN	FP	FN	Sensibilidad	Especificidad	Exactitud	Precisión	Tiempo
NB	1081	998	551	370	74.50 %	64.43 %	69.30 %	66.24 %	0.15 ms
AD	1544	1341	88	27	98.28 %	93.84 %	96.17 %	94.61 %	0.16 ms
RN	1265	957	367	411	75.48 %	72.28 %	74.07 %	77.51 %	0.16 ms
AF	1525	1317	107	51	96.76 %	92.49 %	94.73 %	93.44 %	0.16 ms

4.2. Prueba de hipótesis

A continuación, se muestra las pruebas de hipótesis para cada una de las 15 hipótesis de la investigación realizada.

4.2.1. Hipótesis específica HE1

HE1₀: La sensibilidad del algoritmo fusionado no fue mayor a la obtenida por el algoritmo redes neuronales.

HE1₁: La sensibilidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo redes neuronales.

Como se puede observar en la tabla 7, la sensibilidad fue 75.48% para el algoritmo de redes neuronales y 96.76% para el algoritmo fusionado. Por lo tanto, la sensibilidad del algoritmo fusionado fue mayor a la sensibilidad del algoritmo de redes neuronales, con lo que se acepta la hipótesis alternativa.

4.2.2 Hipótesis específica HE2

HE2₀: La sensibilidad del algoritmo fusionado no fue mayor a la obtenida por el algoritmo Naive bayes.

HE2₁: La sensibilidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo Naive bayes.

Como se puede observar en la tabla 7, la sensibilidad fue 74.50% para el algoritmo de Naive Bayes y 96.76% para el algoritmo fusionado. Por lo tanto, la sensibilidad del algoritmo fusionado fue mayor a la sensibilidad del algoritmo de redes neuronales, con lo que se acepta la hipótesis alternativa.

4.2.3. Hipótesis específica HE3

HE3₀: La sensibilidad del algoritmo fusionado no fue mayor a la obtenida por el algoritmo árboles de decisión.

HE3₁: La sensibilidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo árboles de decisión.

Como se puede observar en la tabla 7, la sensibilidad fue 98.28% para el algoritmo de árbol de decisiones y 96.76% para el algoritmo fusionado. Por lo tanto, la sensibilidad del algoritmo fusionado no fue mayor a la sensibilidad del algoritmo árbol de decisiones, con lo que se acepta la hipótesis nula.

4.2.4. Hipótesis específica HE4

HE4₀: La especificidad del algoritmo fusionado no fue mayor a la obtenida por el algoritmo redes neuronales.

HE4₁: La especificidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo redes neuronales.

Como se puede observar en la tabla 7, la especificidad fue 72.28% para el algoritmo de redes neuronales y 92.49% para el algoritmo fusionado. Por lo tanto, la especificidad del algoritmo fusionado fue mayor a la especificidad del algoritmo de redes neuronales, con lo que se acepta la hipótesis alternativa.

4.2.5 Hipótesis específica HE5

HE5₀: La especificidad del algoritmo fusionado no fue mayor a la obtenida por el algoritmo Naive bayes.

HE5₁: La especificidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo Naive bayes.

Como se puede observar en la tabla 7, la especificidad fue 64.43% para el algoritmo de Naive Bayes y 92.49% para el algoritmo fusionado. Por lo tanto, la especificidad del algoritmo fusionado fue mayor a la especificidad del algoritmo de Naive Bayes, con lo que se acepta la hipótesis alternativa.

4.2.6. Hipótesis específica HE6

HE6₀: La especificidad del algoritmo fusionado no fue mayor a la obtenida por el algoritmo árboles de decisiones.

HE6₁: La especificidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo árboles de decisiones.

Como se puede observar en la tabla 7, la especificidad fue 93.84% para el algoritmo de árbol de decisiones y 92.49% para el algoritmo fusionado. Por lo tanto, la especificidad del algoritmo fusionado no fue mayor a la especificidad del algoritmo de árbol de decisiones, con lo que se acepta la hipótesis nula.

4.2.7. Hipótesis específica HE7

HE7₀: La exactitud del algoritmo fusionado no fue mayor a la obtenida por el algoritmo redes neuronales.

HE7₁: La exactitud del algoritmo fusionado fue mayor a la obtenida por el algoritmo Redes neuronales.

Como se puede observar en la tabla 7, la exactitud fue 74.07% para el algoritmo de redes neuronales y 94.73% para el algoritmo fusionado. Por lo tanto, la exactitud del algoritmo fusionado fue mayor a la exactitud del algoritmo de redes neuronales, con lo que se acepta la hipótesis alternativa.

4.2.8. Hipótesis específica HE8

HE8₀: La exactitud del algoritmo fusionado no fue mayor a la obtenida por el algoritmo Naive bayes.

HE8₁: La exactitud del algoritmo fusionado fue mayor a la obtenida por el algoritmo Naive bayes.

Como se puede observar en la tabla 7, la exactitud fue 69.30 % para el algoritmo de Naive bayes y 94.73% para el algoritmo fusionado. Por lo tanto, la exactitud del algoritmo fusionado fue mayor a la exactitud del algoritmo de Naive Bayes, con lo que se acepta la hipótesis alternativa.

4.2.9. Hipótesis específica HE9

HE9₀: La exactitud del algoritmo fusionado no fue mayor a la obtenida por el algoritmo árboles de decisión.

HE9₁: La exactitud del algoritmo fusionado fue mayor a la obtenida por el algoritmo árboles de decisión.

Como se puede observar en la tabla 7, la exactitud fue 96.17% para el algoritmo de árbol de decisión y 94.73% para el algoritmo fusionado. Por lo tanto, la sensibilidad del algoritmo fusionado no fue mayor a la sensibilidad del algoritmo de redes árbol de decisiones, con lo que se acepta la hipótesis nula.

4.2.10. Hipótesis específica HE10

HE10₀: La precisión del algoritmo fusionado no fue mayor a la obtenida por el algoritmo redes neuronales.

HE10₁: La precisión del algoritmo fusionado fue mayor a la obtenida por el algoritmo redes neuronales

Como se puede observar en la tabla 7, la precisión fue 77.51% para el algoritmo de redes neuronales y 93.44% para el algoritmo fusionado. Por lo tanto, la precisión del algoritmo fusionado fue mayor a la precisión del algoritmo de redes neuronales, con lo que se acepta la hipótesis alternativa.

4.2.11. Hipótesis específica HE11

HE11₀: La precisión del algoritmo fusionado no fue mayor a la obtenida por el algoritmo Naive Bayes.

HE11₁: La precisión del algoritmo fusionado fue mayor a la obtenida por el algoritmo Naive Bayes.

Como se puede observar en la tabla 7, la precisión fue 66.24% para el algoritmo de Naive Bayes y 93.44% para el algoritmo fusionado. Por lo tanto, la precisión del algoritmo fusionado fue mayor a la precisión del algoritmo de redes neuronales, con lo que se acepta la hipótesis alternativa.

4.2.12. Hipótesis específica HE12

HE12₀: La precisión del algoritmo fusionado no fue mayor a la obtenida por el algoritmo árbol de decisiones.

HE12₁: La precisión del algoritmo fusionado fue mayor a la obtenida por el algoritmo árbol de decisiones.

Como se puede observar en la tabla 7, la precisión fue 94.61% para el algoritmo árbol de decisiones y 93.44% para el algoritmo fusionado. Por lo tanto, la precisión del algoritmo fusionado no fue mayor a la precisión del algoritmo de árbol de decisiones, con lo que se acepta la hipótesis nula.

4.2.13. Hipótesis específica HE13

HE13₀: El tiempo de clasificación del algoritmo fusionado no fue menor al obtenido por el algoritmo redes neuronales.

HE13₁: El tiempo de clasificación del algoritmo fusionado fue menor al obtenido por el algoritmo redes neuronales.

Como se puede observar en la tabla 7, el tiempo de clasificación para el algoritmo de redes neuronales fue 0.16 ms y 0.16 ms para el algoritmo fusionado. Por lo tanto, el tiempo de clasificación del algoritmo fusionado no fue mayor al tiempo de clasificación del algoritmo redes neuronales, con lo que se acepta la hipótesis nula.

4.2.14. Hipótesis específica HE14

HE14₀: El tiempo de clasificación del algoritmo fusionado no fue menor al obtenido por el algoritmo Naive Bayes.

HE14₁: El tiempo de clasificación del algoritmo fusionado fue menor al obtenido por el algoritmo Naive Bayes.

Como se puede observar en la tabla 7, el tiempo de clasificación para el algoritmo de Naive Bayes fue de 0.15 ms y 0.16 ms para el algoritmo fusionado. Por lo tanto, el tiempo de clasificación del algoritmo fusionado no fue mayor al tiempo de clasificación del algoritmo Naive Bayes, con lo que se acepta la hipótesis nula.

4.2.15. Hipótesis específica HE15

HE15₀: El tiempo de clasificación del algoritmo fusionado no fue menor al obtenido por el algoritmo árboles de decisiones.

HE15₁: El tiempo de clasificación del algoritmo fusionado fue menor al obtenido por el algoritmo árboles de decisiones.

Como se puede observar en la tabla 7, el tiempo de clasificación para el algoritmo de árbol de decisiones fue 0.16 ms y 0.16 ms para el algoritmo fusionado. Por lo tanto, el tiempo de clasificación del algoritmo fusionado no fue mayor al tiempo de clasificación del algoritmo redes neuronales, con lo que se acepta la hipótesis nula.

4.3. Hipótesis general

HG₀: La sensibilidad, especificidad, precisión, exactitud y tiempo de clasificación del algoritmo fusionado no mejoraron con respecto a los algoritmos árbol de decisiones, Naive Bayes y redes neuronales.

HG₁: La sensibilidad, especificidad, precisión, exactitud y tiempo de clasificación del algoritmo fusionado mejoraron con respecto a los algoritmos árbol de decisiones, Naive Bayes y redes neuronales.

Luego de la revisión de las hipótesis específicas HE1, HE2, HE3, HE4 y HE5, HE6, HE7, HE8, HE9, HE10, HE11, HE12, HE13, HE14, HE15 se puede apreciar que solo se aceptó las hipótesis HE1, HE2, HE4, HE5, HE7, HE8, HE10 y HE11, por lo tanto, no se aceptó la hipótesis general.

4.4. Resumen de las comprobaciones de las hipótesis

En la tabla 13 se evidencia el resumen de los resultados de comprobación para las hipótesis de los indicadores en el cual las columnas muestran los códigos que hacen referencia a cada hipótesis, la segunda columna se define el resultado por cada indicador y finalmente la tercera columna indica si la hipótesis fue aceptada o rechazada.

Tabla 8 Tabla resumen de las hipótesis

Código	Hipótesis	Resultado
HE1	La sensibilidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo redes neuronales.	Aceptada
HE2	La sensibilidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo Naive bayes.	Aceptada
HE3	La sensibilidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo árboles de decisión.	Rechazada
HE4	La especificidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo redes neuronales.	Aceptada
HE5	La especificidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo Naive bayes.	Aceptada
HE6	La especificidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo árboles de decisión.	Rechazada
HE7	La exactitud del algoritmo fusionado fue mayor a la obtenida por el algoritmo redes neuronales.	Aceptada
HE8	La exactitud del algoritmo fusionado fue mayor a la obtenida por el algoritmo Naive Bayes.	Aceptada
HE9	La exactitud del algoritmo fusionado fue mayor a la obtenida por el algoritmo árboles de decisión	Rechazada
HE10	La precisión del algoritmo fusionado fue mayor a la obtenida por el algoritmo redes neuronales.	Aceptada
HE11	La precisión del algoritmo fusionado fue mayor a la obtenida por el algoritmo Naive Bayes.	Aceptada
HE12	La precisión del algoritmo fusionado fue mayor a la obtenida por el algoritmo árboles de decisión	Rechazada
HE13	El tiempo de clasificación del algoritmo fusionado fue menor al obtenido por el algoritmo redes neuronales.	Rechazada
HE14	El tiempo de clasificación del algoritmo fusionado fue menor al obtenido por el algoritmo Naive Bayes	Rechazada
HE15	El tiempo de clasificación del algoritmo fusionado fue menor al obtenido por el algoritmo árboles de decisión.	Rechazada
HG	La sensibilidad, especificidad, precisión, exactitud y tiempo de clasificación del algoritmo fusionado mejoraron con respecto a los algoritmos árboles de decisión, Naive Bayes y redes neuronales.	Rechazada

V. DISCUSIÓN

En general, el algoritmo fusionado obtuvo un efecto positivo en la precisión diagnóstica para la detección de melanoma cutáneo, ya que se logró 93% en precisión, 96.7% en sensibilidad, 92.7% en especificidad, 94.7% en exactitud y 0.16 ms en el tiempo para el diagnóstico preliminar de tres mil fotografías digitales de melanoma cutáneo. Con estos resultados se evidenció que los indicadores con el algoritmo fusionado muestran mayor efectividad en la sensibilidad, especificidad, precisión, exactitud y tiempo con la cantidad de imágenes establecidas para la investigación. A continuación, estos resultados se contrastaron con trabajos similares para cada indicador.

