



UNIVERSIDAD CÉSAR VALLEJO

FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS

Estudio comparativo de la eficiencia diagnóstica del
cáncer de mama con los algoritmos CNN, NB y RF

TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:

Ingeniero de Sistemas

AUTORES:

Araujo Rodriguez, Jhon Alexander (orcid.org/0000-0001-6806-7840)

Medina Paquiuari, Fernando Jose (orcid.org/0000-0002-6521-4646)

ASESOR:

Dr. Alfaro Paredes, Emigdio Antonio (orcid.org/0000-0002-0309-9195)

LÍNEA DE INVESTIGACIÓN:

Sistema de Información y Comunicaciones

LÍNEA DE RESPONSABILIDAD SOCIAL UNIVERSITARIA:

Apoyo a la reducción de brechas y carencias en la educación en todos sus
niveles

LIMA - PERÚ

2023

Dedicatoria

Esta investigación está destinada a nuestros familiares por brindarnos seguridad, apoyo y confortar absolutamente en estos cinco años nuestros resultados profesionales.

Agradecimiento

En primer lugar, agradecemos a Dios por mantenernos con fuerza y salud. En segundo lugar, a nuestro asesor Dr. Emigdio Antonio Alfaro Parades por compartir su tiempo, experiencia y conocimientos profesionales en la investigación.

Declaratoria de Autenticidad del Asesor



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 Completa titulada: "Estudio comparativo de la eficiencia diagnóstica del cáncer de mama con los algoritmos CNN, NB y RF

", cuyos autores son MEDINA PAQUIYAURI FERNANDO JOSE, ARAUJO RODRIGUEZ JHON ALEXANDER, constato que la investigación tiene un índice de similitud de 19.00%, 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 Completa 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, 21 de Julio del 2023

Apellidos y Nombres del Asesor:	Firma
ALFARO PAREDES EMIGDIO ANTONIO DNI: 10288238 ORCID: 0000-0002-0309-9195	Firmado electrónicamente por: EALFAROP el 21-07- 2023 22:24:26

Código documento Trilce: TRI - 0608567

Declaratoria de Originalidad del/os Autor/es



UNIVERSIDAD CÉSAR VALLEJO

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

Declaratoria de Originalidad de los Autores

Nosotros, MEDINA PAQUIYAURI FERNANDO JOSE, ARAUJO RODRIGUEZ JHON ALEXANDER estudiantes de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA DE SISTEMAS de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA ESTE, declaramos bajo juramento que todos los datos e información que acompañan la Tesis Completa titulada: "Estudio comparativo de la eficiencia diagnóstica del cáncer de mama con los algoritmos CNN, NB y RF

", es de nuestra autoría, por lo tanto, declaramos que la Tesis Completa:

1. No ha sido plagiada ni total, ni parcialmente.
2. Hemos mencionado todas las fuentes empleadas, identificando correctamente toda cita textual o de paráfrasis proveniente de otras fuentes.
3. No ha sido publicada, ni presentada anteriormente para la obtención de otro grado académico o título profesional.
4. Los datos presentados en los resultados no han sido falseados, ni duplicados, ni copiados.

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

Nombres y Apellidos	Firma
FERNANDO JOSE MEDINA PAQUIYAURI DNI: 70415187 ORCID: 0000-0002-6521-4646	Firmado electrónicamente por: FMEDINAPAQ el 21-07-2023 23:09:53
JHON ALEXANDER ARAUJO RODRIGUEZ DNI: 75656443 ORCID: 0000-0001-6806-7840	Firmado electrónicamente por: JARAUJORO el 21-07-2023 23:09:53

Código documento Trilce: TRI - 0608566

Índice de Contenidos

Dedicatoria.....	ii
Agradecimiento.....	iii
Declaratoria de Autenticidad del Asesor.....	iv
Declaratoria de Originalidad del/os Autor/es.....	v
Índice de Contenidos.....	vi
Índice de tablas.....	vii
Índice de figuras.....	viii
Resumen.....	x
Abstract.....	xi
I. INTRODUCCIÓN.....	1
II. MARCO TEÓRICO.....	10
III. METODOLOGÍA.....	19
3.1 Tipo y diseño de investigación.....	20
3.2 Variables y operacionalización.....	21
3.3 Población (criterios de selección), muestra y muestreo, unidad de análisis.....	22
3.4 Técnicas e instrumentos de recolección de datos.....	23
3.5 Procedimientos.....	24
3.6 Método de análisis de datos.....	25
3.7 Aspectos éticos.....	25
IV. RESULTADOS.....	27
V. DISCUSIÓN.....	34
VI. CONCLUSIONES.....	39