La sensibilidad de 96.7% del algoritmo fusionado fue mayor a la sensibilidad de redes neuronales que obtuvo 76.6%. Este resultado fue similar al resultado que obtuvieron Abbas et al. (2019), quienes realizaron un algoritmo fusionado basado en los algoritmos de redes neuronales y Fuzzy C-Means obteniendo un 90.1% de sensibilidad, a diferencia del 61.6% de redes neuronales ejecutadas por separado. El resultado de Abbas et al. (2019) fue menor al logrado en esta investigación, puesto que solo usaron un total de 120 fotografías digitales para el entrenamiento de su algoritmo y validación de sus resultados, mientras que en esta investigación se usó un total de 3 mil fotografías digitales para el entrenamiento y validación del algoritmo fusionado.

Asimismo, la sensibilidad del 96.7% del algoritmo fusionado fue mayor al resultado de Tejada et al. (2020), quienes obtuvieron 83.22% con el algoritmo de redes neuronales. El resultado fue mayor porque ellos usaron un total de 200 fotos digitales dermatoscópicas, a diferencia de este estudio en el cual se utilizaron un total de 3 mil fotografías dermatoscópicas para el entrenamiento y las pruebas del algoritmo.

La sensibilidad del algoritmo fusionado fue mayor con un 96.7% a comparación del algoritmo de Naive Bayes con un 77.1%. Este resultado fue similar al obtenido por Khan et al. (2019), quienes usaron un algoritmo fusionado basado en SVM, vecinos cercanos, Naive Bayes y árbol de Decisiones en el cual obtuvieron una sensibilidad del 97%, el cual fue mayor al algoritmo de Naive Bayes ejecutado por separado con un 78%. El resultado del algoritmo fusionado de Khan et al. (2019) fue menor al algoritmo fusionado de esta investigación por

que no consideraron extraer las características del ABCD del melanoma, como parámetros de entrada para el entrenamiento de su algoritmo y solo realizaron la extracción de las características bordes y diámetro.

El resultado de sensibilidad del algoritmo fusionado fue 96.7%, a diferencia del algoritmo de árbol de decisiones con un 98.1%. Este resultado fue mayor al resultado de Thepade et al. (2020), en el que su algoritmo fusionado estaba basado en SVM, árbol de decisiones y bosque aleatorio donde se obtuvo 84.51% y 72.58% del algoritmo de árbol de decisiones independiente. El resultado de Thepade et al. (2020) fue menor al estudio, puesto que usaron fotografías dermatoscópicas que consistían de 1,000 nevus y 1,000 melanomas para el entrenamiento de los algoritmos, siendo menor a la cantidad de fotografías utilizadas en esta investigación.

Adicionalmente, los resultados del estudio fueron similares al estudio de Khan et al. (2019), quienes obtuvieron un resultado de 97% de sensibilidad en su algoritmo fusionado, puesto que este estaba basado en los algoritmos en SVM, vecinos cercanos, Naive Bayes y árbol de decisiones y un 72% de sensibilidad del algoritmo de árbol de decisiones. Los resultados de Khan et al. (2019) fueron similares al logrado en esta investigación, ya que usaron el algoritmo de vecinos cercanos para una mejor clasificación de los diagnósticos y tener un mejor resultado, siendo este algoritmo colocado en prioridades para la clasificación de las imágenes dermatoscópicas.

Asimismo, los resultados de este estudio fueron similares al estudio de Banerjee et al. (2020), quienes obtuvieron 94.22% de sensibilidad con el algoritmo fusionado, el cual estuvo basado en los algoritmos de árbol de decisiones, SVM y vecinos cercanos y un 90.67% del algoritmo de árbol de decisiones. El valor de sensibilidad de este estudio fue mayor al de Banerjee et al. (2020), puesto que el estudio tuvo una cantidad de 3,000 fotos dermatoscópicas y una mejor extracción de características para la clasificación de melanomas y nevus.

La especificidad del algoritmo fusionado fue 92.7%, mayor a la obtenida por el algoritmo de redes neuronales con 70.3%. Estos resultados fueron

similares al obtenido por Abbas et al. (2019), quienes realizaron un algoritmo fusionado basado en redes neuronales y Fuzzy C-Means, obteniendo 84.4% de especificidad con el algoritmo de redes neuronales. La especificidad de este estudio fue mayor al de Abbas et al. (2019), puesto que en su estudio solo usaron un total de 206 imágenes de lesiones a la piel, donde 119 fueron melanomas y 87 de nevos. Asimismo, el algoritmo fusionado de este estudio obtuvo una mayor especificidad a la obtenida por Fariña (2016) con 80.76% mediante redes neuronales, puesto que en su estudio usaron un total de 95 capas de interacciones en las neuronas a comparación de las 500 capas usadas en el estudio.

El algoritmo fusionado obtuvo especificidad del 92.7%, mientras que el algoritmo de Naive Bayes obtuvo 61.5%. Estos resultados fueron similares al estudio de Khan et al. (2019), que realizaron un algoritmo fusionado basado en SVM, vecinos cercanos, Naive Bayes y árbol de decisiones, en el cual obtuvieron un 93% de sensibilidad con el algoritmo fusionado y un 67% con el algoritmo de Naive Bayes ejecutado por separado. El resultado de esta investigación tuvo una mejor especificidad al estudio de Khan et al. (2019), puesto que ellos usaron un total de 397 imágenes dermatoscópicas: 146 imágenes de melanomas y 251 de nevos.

Asimismo, el estudio de Gutiérrez et al. (2017) obtuvo una especificidad de 90.15% con el algoritmo fusionado y 86.16% con el algoritmo de Naive Bayes. El resultado de Gutiérrez fue menor porque en su estudio se utilizó un total de 360 fotografías para el entrenamiento de su algoritmo fusionado, mientras que en este estudio se utilizó un total de 3 mil fotografías digitales.

La especificidad del algoritmo fusionado fue 92.49%, menor al algoritmo de árbol de decisiones con un 93.84%. Este resultado fue mayor al obtenido en el estudio de Thepade et al. (2020), quienes obtuvieron un 80.51% de especificidad con el algoritmo fusionado basado con los algoritmos de SVM, vecinos cercanos, Naive Bayes y árbol de decisiones y un 73.34% con el algoritmo de árbol de decisiones. Thepade et al. (2020) obtuvieron un resultado menor al obtenido en este estudio, puesto que tuvieron varios entrenamientos de las imágenes dermatoscópicas con diferentes tamaños y usaron las dimensiones

de 4x4, 8x8, 16x16, 32x32, 64x64 y 128x128 píxeles, a comparación de este estudio que solo usó una dimensión de 600x600 píxeles en las imágenes.

Asimismo, el estudio tiene resultados similares a los resultados de Khan et al. (2019), quienes obtuvieron una especificidad de 97% en su algoritmo fusionado basado con los algoritmos de SVM, vecinos cercanos, Naive Bayes y árbol de decisiones, el que fue mayor al 60% del algoritmo de árbol de decisiones. Adicionalmente, Banerjee et al. (2020) obtuvieron resultados similares, con el algoritmo fusionado basado en los algoritmos de árbol de decisiones, SVM y vecinos cercanos obtuvo una especificidad de 98.13%, la que fue mayor al 92.03% del árbol de decisiones. En los estudios de Khan et al. (2019) y Banerjee et al. (2020) obtuvieron resultados similares, puesto que ellos usaron dos algoritmos de clasificación adicionales: SVM y vecinos cercanos, los que ayudaron a una tener mejor distribución de características para la clasificación de las imágenes.

La exactitud del algoritmo fusionado fue 94.73%, mayor a la obtenida con el algoritmo de redes neuronales con un 69.2%. Estos resultados fueron similares a los resultados de exactitud del estudio de Abbas et al. (2019), quienes obtuvieron 87.5% de exactitud con el algoritmo fusionado basado en los algoritmos de redes neuronales y Fuzzy C-Means, lo que fue mayor al resultado del algoritmo de redes neuronales con un 71.7%. El presente estudio obtuvo una mejor exactitud que el estudio de Abbas et al. (2019), puesto que ellos solo usaron 206 imágenes dermatoscópicas para el entrenamiento del algoritmo, a comparación de las 3,000 que utilizó el presente estudio.

Asimismo, el presente estudio obtuvo una mayor exactitud que el estudio de Tejada et al. (2020), en el que se obtuvo una exactitud de 88.87% con el algoritmo de redes neuronales con fotos de la galería de ISIC. El algoritmo fusionado de este estudio obtuvo una mejor exactitud que el de Tejada et al. (2020), puesto que ellos usaron una población de 568 imágenes dermatoscópicas de la Galería ISIC, a comparación de las 3,000 imágenes extraídas de la misma galería.

La exactitud del algoritmo fusionado fue 94.73%, mayor a la obtenida por el algoritmo de Naive Bayes con 69.30%. Estos resultados fueron similares a los resultados de Khan et al. (2019), quienes obtuvieron un 94% de exactitud con el algoritmo fusionado basados en SVM, vecinos cercanos, Naive Bayes y árbol de decisiones y un 76% con el algoritmo de Naive Bayes. Este estudio obtuvo una mejor exactitud que el estudio de Khan et al. (2019), puesto que se utilizó 3,000 imágenes dermatoscópicas a comparación de 397 de su estudio.

Conjuntamente, los resultados de exactitud del algoritmo fusionado fueron similares a los resultados de Gutiérrez et al. (2017), donde obtuvieron un mayor resultado con el algoritmo fusionado basado en Naive Bayes con un 93.64%, a comparación de 90.36% con el algoritmo de Naive Bayes. Este estudio tuvo una mejor exactitud que el de Gutiérrez et al. (2017), puesto que en esta investigación se usó también algoritmos de clasificación tales como el árbol de decisiones y redes neuronales y no el algoritmo probabilístico particularmente.

La exactitud del algoritmo fusionado fue 94.7%, menor al algoritmo de árbol de decisiones con 96.1%. Estos resultados fueron diferentes a los obtenidos en el estudio de Khan et al. (2019), quienes obtuvieron una mayor exactitud de un 97% con el algoritmo fusionado basado en los algoritmos de SVM, vecinos cercanos, Naive Bayes y árbol de decisiones y un 66% con el algoritmo de árbol de decisiones. En el estudio de Khan et al. (2019) obtuvieron una mejor exactitud, puesto que ellos usaron algoritmos de clasificación como: SVM, vecinos cercanos y árbol de decisiones, los que ayudaron a tener mejor distribución de características para la clasificación de las imágenes dermatoscópicas.

Por el contrario, los resultados obtenidos en este estudio fueron similares a los de Banerjee et al. (2020), quienes demostraron una mejora de la exactitud de 95% con su algoritmo fusionado, basado en los algoritmos de árbol de decisiones, SVM y vecinos cercanos a comparación del 99% del árbol de decisiones por separado. El estudio de Banerjee et al. (2020) obtuvo un mejor resultado de exactitud con el algoritmo fusionado, puesto que ellos usaron algoritmos netamente de clasificación, al contrario de esta investigación que utilizó el algoritmo de Naive Bayes, el que está basado en probabilidades.

La precisión del algoritmo fusionado de 93% fue mayor a la precisión del algoritmo de redes neuronales con 77.5%. Estos resultados fueron similares a los resultados en el estudio de Arasi et al. (2016), donde consiguieron 97.5% de precisión con el algoritmo fusionado basado con los algoritmos de redes neuronales, SVM y KNN y un 90% con el algoritmo de redes neuronales. Arasi et al. (2016) obtuvieron una mejor precisión, puesto que ellos usaron dos algoritmos de clasificación adicionales: vecinos cercanos y SVM, los cuales ayudaron a obtener una mejor clasificación de las imágenes dermatoscópicas.

Adicionalmente, la precisión de 93.44% del algoritmo fusionado del estudio fue mayor al resultado del algoritmo de redes neuronales que obtuvo 80%. El presente estudio obtuvo una mejor precisión que el de Rangel et al. (2019), puesto que este estudio tuvo tres algoritmos para tener una mejor clasificación de las imágenes, a comparación de realizarlo con solo un algoritmo.

La precisión del algoritmo fusionado de 93.44% fue mayor a la obtenida por el algoritmo de Naive Bayes con 66.2%. Estos resultados fueron similares a los resultados del estudio de Khan et al. (2019), quienes obtuvieron un 95% de precisión con el algoritmo fusionado basado en los algoritmos de SVM, vecinos cercanos, Naive Bayes y árbol de decisiones y 73% con el algoritmo de Naive Bayes. El estudio de Khan et al. (2019) obtuvo una mejor precisión que el algoritmo fusionado a este estudio, puesto que usaron algoritmos adicionales de clasificación: SVM y vecinos cercanos para una mejor precisión en la clasificación de las imágenes dermatoscópicas.

Asimismo, este estudio obtuvo resultados en la precisión similares al de Gutiérrez et al. (2017) donde demostró una mejoría en el algoritmo fusionado con el algoritmo fusionado basado en el Naive Bayes con un 93.65% a comparación al 90.21% del resultado de la precisión del algoritmo Naive Bayes. El estudio de Gutiérrez et al. (2017) obtuvo una mejor precisión que este estudio, porque ellos tuvieron una población de 4,997 datos, por lo cual tuvieron un mejor entrenamiento con el algoritmo fusionado.

La precisión del algoritmo fusionado de 93.44% fue menor a la obtenida por el algoritmo de árbol de decisiones con un 94.61%. Estos resultados fueron

similares a los obtenidos en el estudio de Thepade et al. (2020), quienes realizaron un algoritmo fusionado basado en los algoritmos de SVM, árbol de decisiones y bosque aleatorio, donde obtuvieron una precisión de un 82.1%, mayor al 74.36% de precisión con el árbol de decisiones. Adicionalmente, este estudio tuvo resultados similares al de Khan et al. (2019), quienes obtuvieron una precisión del 97% con el algoritmo fusionado basado en SVM, vecinos cercanos, Naive Bayes y árbol de decisiones, la que fue mayor a la precisión de 73% del árbol de decisiones. Este estudio obtuvo una mejor precisión en el algoritmo fusionado de Thepade et al. (2020) y Khan et al. (2019), puesto que este estudio tuvo un total de 3,000 imágenes dermatoscópicas para el entrenamiento y clasificación de las mismas.

Conjuntamente, estos resultados fueron similares al estudio de Banerjee et al. (2020), quienes desarrollaron un algoritmo fusionado basado en los algoritmos de árbol de decisiones, SVM y vecinos cercanos, con una precisión de 94.64%, la que fue mayor al 80% de precisión con el algoritmo de árbol de decisiones. El estudio de Banerjee et al. (2020) obtuvo una mejor precisión con el algoritmo fusionado, puesto que ellos netamente usaron algoritmos de clasificación para lograr una mejor distribución de características para poder clasificar las imágenes dermatoscópicas.

El tiempo del algoritmo fusionando de 0.16 ms fue igual al algoritmo de redes neuronales con 0.16 ms. Estos resultados fueron diferentes del estudio de Redmon et al. (2015), quienes obtuvieron un tiempo de 25 ms para el resultado de las redes neuronales, el cual ejecuta 45 fotogramas por segundo para el diagnóstico. Adicionalmente, el tiempo del estudio fue mejor que el de Ulloa (2018), quien señaló que el algoritmo de redes neuronales tuvo un tiempo de 171 ms de predicción con un tamaño de 3,570 datos por evaluar.

El tiempo del algoritmo fusionado de 0.16 ms fue inferior al tiempo del algoritmo de Naive Bayes con 0.15 ms. El resultado del algoritmo fusionado fue mejor que el logrado en el estudio de Monja (2020), quien obtuvo un tiempo de 0.23 ms con el algoritmo de Naive Bayes. El tiempo de este estudio fue mejor que el de Monja (2020), ya que tuvo una latencia mediante la consulta con su base de datos, a comparación de este estudio que tuvo un archivo plano y no

dependía de una conexión extra. Adicionalmente, el resultado de este estudio fue mejor al tiempo obtenido en el estudio de Zamorano (2018), quien consiguió un tiempo de 0.39 ms en el tiempo de predicción del algoritmo de Naive Bayes, puesto que en su estudio tuvo una muestra de 581,012 datos, a comparación de los 3,000 de este estudio.

El tiempo del algoritmo fusionado de 0.16 ms fue igual al tiempo del algoritmo de árbol de decisiones con 0.16 ms. Este estudio tuvo resultados similares en tiempo a los resultados de Banerjee et al. (2020), quienes obtuvieron un mejor tiempo con el algoritmo fusionado basado en los algoritmos de árbol de decisiones, SVM y vecinos cercanos con 12.4 segundos y tiempo de 15.21 segundos con el algoritmo de árbol de decisiones. El tiempo obtenido por este estudio fue mejor al obtenido en el estudio de Banerjee et al. (2020), puesto que ellos usaron 3 fuentes de información para extraer las imágenes dermatoscópicas: PH2, ISBI 2017 y ISIC 2019, a comparación de este estudio que solo uso el ISIC 2020.

Adicionalmente, el tiempo obtenido por el algoritmo fusionado de 0.16 ms fue menor que el obtenido de 0.89 ms en el estudio de Zamorano (2018) con el algoritmo de árbol de decisiones. En el presente estudio se usó 3,000 datos y se logró un menor tiempo que el obtenido por Zamorano (2018) quien usó una muestra de 581,012 datos, probablemente debido a la calidad de las imágenes de la fuente de información utilizada.

VI. CONCLUSIONES

Las conclusiones de la investigación fueron las siguientes:

1. Las sensibilidades de los algoritmos para el diagnóstico de las imágenes dermatoscópicas de melanoma cutáneo fueron: 96.76%, 75.48%, 74.50% y 98.28% para el algoritmo fusionado, redes neuronales, Naive Bayes y árboles de decisiones, respectivamente.
2. Las especificidades de los algoritmos para el diagnóstico de las imágenes dermatoscópicas de melanoma cutáneo fueron: 92.49%, 72.28%, 64.43% y 93.84% para el algoritmo fusionado, redes neuronales, Naive Bayes y árboles de decisiones, respectivamente.
3. Las exactitudes de los algoritmos para el diagnóstico de las imágenes dermatoscópicas fueron: 94.73%, 74.07%, 69.30% y 96.17% para el algoritmo fusionado, redes neuronales, Naive Bayes y árboles de decisiones, respectivamente.
4. Las precisiones de los algoritmos para el diagnóstico de las imágenes dermatoscópicas de melanoma cutáneo fueron: 93.44%, 77.51%, 66.24% y 94.61% para el algoritmo fusionado, redes neuronales, Naive Bayes y árboles de decisiones, respectivamente.
5. Los tiempos de los algoritmos para el diagnóstico de las imágenes dermatoscópicas de melanoma cutáneo fueron: 0.16 ms, 0.16 ms, 0.15 ms y 0.16 ms para el algoritmo fusionado, redes neuronales, Naive Bayes y árboles de decisiones, respectivamente. Por lo tanto, no se pudo apreciar diferencias significativas entre los tiempos de diagnóstico con los algoritmos utilizados.
6. El algoritmo fusionado solo logró incrementar la sensibilidad, la especificidad, la precisión y la exactitud con respecto a los algoritmos de redes neuronales y Naive Bayes debido al uso de las técnicas de clasificación para el pre-procesamiento de las imágenes; pero, no fue mayor en dichos resultados con el algoritmo de árboles de decisiones.

7. Las técnicas de clasificación para el pre-procesamiento de las imágenes y la cantidad y calidad de las 3,000 imágenes utilizadas (cantidad mayor a la utilizada en la mayoría de estudios previos) contribuyeron a tener mejores resultados con el algoritmo fusionado con respecto a la mayoría de estudios previos.

VII. RECOMENDACIONES

Las recomendaciones para futuras investigaciones son las siguientes:

1. Aumentar el número de fotografías digitales para incrementar el entrenamiento de los algoritmos y reducir el margen de error en la clasificación.
2. Tener en cuenta el uso de fotografías microscópicas de melanoma y nevus para conseguir un proceso de extracción de características más preciso.
3. Usar datos de un hospital o clínica, a fin de tener una base de datos de pacientes, a los que se pueda aplicar un pre-test y post-test según la evolución de las lesiones de melanoma.
4. Usar las librerías Tensorflow y Keras para el proceso de extracción de características y clasificación, ya que esta librería es flexible y permite usar distintos algoritmos, incluyendo el entrenamiento y los modelos de redes neuronales para la extracción de características; asimismo, esta librería tiene un mejor modelo para las redes neuronales convolucionales, ya que esta tiene sobreajustes para obtener las variables de entrada y de salida iguales (Refianti, Mutiara y Priyandini, 2019, p. 412).
5. Desarrollar un estudio similar fusionando otros algoritmos con el algoritmo de árbol de decisiones, ya que en esta investigación se logró buenos resultados en la clasificación de las fotografías de melanoma cutáneo, por lo que es muy probable que al fusionar otros algoritmos de clasificación con árbol de decisiones se logre aumentar la precisión diagnóstica.
6. Extender el diagnóstico preliminar a otros tipos de cáncer de piel existentes, ya que a través de la extracción y clasificación de características se podría lograr tener un mejor descarte, el cual

apoyará a los médicos a detectar enfermedades que muchas veces son mortales.

7. Agregar al modelo fusionado un algoritmo más orientado a clasificación, como el algoritmo K-Means, vecinos cercanos y/o SVM o máquinas de vectores de soporte, a fin de aumentar el porcentaje de precisión del modelo, puesto que este algoritmo clasifica la información en un plano cartesiano con diferentes dimensiones y busca la similitud de los datos de entrada en las clases del modelo entrenado (Refianti, Mutiara y Priyandini, 2019, p. 310).
8. Usar plataformas cloud gratuitas como Google Colab, puesto que solo se necesita una cuenta de Google para el desarrollo de proyectos en Python Jupiter Notebook de la plataforma antes mencionada; asimismo, estas plataformas cloud permiten el uso de GPUs y TPUs de Google ya que al ser una plataforma web elaborada por Google, ya no será necesario exigir muchos recursos del procesador de la computadora del usuario, ya que el entrenamiento de los usuarios se realizaría en el servidor de Google como un microservicio que ofrece 12.72 GB de RAM y 358.27 GB de disco duro en la nube y solo dependerá de la velocidad del Internet (Kanani et al., 2019, p. 2178-2180).
9. Usar una computadora mucho más potente respecto a procesador, tarjeta gráfica y GB de velocidad en la RAM a fin de tener un menor tiempo en el procesamiento de las fotos y mejor precisión en el diagnóstico del cáncer. Los componentes de la computadora que se utilizó fueron: Intel Core i5 9400, 16GB DDR4 y GPU Intel UHD Graphics 630. Asimismo, Rangel et al. (2019) utilizaron un “Intel Core i7 con 2.20GHz, 8.00GB DDR3 de doble canal a 665 MH, Tarjeta gráfica NVIDIA de 2.047 MB GeForce GT 54 M” (p. 22).
10. Realizar el desarrollo del sistema de diagnóstico preliminar en un lenguaje de programación distinto a Python, para medir las diferencias

en los resultados en los indicadores (precisión, sensibilidad, especificidad, exactitud y tiempo).

11. Buscar otros criterios de evaluación para tener mejor resultados de precisión, sensibilidad, especificidad y exactitud; por ejemplo, el consumo de GPU del servidor, medir el tiempo de entrenamiento de cada algoritmo, etc.

REFERENCIAS

- ABBES, W. y SELLAMI, D. Deep Neural Network for Fuzzy Automatic Melanoma Diagnosis [Red neuronal profunda para el diagnóstico automático difuso de melanoma]. *Proc. 14th Int. Joint Conf. Comput. Vis. Imag. Comput. Graph. Theory Appl* [en línea]. 2019, 1(1), pp. 47-56 [consulta: 27 de octubre de 2020]. ISBN 978-989-758-354-4. Disponible en: <https://www.scitepress.org/Papers/2019/76979/76979.pdf>
- ARASI, M., EL-DAHSHAN, EI-S., EL-HORBATY, EI-S., SALEM, A. Malignant Melanoma Detection Based on Machine Learning Techniques: A Survey [Detección de melanomas malignos basada en técnicas de aprendizaje automático: Un estudio]. *Egyptian Computer Science Journal*. [en línea]. 2016, 40(1), pp.1-10 [consulta: 27 de octubre de 2020]. ISSN1110–2586. Disponible en: <http://ecsjournal.org/Archive/Volume40/Issue3/1.pdf>
- AYALA, W., E. Técnicas quirúrgicas en tratamiento del cáncer de piel facial no melanoma complejo hospitalario policial nacional del Perú Luis Nicasio Sáenz 2017-2019 [en línea]. Tesis de pregrado. Universidad San Martín de Porres. Perú. 2020 [consultado: 27 de octubre de 2020]. Disponible en: <https://repositorio.usmp.edu.pe/handle/20.500.12727/6459>
- BANERJEE, S., KUMAR, S., CHAKRABORTY, A., DAS, A. y BAG, R. Melanoma Diagnosis Using Deep Learning and Fuzzy Logic [Diagnóstico de melanoma mediante aprendizaje profundo y lógica difusa]. *Diagnostics*. [en línea]. 2020, 10(8), pp. 1-26 [consulta: 27 de octubre de 2020]. Disponible en: <https://www.mdpi.com/2075-4418/10/8/577>
- BARRERA, J. A. *Redes Neuronales*. 2016 [consulta: 27 de octubre de 2020]. Disponible en: http://www.cucei.udg.mx/sites/default/files/pdf/toral_barrera_jamie_areli.pdf
- CAMPBELL, D. y STANLEY, J. Diseños experimentales y cuasi experimentales en la investigación social. Buenos Aires, Argentina: Amorrortu editores. 1973, [fecha de consulta: 27 de octubre de 2020]. Disponible en: <https://knowledgesociety.usal.es/sites/default/files/campbell-stanley-disec3b1os-experimentales-y-cuasiexperimentales-en-la-investigac3b3n-social.pdf>

- CAMPOS, D. y MUNDACA, L. Propuesta de método de reconocimiento de imágenes para la identificación del melanoma humano [en línea]. Tesis de pregrado. Universidad Señor de Sipán, Chiclayo-Perú, 2016. [fecha de consulta: 27 de octubre de 2020]. Disponible en: <https://repositorio.uss.edu.pe/handle/20.500.12802/156>
- CAPURRO, G. y ABELLA, Y. Proyecto Lanac medidas de calidad del SUL^cGabriel Capurro, Ignacio Abella [en línea]. 2007, 1(1), pp.1-35 [fecha de consulta: 27 de octubre de 2020].
- CÁRDENAS, J, A. *Clasificación de aceptación de campañas para una entidad financiera usando random forest con datos balanceados y datos no balanceados*. [en línea]. Tesis de pregrado. Universidad Ricardo Palma, Lima-Perú, 2019 [consultado: 27 de octubre de 2020]. Disponible en: https://repositorio.urp.edu.pe/bitstream/handle/URP/2307/T030_47199993_M%20%20%20CARDENAS%20GARRO%20JOS%C3%89%20ANTONIO.pdf?sequence=1&isAllowed=y
- CARRASCO, M., OCAMPO, W., ULLOA, L. y AZCONA, J. METODOLOGÍA HÍBRIDA DE DESARROLLO DE SOFTWARE COMBINANDO XP Y SCRUM. *Revista Científica Multidisciplinaria*. [en línea]. 2019, 5(2), pp.109-116 [consulta: 27 de octubre de 2020]. ISSN 2528-7842. Disponible en: https://www.researchgate.net/profile/Jon-Azcona-Esteban-2/publication/336588210_METODOLOGIA_HIBRIDA_DE_DESARROLLO_DE_SOFTWARE_COMBINANDO_XP_Y_SCRUM/links/5da724db299bf1c1e4c81709/METODOLOGIA-HIBRIDA-DE-DESARROLLO-DE-SOFTWARE-COMBINANDO-XP-Y-SCRUM.pdf
- CASTAÑEDA, P., ELJUERE, J. El cáncer de piel, un problema actual. *Revista de la facultad de Medicina de la UNAM*. [en línea]. 2016, 59(2), pp. 6-14 [consulta: 27 de octubre de 2020]. ISSN 0026-1742. Disponible en: http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0026-17422016000200006
- CELENTANO, D. y SZKLO, M. *Gordis Epidemiología* (6ª ed.). Barcelona, España. ELSEVIER. 2019, [fecha consulta: 27 de octubre de 2020]. ISBN: 978-0-323-55-229-5

- CORONADO, R. *Reconocimiento de patrones en imágenes no dermatoscópicas para la detección de enfermedades malignas en la piel, utilizando Redes Neuronales Convolutivas y Autocodificadores*. [en línea]. Tesis de posgrado. Universidad nacional de san Agustín, Arequipa-Perú, 2018 [consultado: 27 de octubre de 2020]. Disponible en: <http://190.119.145.154/handle/UNSA/6520>
- DING, C., y HERSHBERGER, S. Assessing content validity and content equivalence using structural equation modeling. *Structural Equation Modeling* [en línea]. 2002, **9**(2), pp. 283-291 [consultado: 27 de octubre de 2020]. Disponible en: https://doi.org/10.1207/S15328007SEM0902_7
- FARIÑA, A. *Detección de distintos tipos de cáncer mediante redes neuronales artificiales*. [en línea]. Tesis de pregrado. Universidad de la laguna, Tenerife-España, 2016 [consultado: 27 de octubre de 2020]. Disponible en: <https://riull.ull.es/xmlui/bitstream/handle/915/2905/Deteccion%20de%20distintos%20tipos%20de%20cancer%20mediante%20Redes%20Neuronales%20Artificiales.pdf?sequence=1>
- FERNANDEZ, V. *Fundamentos de Metodología de Investigación* (4ª ed.). Catalunya, Barcelona – España. OmniaScience Scholar. 2015, [fecha consulta: 27 de octubre de 2020]. ISBN: 978-84-120643-8-4
- GAIBOR, J. M., NUÑEZ, M. B. *Determinación del cumplimiento de las metodologías SCRUM Y XP con relación al estándar IEEE-12207 aplicado al Sistema de Control de Proveeduría en la CACECH* [en línea]. Tesis de pregrado. Escuela Superior Politécnica de Chimborazo, Ecuador, 2015 [consultado: 27 de octubre de 2020]. Disponible en: <http://dspace.esPOCH.edu.ec/handle/123456789/4339>
- GONZÁLEZ, C., JOFRE, M., PODLIPNIK, S., COMALIA, M., GAREAU, D., GAMBOA, M., VALLONE, M. G., FARIDE, Z., TAMEZ, A. L., MONTOYA, J., AMÉRICA, A., CARRERA, C., MALVEHY, J., y PUIG, S. Uso del aprendizaje automático en el diagnóstico del melanoma. Limitaciones por superar. *Academia española de dermatología y venereología* [en línea]. 2020, **111**(4), pp.313-316 [consulta: 27 de octubre de 2020]. ISSN 0001-7310. Disponible

en:

<https://www.sciencedirect.com/science/article/abs/pii/S0001731020300041>

GUEREQUETA, R., y VALLECILLO, A. Técnica de Diseño de Algoritmo (6ª ed.). Málaga. España. Servicio de Publicaciones de la Universidad de Málaga, 2000. [fecha consulta: 27 de octubre de 2020]. ISBN: 84-7496-666-3

GUTIÉRREZ, G., MARGAIN, M., y RAMÍREZ, T. Un modelo basado en el clasificador Naive Bayes para la evaluación del desempeño docente. *Revista Iberoamericana de Educación a distancia* [en línea]. 2017, **20**(2), pp. 293-313 [consulta: 27 de octubre de 2020]. ISSN 0001-7310. Disponible en: <http://hdl.handle.net/11162/141907>

HERNÁNDEZ, R., MARTÍNEZ, C, A., y NAVARRO, S., G. Redes neuronales y árboles de decisión para la clasificación de objetos astronómicos. *Tecnológico nacional de México* [en línea]. 2019, **148**(7), pp. 477-489 [consulta: 27 de octubre de 2020]. Disponible en: https://rcs.cic.ipn.mx/2019_148_7/Redes%20neuronales%20y%20arboles%20de%20decision%20para%20la%20clasificacion%20de%20objetos%20astronomicos.pdf

HERNÁNDEZ, R., y MENDOZA, C. Metodología de la investigación. Las rutas cuantitativa, cualitativa y mixta (4ª ed.). Cd. México. Editorial Mc Graw Hill Education Hill Education, 2017. [fecha consulta: 27 de octubre de 2020]. ISBN: 975-1-4532-6096-5

IGLESIAS, N., PARADELA, S., TEJERA, A., Boada, A., y Fonseca, E. melanoma cutáneo en el anciano: revisión de un problema creciente. *ACTAS Dermo-Sifiliográficas* [en línea]. 2019, **110**(6), pp. 434-447 [consulta: 27 de octubre de 2020]. Disponible en: <https://www.sciencedirect.com/science/article/abs/pii/S0001731019301231>

INSUA, J. Principalísimo, bioética personalista y principios de acción en medicina y en servicios de salud. *Persona y Bioética* [en línea]. 2018, **22**(2), pp. 223-246 [consulta: 27 de octubre de 2020]. Disponible en: http://www.scielo.org.co/scielo.php?pid=S0123-31222018000200223&script=sci_abstract&tlng=pt

- KANANI, P., y PADOLE, M. Deep Learning to Detect Skin Cancer using Google Colab [Aprendizaje profundo para detectar el cáncer de piel con Google Colab] [en línea]. 2019, **8**(6), pp. 2176-2183 [consulta: 27 de octubre de 2020]. Disponible en: https://www.researchgate.net/profile/Pratik-Kanani/publication/345321282_Deep_Learning_to_Detect_Skin_Cancer_using_Google_Colab/links/60329cbfa6fdcc37a8424383/Deep-Learning-to-Detect-Skin-Cancer-using-Google-Colab.pdf
- KHAN, M. Q., SAEED, A. H., MUAZZAM, U., MEHMOOD, K., y KHAN, M. Classification of Melanoma and Nevus in Digital Images for Diagnosis of Skin Cancer [Clasificación de melanomas y nevus en imágenes digitales para el diagnóstico del cáncer de piel]. *IEEE Access* [en línea]. 2019, **7**(1), pp. 90132-90144 [consulta: 27 de octubre de 2020]. Disponible en: <https://ieeexplore.ieee.org/abstract/document/8756036>
- LARRAÑAGA. P., INZA, I. MAUJAHID, A. *Tema 6. Clasificadores Bayesianos*. 1997 [consulta: 27 de octubre de 2020]. Disponible en: <http://www.sc.ehu.es/ccwbayes/docencia/mmcc/docs/t6bayesianos.pdf>
- LÓPEZ, R. E. Metodologías ágiles de desarrollo de Software aplicadas a la Gestión de Proyectos Empresariales. *Revista Tecnológica* [en línea]. 2015, **8**(1), pp. 6-11 [consulta: 27 de octubre de 2020]. Disponible en: <http://www.redicces.org.sv/jspui/bitstream/10972/2917/1/Articulo1.pdf>
- LÓPEZ, R. *Melanoma Cutáneo en Áreas con Índice de Radiación ultravioleta elevado* [en línea]. Tesis doctoral. Universidad de Extremadura. Badajoz, España, 2016 [consultado: 27 de octubre de 2020]. Disponible en: <https://dialnet.unirioja.es/servlet/tesis?codigo=54134>
- MEJÍA, M., y ALZATE, M. A. Clasificación automática de formas patológicas de eritrocitos humanos. *Revista Ingeniería* [en línea]. 2016, **21**(1), pp. 31-48 [consulta: 27 de octubre de 2020]. Disponible en: http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0121-750X2016000100004
- MOLINA, G., y RAMÍREZ, A. Conflicto de valores en el sistema de salud de Colombia: entre la economía de mercado y la normativa constitucional, 2007-

2009. *Revista Panamericana de Salud Pública* [en línea]. 2013, **33**(4), pp. 287-293 [consulta: 27 de octubre de 2020]. Disponible en: https://www.scielosp.org/article/ssm/content/raw/?resource_ssm_path=/media/assets/rpsp/v33n4/a08v33n4.pdf
- MONJA, E., *Comparación de Naive Bayes y series de Tiempo en la Predicción de morosidad de cuotas sociales del colegio de ingenieros del Perú consejo departamental Lambayeque* [en línea]. Tesis de pregrado. Universidad Señor de Sipán, Chiclayo-Perú, 2020 [consultado: 27 de octubre de 2020]. Disponible en: <https://repositorio.uss.edu.pe/handle/20.500.12802/6755>
- MURILLO, R. E. *Gestión administrativa y Calidad de servicio del programa Qali Warma en la provincia de Marscal Nieto, Moquegua-2018.* [en línea]. Tesis de maestría. Universidad César Vallejo, Lima-Perú, 2018 [consultado: 27 de octubre de 2020]. Disponible en: <https://repositorio.ucv.edu.pe/handle/20.500.12692/27075>
- MURRUGARRA, S., LORA, M., CABREJO, J., MUCHA, L., y FERNANDEZ, H. Factores asociados a mortalidad en pacientes Covid-19 en un hospital del norte de Perú. *Repositorio digital institucional Universidad César Vallejo* [en línea]. 2020, **1**(1), pp. 1-8 [consulta: 27 de octubre de 2020]. Disponible en: <https://repositorio.ucv.edu.pe/handle/20.500.12692/56325>
- NIÑO, V. M. *Metodología de la Investigación* (1ª ed.). Bogotá. Colombia. Ediciones de la U, 2011. [fecha consulta: 27 de octubre de 2020]. ISBN: 978-958-8675-94-7
- PIZARRO, C., HOELL, I., ARAYA, J., y ARATA, G. Epidemiología del melanoma en población de la provincia de Osorno: estudio retrospectivo 2016-2018. *Revista chilena de Dermatología* [en línea]. 2019, **1**(1), pp. 141-145 [consulta: 27 de octubre de 2020]. Disponible en: <https://rcderm.org/index.php/rcderm/article/view/257>
- RAE [en línea]. *Diccionario*, 2020 [consulta: 27 de octubre de 2020]. Disponible en: <https://bit.ly/2SEo7pl>
- RAMÍREZ, P., y GRANDÓN, E. Predicción de la Deserción Académica en una Universidad Pública Chilena a través de la Clasificación basada en Árboles

- de Decisión con Parámetros Optimizados. *Formación Universitaria* [en línea]. 2018, **11**(3), pp. 3-10 [consulta: 27 de octubre de 2020]. Disponible en: https://scielo.conicyt.cl/scielo.php?pid=S0718-50062018000300003&script=sci_arttext
- RAMOS, J., R. *Aprendizaje automático para flujos de datos* [en línea]. Tesis de maestría. Universidad Politécnica de Madrid, Madrid-España, 2019 [consultado: 27 de octubre de 2020]. Disponible en: <https://oa.upm.es/56025/>
- RANGEL, J. J., RUIZ, J. S., GARCÍA, F., y CERVANTES, J. Redes Neuronales Convolucionales en la identificación de melanomas benignos y malignos. *Revista Ibérica de Sistemas e Tecnologías de Informação* [en línea]. 2019, **1**(1), pp. 15-27 [consulta: 27 de octubre de 2020]. Disponible en: <https://ri.uaemex.mx/handle/20.500.11799/105226>
- RASTGOO, M., GARCIA, R., MOREL, O., y MARZANI. Automatic differentiation of melanoma from dysplastic nevi [Diferenciación automática del melanoma de los nuevos displásicos]. *Computerized Medical Imaging and Graphics* [en línea]. 2015, **43**(1), pp. 44-52 [consulta: 27 de octubre de 2020]. Disponible en: <https://www.sciencedirect.com/science/article/abs/pii/S0895611115000609>
- REDMON, J., y ANGELOVA. A. Real-time grasp detection using convolutional neural networks [Detección del agarre en tiempo real mediante redes neuronales convolucionales]. *IEE Xplore* [en línea]. 2015, **1**(1), pp. 1050-4729 [consulta: 27 de octubre de 2020]. Disponible en: <https://ieeexplore.ieee.org/abstract/document/7139361>
- REFIANTI, R., MUTIARA, A. B., y POETRI, R. Classification of Melanoma- Skin Cancer using Convolutional Neural Network [Clasificación del cáncer de piel de melanoma mediante redes neuronales Convolucionales]. *International Journal of Advanced Computer Science and Applications* [en línea]. 2019, **10**(3), pp. 409-417 [consulta: 27 de octubre de 2020]. Disponible en: <https://pdfs.semanticscholar.org/4ed8/fc6facfe78546fdeb937a9862cafcc32bbce.pdf>

- SALAZAR, J., TOVAR, Á., LINARES, J., LOZANO, A., y VALBUENA, Y. Scrum versus XP: Similitudes y diferencias. *Tecnología Investigación y Academia* [en línea]. 2018, **6**(2), pp. 29-37 [consulta: 27 de octubre de 2020]. Disponible -en: <https://revistas.udistrital.edu.co/index.php/tia/article/view/10496>
- SÁNCHEZ, N. Máquinas de soporte vectorial y redes neuronales artificiales en la predicción del movimiento USD/COP spot intradiario. *ODEON* [en línea]. 2015, **9**(1), pp. 113-172 [consulta: 27 de octubre de 2020]. Disponible en: <https://core.ac.uk/download/pdf/230113657.pdf>
- SARITAS, M, M., y YASAR, A. Performance analysis of ANN and Naive- Bayes classification algorithm for data classification [Análisis del rendimiento del algoritmo de clasificación ANN y Naive Bayes para la clasificación de datos]. *International Journal of Intelligent Systems and Applications in Engineering* [en línea]. 2019, **7**(2), pp. 88-91 [consulta: 27 de octubre de 2020]. Disponible en: <https://ijisae.org/index.php/IJISAE/article/view/934>
- SERRANO, J. *Sistema de ayuda al diagnóstico para la detección temprana de melanomas* [en línea]. Tesis de pregrado. Universidad Carlos III de Madrid, España, 2017 [consultado: 27 de octubre de 2020]. Disponible en: <https://e-archivo.uc3m.es/handle/10016/28200#preview>
- TEJADA, G., y GONZALES, R. *Arquitectura de red neuronal convolucional para diagnóstico de cáncer de piel* [en línea]. Tesis de pregrado. *Universidad Tecnológica del Perú*. 2020 [consultado: 27 de octubre de 2020]. Disponible en: https://repositorio.utp.edu.pe/bitstream/handle/20.500.12867/3043/Giorzini%20Tejada_Renzo%20Gonzales_Tesis_Titulo%20Profesional_2020.pdf?sequence=1&isAllowed=y
- THEPADE, S., RAMMANI, G., y MANDHARE, S. Hybrid Wavelet Transform Based Melanoma Identification Using Ensemble of Machine Learning Algorithms [Identificación de melanomas basada en la transformada de ondas híbrida utilizando un conjunto de algoritmos de aprendizaje automático]. 2020, **19**(3), pp. 1-17 [consulta: 27 de octubre de 2020]. Disponible en: <https://raco.cat/index.php/ELCVIA/article/view/373196>

- TOVAR, M. La investigación cualitativa en educación: necesidad y reto para los modelos pedagógicos contemporáneos. *Revista cubana de psicología* [en línea]. 2000, **17**(2), pp. 158-164 [consulta: 27 de octubre de 2020]. Disponible en: <http://pepsic.bvsalud.org/pdf/rcp/v17n2/09.pdf>
- ULLOA, R. *Detección de fallas en maquinaria rotativa: implementación de una red neuronal convolucional* [en línea]. Tesis de pregrado. Universidad de los Andes. 2018 [consultado: 27 de octubre de 2020]. Disponible en: <https://repositorio.uniandes.edu.co/handle/1992/34072>
- VALDIVIESO, C. E., VALDIVIESO, R., y VALDIVIESO, O, Á. Determinación del tamaño muestral mediante el uso de Árboles de decisión. *Investigacion y Desarrollo* [en línea]. 2011, **11**(1), pp. 53-80 [consulta: 27 de octubre de 2020]. Disponible en: <https://www.upb.edu/revista-investigacion-desarrollo/index.php/id/article/view/64>
- ZAMORANO, J. *Comparativa y análisis de algoritmos de aprendizaje automático para la predicción del tipo predominante de cubierta arbórea* [en línea]. Tesis de pregrado. Universidad complutense de Madrid. 2018 [consultado: 27 de octubre de 2020]. Disponible en: <https://eprints.ucm.es/id/eprint/48800/>
- ZIPES, D., LIBBY, P., BONOW, R., MANN, D., y TOMASELLI, G. Braunwald Tratado de cardiología (11ª ed.). Elsevier Health Sciences, Barcelona, España, 2019. [fecha consulta: 27 de octubre de 2020]. ISBN: 978-0-323-46-342-3

ANEXOS

Anexo 1: Matriz de operacionalización de variables

Tabla 9 Matriz de operacionalización de variables

VARIABLE	DIMENSIONES	INDICADORES		ESCALA DE MEDICIÓN
Efectividad del algoritmo fusionado basado en los algoritmos de árboles de decisión, Naive Bayes y redes neuronales. (González et al., 2020, p. 313).	Precisión diagnóstica (Celentano et al., 2015, p.89)	Sensibilidad = (TP) / (TP + FN) TP: Verdadero Positivos FN: Falsos Negativos (Celentano et al., 2015, p. 93)	$Sensibilidad = \frac{TP}{TP + FN}$	Porcentual (%)
		Especificidad = (TN) / (TN + FP) TN: Verdadero negativos FP: Falsos Positivos (Celentano et al., 2015, p. 93)	$Especificidad = \frac{TN}{TN + FP}$	
		Exactitud = (TP+TN) / (TP+ TN + FP+FN) TP: Verdadero Positivos FN: Falsos Negativos TN: Verdadero negativos FP: Falsos Positivos (Celentano et al., 2015, p. 93)	$Exactitud = \frac{TP + TN}{TP + TN + FP + FN}$	
		Precisión = TP / (TP + FP) TP: Verdadero Positivos FP: Falsos Positivos (Celentano et al., 2015, p. 93)	$Precisión = \frac{TP}{TP + FP}$	
	Tiempo			Milisegundo (ms)

Anexo 2: Matriz de consistencia

Tabla 10 Matriz de consistencia

PROBLEMA	OBJETIVO	HIPÓTESIS	VARIABLE	DIMENSIONES	INDICADORES
General	General	General			
¿Cuál fue el efecto del algoritmo fusionado basado en los algoritmos de Naive Bayes, árboles de decisiones y redes neuronales en la precisión diagnóstica preliminar de melanoma cutáneo?	Determinar qué precisión diagnóstica obtendrá el algoritmo fusionado en el diagnóstico preliminar de melanoma cutáneo en relación con los algoritmos redes neuronales, Naive Bayes y árbol de decisiones.	La sensibilidad, especificidad, precisión, exactitud y tiempo del algoritmo fusionado mejoraron con respecto a los algoritmos de redes neuronales, Naive Bayes y árbol de decisiones			
Específicos	Específicos	Específicas			
PE1: ¿Cuál fue el efecto del algoritmo fusionado basado en los algoritmos de Naive Bayes, árboles de decisiones y redes neuronales en la sensibilidad del diagnóstico preliminar de melanoma cutáneo?	OE1: Contrastar la sensibilidad obtendrá por el algoritmo fusionado en el diagnóstico preliminar de melanoma cutáneo en relación con los algoritmos de redes neuronales, Naive Bayes y árbol de decisiones.	HE1: La sensibilidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo redes neuronales en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales (Abbes et al., 2019, p. 55; Tejada et al., 2020, p. 84). HE2: La sensibilidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo Naive bayes en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales (Khan et al., 2019, p. 41; Gutiérrez et al., 2017, p. 305). HE3: La sensibilidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo árbol de decisiones en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales. (Thepade et al., 2020, p. 3432; Khan et al., 2019, p. 90141; Banerjee et al., 2020, p. 22).	Efecto del algoritmo fusionado basado en los algoritmos de árboles de decisión, Naive Bayes y redes neuronales. (González et al., 2020, p. 313).	Precisión diagnóstica (Celentano et al., 2015, p.89)	Sensibilidad (Celentano et al., 2015, p. 93)
PE2: ¿Cuál fue el efecto del algoritmo fusionado basado en los algoritmos de Naive bayes, árboles de decisiones y redes neuronales en la especificidad del diagnóstico preliminar de melanoma cutáneo?	OE2: Contrastar la especificidad obtenida por el algoritmo fusionado en el diagnóstico preliminar de melanoma cutáneo en relación con los algoritmos de redes neuronales, Naive Bayes y árbol de decisiones.	HE4: La especificidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo redes neuronales en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales (Abbes et al. 2019, p. 55; Fariña, 2016, p. 40). HE5: La especificidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo Naive bayes en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales (Khan et al., 2019, p. 90141; Gutiérrez et al., 2017, p. 306). HE6: La especificidad del algoritmo fusionado fue mayor a la obtenida por el algoritmo Árbol de decisiones en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales (Thepade et al., 2020, p. 12; Khan et al., 2019, p. 90141 Banerjee et al., p. 22).			Especificidad (Celentano et al., 2015, p. 93)

PROBLEMA	OBJETIVO	HIPÓTESIS	VARIABLE	DIMENSIONES	INDICADORES
Específicos	Específicos	Específicas			
PE3: ¿Cuál fue el efecto del algoritmo fusionado basado en los algoritmos de Naive bayes, árboles de decisiones y redes neuronales en la exactitud del diagnóstico preliminar de melanoma cutáneo?	OE3: Contrastar la exactitud obtenida por el algoritmo fusionado en el diagnóstico preliminar de melanoma cutáneo en relación con los algoritmos de redes neuronales, Naive Bayes y árbol de decisiones.	HE7: La exactitud del algoritmo fusionado fue mayor a la obtenida por el algoritmo Redes neuronales en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales (Abbes et al., 2019, p. 55; Tejada et al., 2020, p. 84). HE8: La exactitud del algoritmo fusionado fue mayor a la obtenida por el algoritmo Naive bayes en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales (Khan et al., 2019, p. 90141; Gutiérrez, p. 307). HE9: La exactitud del algoritmo fusionado fue mayor a la obtenida por el algoritmo Árbol de decisiones en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales (Khan et al. 2019, p. 90141; Banerjee et al., 2020, p. 22).			Exactitud (Celentano et al., 2015, p. 93)
PE5: ¿Cuál fue el efecto del algoritmo fusionado basado en los algoritmos de Naive bayes, árboles de decisiones y redes neuronales en la precisión del diagnóstico preliminar de melanoma cutáneo?	OE5: Contrastar la precisión de clasificación del algoritmo fusionado en relación con los algoritmos de redes neuronales, Naive Bayes y árbol de decisiones.	HE10: La precisión del algoritmo fusionado fue mayor a la obtenida por el algoritmo Redes neuronales en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales (Arasi et al., 2016, p. 7; Rangel et al., 2019, p. 26). HE11: La precisión del algoritmo fusionado fue mayor a la obtenida por el algoritmo Naive Bayes en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales (Khan et al., 201, p. 90141; Gutiérrez et al., 2017, p. 308). HE12: La precisión del algoritmo fusionado fue mayor a la obtenida por el algoritmo Árbol de decisiones en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales (Thepade et al., 2020, p. 9; Khan et al., 2019, p. 90141, Banerjee, 2020, p. 22).	Efecto del algoritmo fusionado basado en los algoritmos de árboles de decisión, Naive Bayes y redes neuronales. (González et al., 2020, p. 313).	Precisión diagnóstica (Celentano et al., 2015, p. 89)	Precisión (Celentano et al., 2015, p. 93)
PE4: ¿Cuál fue el efecto del algoritmo fusionado basado en los algoritmos de Naive Bayes, árboles de decisiones y redes neuronales en el tiempo del diagnóstico?	OE4: Contrastar el tiempo total de clasificación del algoritmo fusionado en relación con los algoritmos de redes neuronales, Naive Bayes y árbol de decisiones.	HE13: El tiempo de clasificación del algoritmo fusionado fue menor al obtenido por el algoritmo Redes neuronales en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales (Redmon et al., 2015, p. 56; Ulloa, 2018, p. 8). HE14: El tiempo de clasificación del algoritmo fusionado fue menor al obtenido por el algoritmo Naive Bayes en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales (Monja, 2020, p. 39; Zamorano, 2018, p. 104). HE15: El tiempo de clasificación del algoritmo fusionado fue menor al obtenido por el algoritmo Árbol de decisiones en el diagnóstico preliminar de melanoma cutáneo a través de fotografías digitales. (Banerjee et al., 2020, p. 22; Zamorano, 2018, p. 106).			Tiempo

Anexo 3: Redes neuronales artificiales

Una red neuronal artificial es un conjunto de algoritmos matemáticos que procesan información y encuentran relaciones no lineales entre el conjunto de datos, y cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano: la neurona (Sánchez, 2015, p. 117). Barrera (2016) mencionó que las redes neuronales permiten obtener un modelo no explícito que relaciona un conjunto de variables de salida con un conjunto de variables de entrada (p. 1).

Asimismo, estos modelos permiten predecir cuál es el valor de salida, dados unos valores de entrada del modelo; para estimar el modelo es necesario disponer de un conjunto de observaciones de las variables; estas observaciones son usadas como patrones de entrenamiento para que la red aprenda y sea capaz de predecir una salida del modelo, ante nuevas observaciones (Barrera, 2016, p.1). Por tanto, las capacidades de la red van a depender en gran medida de esta fase de entrenamiento; en la fase de entrenamiento es necesario controlar muchos parámetros y distintos algoritmos de optimización (Barrera, 2016, p.2).

Sánchez (2015) mencionó que la distribución de neuronas dentro de una red neuronal artificial se realiza formando niveles o capas de un número determinado de neuronas cada una (p. 122). A partir de su situación dentro de la red, se pueden distinguir tres tipos de capas:

- **Capas de entrada:** es la capa que recibe directamente la información de las fuentes externas de la red. Capa que recibe las variables de entrada (Sánchez, 2015, p.122).
- **Capas ocultas:** son internas a la red y no tienen contacto directo con el entorno exterior. El número capas ocultas puede ser mayor a uno y las neuronas de las capas ocultas pueden estar interconectadas de distintas maneras, lo que determina, junto con su número, las tipologías de redes (Sánchez, 2015, p.122).
- **Capas de salida:** es el conjunto de neuronas que transfieren la información que la red ha procesado hacia el exterior (Sánchez, 2015, p.122).

Anexo 4: Algoritmo de árbol de decisiones

Un árbol de decisión es un algoritmo que genera un árbol similar a un diagrama de flujo, donde cada nodo interno representa un valor de vector de características, las ramas representan decisiones y los nodos de hoja representan un resultado de clasificación de resultados (Hernández, Martínez y Navarro, 2019, p. 484). Es un algoritmo de clasificación supervisado no paramétrico que no requiere suposiciones de distribución, puede modelar relaciones no lineales y es insensible a los datos faltantes; el fundamento es la partición recursiva basada en reglas de asignación, partición y parada (Hernández et al., 2019, p. 484).

Un árbol de decisión es un modelo predictivo cuyo objetivo principal es aprender inductivamente a partir de observaciones y estructuras lógicas; son muy similares a los sistemas de predicción basados en reglas, que se utilizan para representar y clasificar una secuencia de condiciones que ocurren consecutivamente para encontrar una solución a un problema (Cárdenas, 2019, p. 129). Este es probablemente el modelo de clasificación más utilizado y popular; el conocimiento adquirido durante el aprendizaje inductivo está representado por un árbol (Cárdenas, 2019, p. 129).

Un árbol se representa gráficamente por un conjunto de nudos, hojas y ramas; el nodo principal o raíz es el atributo del que parte la clasificación; los nodos internos corresponden a cada pregunta en el atributo específico de la pregunta (Valdivieso, Valdivieso y Valdivieso, p. 2012, p. 11). Cada posible respuesta a la pregunta está representada por un nodo secundario; las ramas de cada uno de estos nodos están marcadas con posibles valores para el atributo; un nodo final o nodo hoja corresponde a una decisión que se ajusta a una de las variables de clase del problema a resolver (Valdivieso et al., p. 2012, p. 11).

Entre las principales ventajas de este algoritmo es que crea un modelo de caja blanca, por lo que es fácil de comprender el resultado (Hernández, et al., 2019, p. 484). Y requiere poca preparación del set de datos, ya que no requiere la eliminación de datos faltantes, o normalización (Hernández, et al., 2019, p. 484).

Anexo 5: Algoritmo de Naive Bayes

El algoritmo Naive Bayes es un clasificador de probabilidad simple que calcula un conjunto de probabilidades contando la frecuencia y las combinaciones de valores en un conjunto de datos dado; el algoritmo utiliza el teorema de Bayes y supone que todas las variables son independientes considerando el valor de la variable de clase (Saritas y Yasar, 2019, p. 90). Este supuesto de independencia condicional rara vez es válido en aplicaciones del mundo real, por lo que se caracteriza por ser ingenuo, pero el algoritmo tiende a aprender rápidamente en una variedad de problemas de clasificación controlada; el teorema de Bayes es una fórmula matemática utilizada para determinar la probabilidad condicional (Eq1), que lleva el nombre del matemático británico del siglo XVIII Thomas Bayes (Saritas y Yasar, 2019, p. 90).

Saritas et al. (2019) presentaron la siguiente fórmula: $P(A|B) = \frac{P(A)P(B|A)}{P(B)}$; dónde:

$P(A|B)$ es la probabilidad de que ocurra el evento A cuando ocurre el evento B, $P(A)$ es la probabilidad de que ocurra A, $P(B|A)$ es la probabilidad de que ocurra el evento B cuando ocurre el evento A, $P(B)$ es la probabilidad de que ocurra B (p.90).

Naive Bayes se aplica al conjunto de datos y se genera la matriz de confusión para el género de la clase que tiene dos valores posibles, es decir, controles sanos o pacientes (Saritas et al., 2019, p. 90). El paradigma clasificatorio en el que se utiliza el teorema de Bayes en conjunción con la hipótesis de independencia condicional de las variables predictoras dada la clase se conoce bajo diversos nombres que incluyen los de idiota Bayes, naïve Bayes, simple Bayes y Bayes independiente (Larrañaga, Inza y Moujahid, 1997, p. 1).

Vamos a plantear la formulación clásica de un problema de diagnóstico utilizando una terminología habitual en medicina; es evidente que la terminología puede trasladarse a otras ramas de la ciencia y de la técnica, en particular a la ingeniería (Larrañaga et al., 1997, p. 3). La terminología para usar incluye términos como:

- **Hallazgo**, con el cual determina el valor de una variable predictora X_r . Así por ejemplo X_r (valor de la variable X_r) puede estar representando la existencia de vómitos en un determinado enfermo (Larrañaga et al., 1997, p. 3).

- **Evidencia**, denota el conjunto de todos los hallazgos para un determinado individuo. Es decir, $x = (x_1, \dots, x_n)$ puede estar denotando (si $n = 4$) que el individuo en cuestión es joven, hombre, presenta vómitos y además no tiene antecedentes familiares (Larrañaga et al., 1997, p. 3).
- **Diagnóstico**, denota el valor que toman las m variables aleatorias Y_1, \dots, Y_m , cada una de las cuales se refiere a una enfermedad (Larrañaga et al., 1997, p. 3).
- **Probabilidad a priori del diagnóstico**, $p(y)$ o $p(Y_1 = y_1, \dots, Y_m = y_m)$, se refiere a la probabilidad de un diagnóstico concreto, cuando no se conoce nada acerca de los hallazgos, es decir, cuando se carece de evidencia (Larrañaga et al., 1997, p. 3).
- **Probabilidad a posteriori de un diagnóstico**, $p(y|x)$ o $p(Y_1 = y_1, \dots, Y_m = y_m | X_1 = x_1, \dots, X_n = x_n)$, es decir, la probabilidad de un diagnóstico concreto cuando se conocen n hallazgos (evidencia) (Larrañaga et al., 1997, p. 3).

Anexo 6: Prototipos del proyecto

En la figura 1 muestra la pantalla donde hay botones para acceder a las diferentes opciones del sistema, estas son: galería, estadísticas, árbol de decisiones, naive bayes, redes neuronales y el algoritmo fusionado.

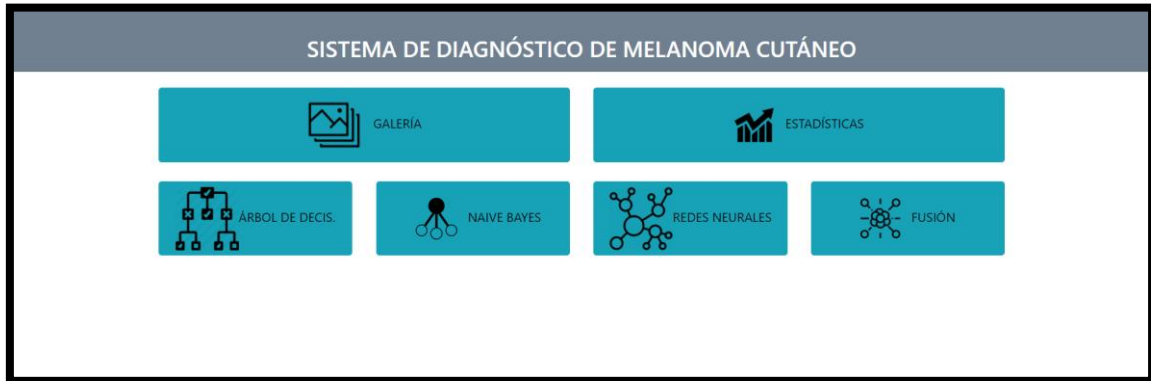


Figura 1 Pantalla principal del sistema

En la figura 2 se muestra la pantalla de la galería, en la que se podrá visualizar las fotos dermatoscópicas digitales de melanomas y no melanomas.

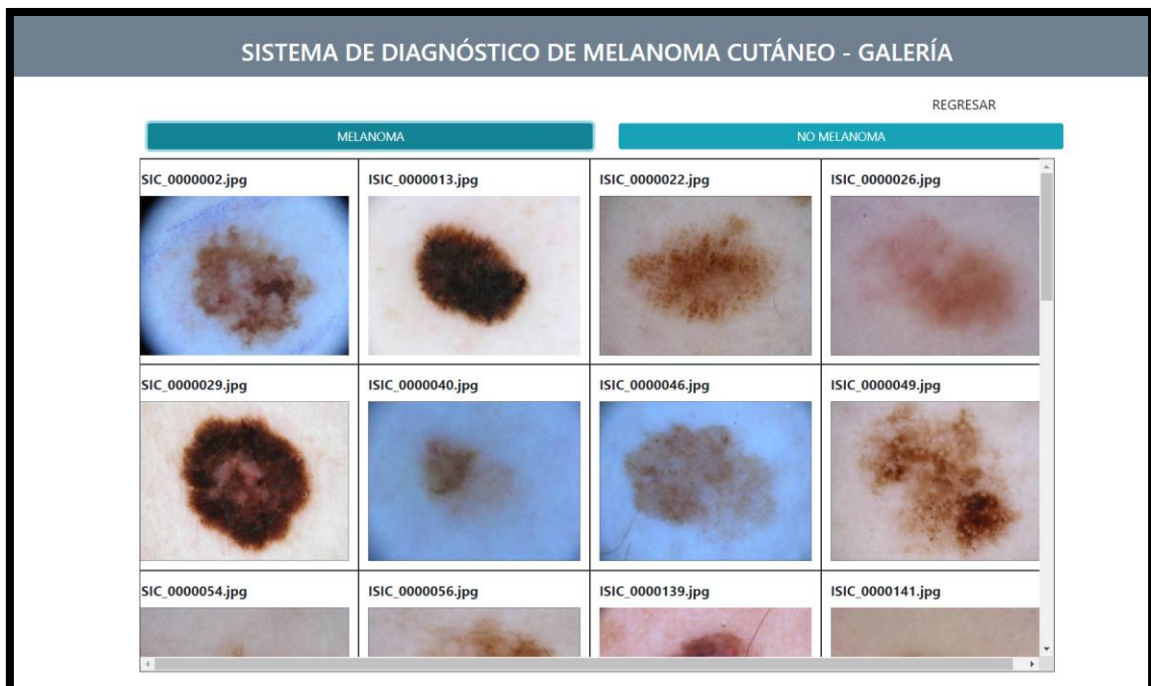


Figura 2 Pantalla de la galería

En la figura 3 se muestra la pantalla para el resultado de diagnóstico, donde la interfaz de árbol de decisiones, Naive Bayes, redes neuronales y el algoritmo fusionado son idénticas, puesto que debe ingresar una foto dermatoscópica y este le dará el resultado de su diagnóstico al presionar el botón de “EJECUTAR DIAGNÓSTICO”.




Figura 3 Pantalla para la predicción del diagnóstico

En la figura 4 se muestra la pantalla de cuadro estadístico de resultados de diagnósticos para evaluar la sensibilidad, especificidad, precisión, exactitud y tiempo de duración, todo esto mediante el cuadro de confusión de cada algoritmo.

	VERDADEROS POSITIVOS	VERDADEROS NEGATIVOS	FALSOS POSITIVOS	FALSOS NEGATIVOS	SENSIBILIDAD (%)	ESPECIFICIDAD (%)	EXACTITUD (%)	PRECISION (%)	TIEMPO (seg)
NAIVE BAYES	--	--	--	--	--	--	--	--	--
ARBOL DE DECISIONES	--	--	--	--	--	--	--	--	--
REDES NEURONALES	--	--	--	--	--	--	--	--	--
ALGORITMO FUSIONADO	--	--	--	--	--	--	--	--	--

Sensibilidad = $(TP) / (TP + FN)$ Especificidad = $(TN) / (TN + FP)$ Exactitud = $(TP+TN) / (TP+ TN + FP+FN)$ Precisión = $TP / (TP + FP)$
 TP: Verdadero Positivos TN: Verdadero negativos TP: Verdadero Positivos
 FN: Falsos Negativos FP: Falsos Positivos FN: Falsos Negativos FP: Falsos Positivos
 TN: Verdadero negativos FP: Falsos Positivos

Figura 4 Pantalla de estadística de resultados

Anexo 7: Pseudocódigo del algoritmo de árbol de decisiones

En la figura 5 se muestra el algoritmo de la función para extraer el diagnóstico de las fotos ingresadas con el algoritmo de árbol de decisiones.

```
Funcion json <- ArbolDecisionesClasificacion (cant)
  tiempoInicial <- funcionTime
  dataset <- csv
  data <- csv/cant
  X1 <- data
  yp <- dataPrediccion
  Dimension X[4]
  Mientras X1=cant Hacer
  .....
    X[0] <- parametro1
    X[1] <- parametro2
    X[2] <- parametro3
    X[3] <- parametro4
  FinMientras
  ArbolDecision <- SklearnTreeDecisionTreeClassifier
  ArbolDecision <- CriterioEntropia
  ArbolDecision <- Entrenamiento
  ArbolDecision <- Testeo
  ArbolDecision <- Prediccion
  y_pred <- ArbolDecision
  confusion_matrix <- SklearnConfusionMatrix
  matriz <- confusion_matrix*(yp-y_pred)
  TP <- matrizTP
  FP <- matrizFP
  TN <- matrizTN
  FN <- matrizFN
  sens <- Sensibilidad(TP,FN)
  espe <- Especificidad(TN,FP)
  exac <- Exactitud(TP,TN,FP,FN)
  prec <- Precision(TP,FP)
  tiempoFinal <- funcionTime
  tiempo <- tiempoInicial-tiempoFinal
  json <- parametros
FinFuncion
```

Figura 5 Pseudocódigo del algoritmo de árbol de decisiones

Flujograma de algoritmo de árbol de decisiones

En la figura 6 se muestra el flujograma del algoritmo de la función para extraer el diagnóstico de las fotos ingresadas con el algoritmo de árbol de decisiones.

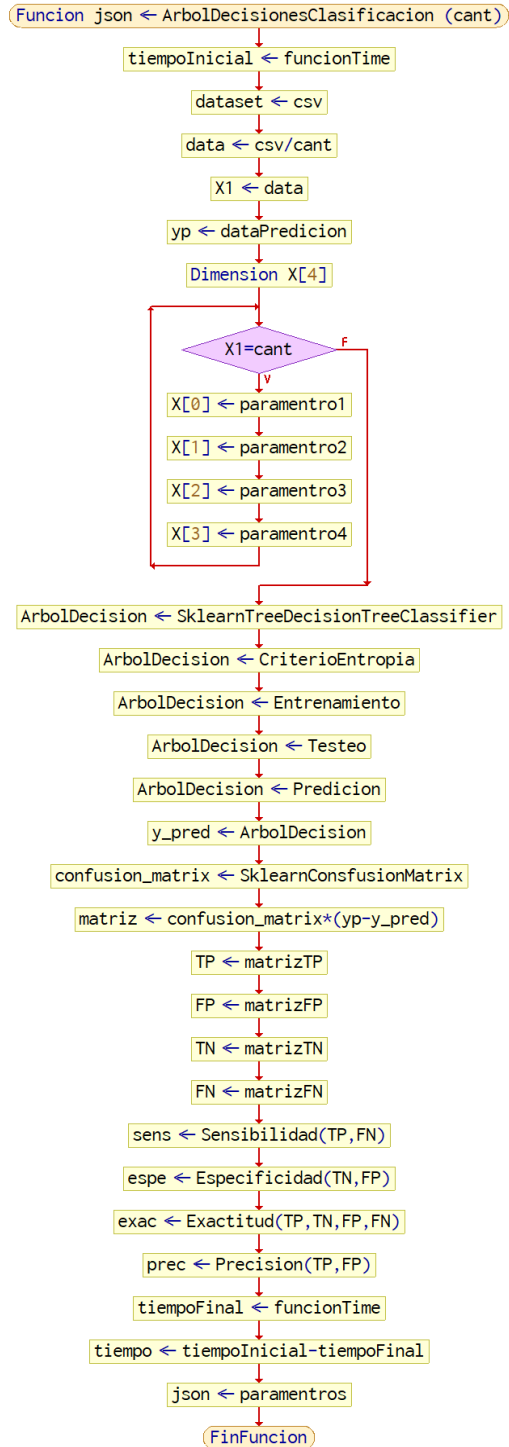


Figura 6 Flujograma del algoritmo de árbol de decisiones

Anexo 8: Pseudocódigo del algoritmo de redes neuronales

En la figura 7 se muestra el algoritmo de la función para extraer el diagnóstico de las fotos ingresadas con el algoritmo de redes neuronales.

```
Funcion json <- RedesNeuronalesClasificacion (cant)
  tiempoInicial <- funcionTime
  dataset <- csv
  data <- csv/cant
  X1 <- data
  yp <- dataPrediccion
  Dimension X[4]
  Mientras X1=cant Hacer
  .....
    X[0] <- paramentro1
    X[1] <- paramentro2
    X[2] <- paramentro3
    X[3] <- paramentro4
  .....
  FinMientras
  RedesNeuronales <- SklearnNeuraNetworkClassifier
  RedesNeuronales <- MLPClassifier
  RedesNeuronales <- Entrenamiento
  RedesNeuronales <- Testeo
  RedesNeuronales <- Prediccion
  y_pred <- RedesNeuronales
  confusion_matrix <- SklearnConsfusionMatrix
  matriz <- confusion_matrix*(yp-y_pred)
  TP <- matrizTP
  FP <- matrizFP
  TN <- matrizTN
  FN <- matrizFN
  sens <- Sensibilidad(TP,FN)
  espe <- Especificidad(TN,FP)
  exac <- Exactitud(TP,TN,FP,FN)
  prec <- Precision(TP,FP)
  tiempoFinal <- funcionTime
  tiempo <- tiempoInicial-tiempoFinal
  json <- paramentros
FinFuncion
```

Figura 7 Pseudocódigo del algoritmo de redes neuronales

Flujograma del algoritmo de redes neuronales

En la figura 8 se muestra el flujograma del algoritmo de la función para extraer el diagnóstico de las fotos ingresadas con el algoritmo de redes neuronales.

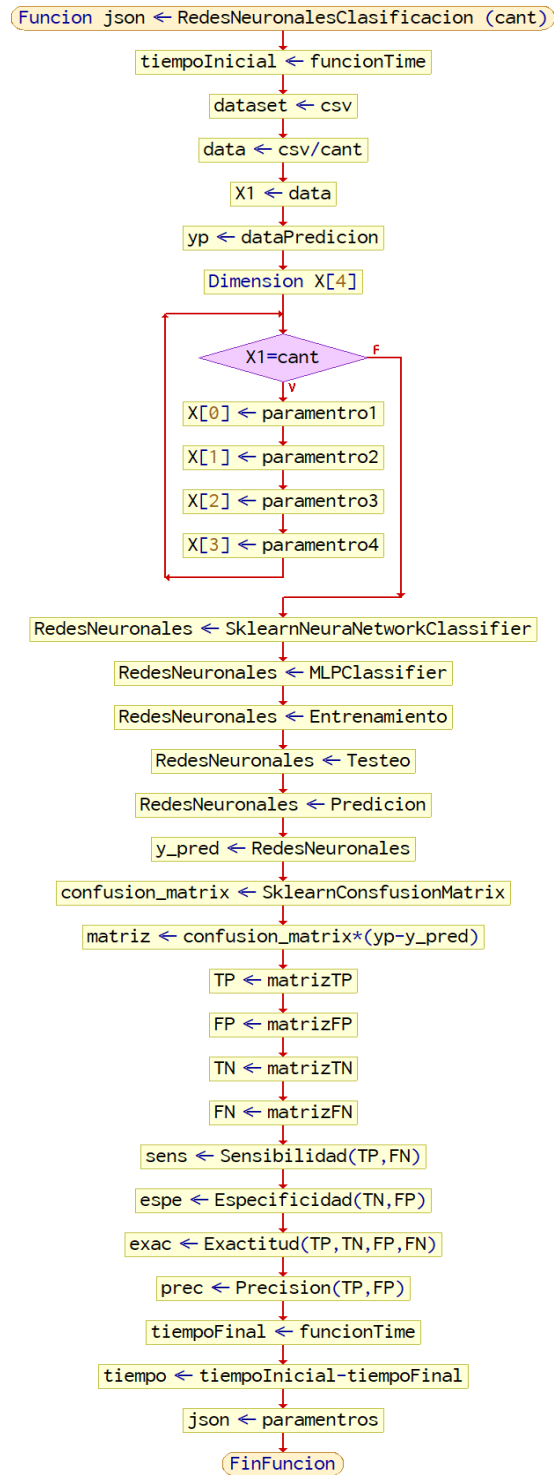


Figura 8 Flujograma del algoritmo de redes neuronales

Anexo 9: Pseudocódigo del algoritmo de Naive Bayes

En la figura 9 se muestra el algoritmo de la función para extraer el diagnóstico de las fotos ingresadas con el algoritmo de Naive Bayes.

```
Funcion json <- BayesNaivesClasificacion (cant)
  tiempoInicial <- funcionTime
  dataset <- csv
  data <- csv/cant
  X1 <- data
  yp <- dataPredicion
  Dimension X[4]
  Mientras X1=cant Hacer
  .....
    X[0] <- paramentro1
    X[1] <- paramentro2
    X[2] <- paramentro3
    X[3] <- paramentro4
  .....
  FinMientras
  NaiveBayes <- SklearnNaiveBayesClassifier
  NaiveBayes <- GaussianNB
  NaiveBayes <- Entrenamiento
  NaiveBayes <- Testeo
  NaiveBayes <- Prediccion
  y_pred <- NaiveBayes
  confusion_matrix <- SklearnConfusionMatrix
  matriz <- confusion_matrix*(yp-y_pred)
  TP <- matrizTP
  FP <- matrizFP
  TN <- matrizTN
  FN <- matrizFN
  sens <- Sensibilidad(TP,FN)
  espe <- Especificidad(TN,FP)
  exac <- Exactitud(TP,TN,FP,FN)
  prec <- Precision(TP,FP)
  tiempoFinal <- funcionTime
  tiempo <- tiempoInicial-tiempoFinal
  json <- paramentros
FinFuncion
```

Figura 9 Pseudocódigo del algoritmo de Naive Bayes

Flujograma del algoritmo de Naive bayes

En la figura 10 se muestra el flujograma del algoritmo de la función para extraer el diagnóstico de las fotos ingresadas con el algoritmo de Naive Bayes.

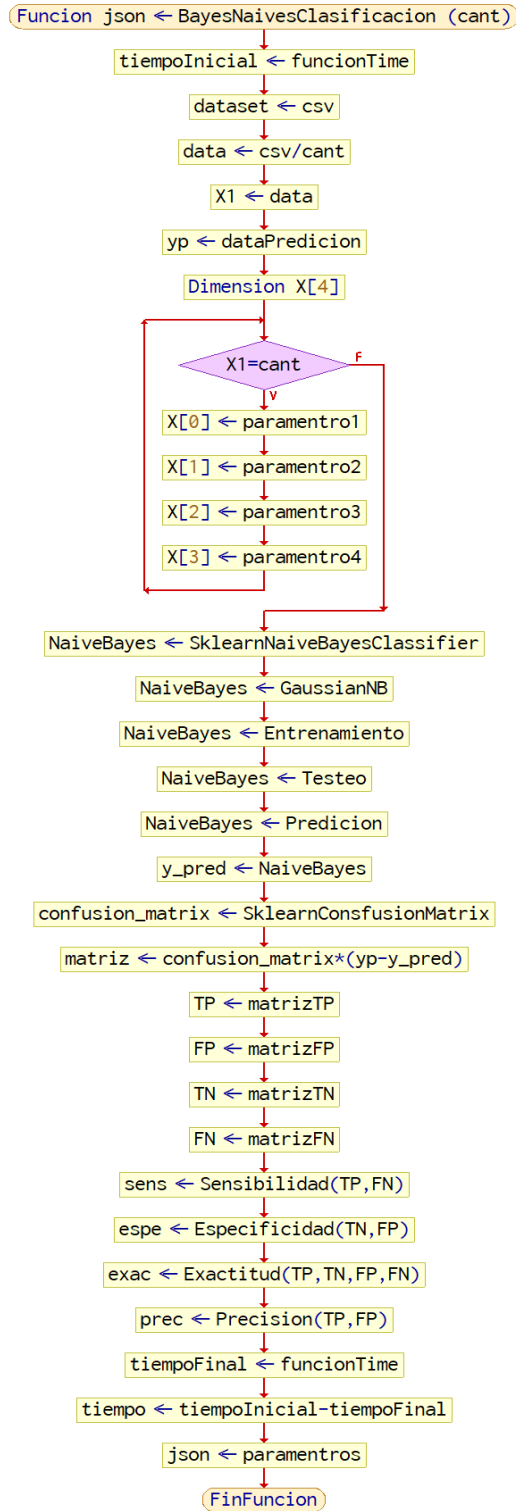


Figura 10 Flujograma del algoritmo de Naive Bayes

Anexo 10: Pseudocódigo del algoritmo fusionado

En la figura 11 se muestra el algoritmo de la función para extraer el diagnóstico de las fotos ingresadas con el algoritmo fusionado.

```
Funcion json <- Fusionado (cant)
  tiempoInicial <- funcionTime
  dataset <- csv
  data <- csv/cant
  X1 <- data
  yp <- dataPrediccion
  Dimension X[4]
  Mientras X1=cant Hacer
  .....
    X[0] <- paramentro1
    X[1] <- paramentro2
    X[2] <- paramentro3
    X[3] <- paramentro4
  .....
  FinMientras
  ArbolDecision <- SklearnTreeDecisionTreeClassifier
  ArbolDecision <- CriterioEntropia
  ArbolDecision <- Entrenamiento
  ArbolDecision <- Testeo
  ArbolDecision <- Prediccion
  y_pred_AD <- ArbolDecision
  RedesNeuronales <- SklearnNeuraNetworkClassifier
  RedesNeuronales <- MLPClassifier
  RedesNeuronales <- Entrenamiento
  RedesNeuronales <- Testeo
  RedesNeuronales <- Prediccion
  y_pred_RN <- RedesNeuronales
  NaiveBayes <- SklearnNaiveBayesClassifier
  NaiveBayes <- GaussianNB
  NaiveBayes <- Entrenamiento
  NaiveBayes <- Testeo
  NaiveBayes <- Prediccion
  y_pred_NB <- NaiveBayes
  confusion_matrix <- SklearnConfusionMatrix
  matriz <- confusion_matrix*(yp-y_pred)
  TP <- matrizTP
  FP <- matrizFP
  TN <- matrizTN
  FN <- matrizFN
  sens <- Sensibilidad(TP,FN)
  espe <- Especificidad(TN,FP)
  exac <- Exactitud(TP,TN,FP,FN)
  prec <- Precision(TP,FP)
  tiempoFinal <- funcionTime
  tiempo <- tiempoInicial-tiempoFinal
  y_pred <- (y_pred_AD+y_pred_NB+y_pred_RN)/3
  json <- paramentros
FinFuncion
```

Figura 11 Pseudocódigo del algoritmo fusionado

Flujograma del algoritmo fusionado

En la figura 12 se muestra el flujograma del algoritmo de la función para extraer el diagnóstico de las fotos ingresadas con el algoritmo fusionado.

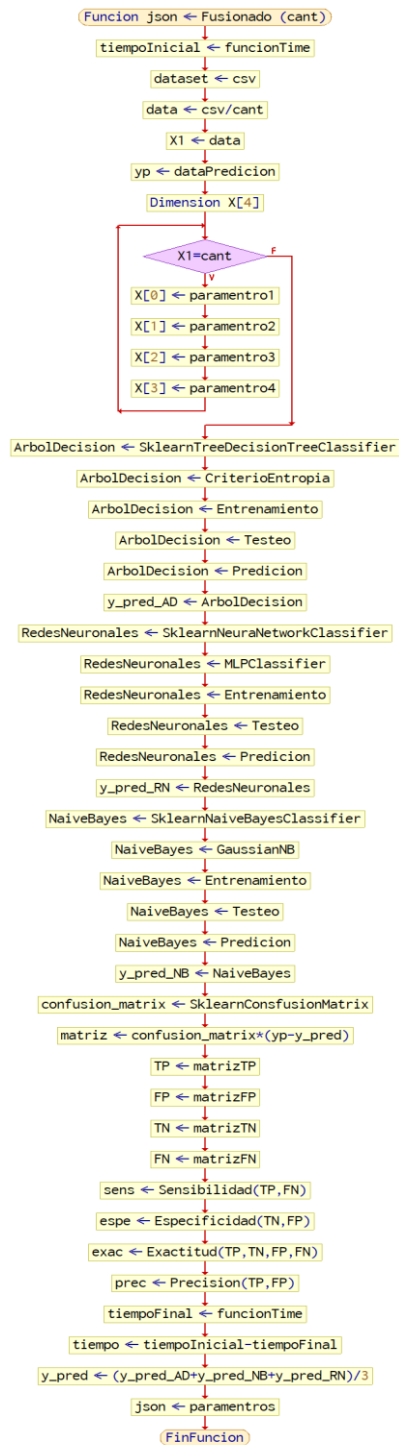


Figura 12 Flujograma del algoritmo fusionado

Anexo 11: Arquitectura tecnológica



Figura 13 Arquitectura tecnológica

En la figura 13 se muestra la arquitectura tecnológica, el cual muestra a interacción del servidor hacia el cliente, el cual se denomina servicio donde se utiliza Python, Flask, HTML5, CSS, Ajax y JavaScript para mostrar el sistema en el navegador web de preferencia del cliente.

Anexo 12: Metodología XP

López (2015) indicó que la metodología XP se apoya en una serie de reglas y fundamentos en el desarrollo de un software, el cual se calificaría como un proceso ágil (p. 8). Asimismo, Gaibor y Núñez (2015) mencionaron que la metodología XP se basa en 5 valores en los cuales todo el equipo debe trabajar estos son: comunicación, simplicidad, retroalimentación, coraje y respeto (p. 45).

Salazar, Tovar, Linares, Lozano y Valbuena (2018) señalaron que esta metodología se basa en la prueba y error para un desarrollo efectivo, en un sistema funcional, el cual el cliente tiene interacción en el proceso de desarrollo para determinar los resultados, y así lograr un buen ambiente laboral (p. 34). También, López (2015, p. 9) indicó que esta metodología tiene doce principios básicos, los cuales están separados por cuatro categorías, estas son:

- Retroalimentación a escala fina: en esta fase se ubica los principios de realización de pruebas, proceso de planificación, el cliente en el sitio y programación en parejas (López, 2015, p. 9).
- Proceso Continuo en lugar de por lotes: permite la integración continúa y entregas pequeñas (López, 2015, p. 9).
- Entendimiento compartido: hay criterios como la creación de un diseño fácil, las tarjetas CRC y la creación de metáfora de sistema o historia completa (López, 2015, p. 9).
- Bienestar del programador: acá se considera la filosofía de un programador cansado, el cansancio puede crear una mala calidad en el código, por eso es recomendable que los desarrolladores del sistema trabajen 40 horas a la semana y muy pocas horas extras de trabajo (López, 2015, p. 9).

Gaibor et al. (2015) mencionaron los roles en la metodología XP, los cuales son:

- Desarrollador: se encarga en la ejecución de pruebas unitarias y del código para el sistema. Debe realizarse un buen trabajo en equipo entre los programadores y otros miembros de equipo mediante una buena comunicación y coordinación (Gaibor et al., 2015, p. 46).
- Cliente: es el encargado de las historias de usuario, las pruebas de aceptación para la validación del software analizan y determinan la

prioridad de las historias de usuario, decide cuál de ellas se implementarán para fortalecer el negocio (Gaibor et al., 2015, p. 46).

- Encargado de pruebas (QA): realiza el análisis y diseño de los escenarios de pruebas funcionales, es el responsable de ejecutar las pruebas, obtener resultados y el responsable de las herramientas de soporte de pruebas. (Gaibor et al., 2015, p. 47).
- Encargado de seguimiento (tracker): es el encargado en verificar el grado de acierto en las funciones implementadas y en tiempo real, obtiene los resultados, realiza seguimiento del progreso de cada función y evalúa si los objetivos son alcanzados, el tracker determina si se realiza algún cambio obteniendo la retroalimentación en el proceso XP (Gaibor et al., 2015, p. 47).
- Entrenador (COACH): es responsable del proceso global. El entrenador debe conocer a profundamente el proceso de XP para poder guiar a los miembros del equipo de forma que se apliquen las practicas XP y se siga el proceso correctamente (Gaibor et al., 2015, p. 47).
- Consultor: es un miembro externo del equipo con un conocimiento específico en algún tema necesario para el proyecto. Se encarga de guiar al equipo para resolver un problema específico (Gaibor et al., 2015, p. 47).
- Gestor (BIG BOSS): se encarga en la coordinación entre clientes y programadores, ayuda a que el equipo trabaje efectivamente creando las condiciones adecuadas (Gaibor et al., 2015, p. 467).

Carrasco, Ocampo, Ulloa y Azcona (2019, p. 113) hacen mención de las seis fases del ciclo de vida en la metodología XP, los cuales son:

- Fase I: Exploración: en esta fase se tendrá que establecer los roles como: Product Owner, Development Team y Scrum Master, los cuales tendrán una reunión con el Product Owner y todos los interesados del proyecto para recopilar las funcionalidades de la empresa para poder plantear las historias del usuario para poder tener sus entregables deseados (Carrasco et al., 2019, p.113).
- Fase II: Planeación: en esta fase se inicia el primer sprint, el cual será escoger las historias del usuario de acuerdo con la prioridad, luego de

establecer las prioridades el Development Team establecerá la complejidad de cada historia, el cual dependerá con la experiencia del desarrollador. Luego se crea el sprint Backlog en base a las historias elegidas, los cuales se establece un tiempo de duración de cuatro semanas, y las tareas se dividirán para un mejor control de trabajo. En esta fase se ubica la Gestión de Tareas y la Gestión de Versiones (Carrasco et al., 2019, p. 113).

- Fase III: Diseño: en esta fase se utiliza las tarjetas CRC, las cuales ayudan a identificar y organizar los requerimientos del sistema (Carrasco et al., 2019, p. 114).
- Fase IV: Codificación: En esta fase se desarrolla las funcionalidades del sistema, la creación del código fuente. En esta fase se realiza diariamente los Daily Scrum, el cual son reuniones para la verificación de los trabajos realizados el día anterior y evaluar el avance y riesgos en la elaboración de sus tareas del desarrollador (Carrasco et al., 2019, p. 114).
- Fase V: Pruebas: A la par de la fase anterior, se deben realizar pruebas unitarias para poder verificar la funcionalidad del sistema en su desarrollo, en esta fase se ejecutarán los Sprint Review, los cuales son reuniones con el Product Owner donde se demostrará el producto desarrollado y se explica las funcionalidades del sistema, el cual se recibirá la aceptación del sistema. Luego de esta fase será necesario volver a la fase II para poder continuar con los sprints. Al terminar todos los sprints se podrá proceder a la fase final (Carrasco et al., 2019, p. 115).
- Fase VI: Fin del Proyecto: en esta fase luego que el Product Backlog no tenga más historias de usuario y todas las funcionalidades estén correctamente desarrolladas, se dará por finalizado el ciclo de vida del desarrollo del software. Y se hará un acta de la finalización del proyecto por parte del Product Owner (Carrasco et al., 2019, p. 115).



UNIVERSIDAD CÉSAR VALLEJO

**FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**

Declaratoria de Autenticidad del Asesor

Yo, ALFARO PAREDES EMIGDIO ANTONIO, docente de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA DE SISTEMAS de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA ESTE, asesor de Tesis titulada: "ALGORITMO PARA EL DIAGNOSTICO PRELIMINAR DE MELANOMA CUTANEO BASADO EN REDES NEURONALES, NAIVE BAYES Y ARBOLES DE DECISION.", cuyos autores son ALARCON VELA VICTOR MIGUEL, MURGA AGUILAR DAISY MAGALY, constato que la investigación cumple con el índice de similitud de 16% establecido, y verificable en el reporte de originalidad del programa Turnitin, el cual ha sido realizado sin filtros, ni exclusiones.

He revisado dicho reporte y concluyo que cada una de las coincidencias detectadas no constituyen plagio. A mi leal saber y entender la Tesis cumple con todas las normas para el uso de citas y referencias establecidas por la Universidad César Vallejo.

En tal sentido, asumo la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión tanto de los documentos como de información aportada, por lo cual me someto a lo dispuesto en las normas académicas vigentes de la Universidad César Vallejo.

LIMA, 28 de Diciembre del 2020

Apellidos y Nombres del Asesor:	Firma
ALFARO PAREDES EMIGDIO ANTONIO DNI: 10288238 ORCID 0000-0002-0309-9195	Firmado digitalmente por: EALFAROP el 28-12-2020 12:31:20

Código documento Trilce: TRI - 0101635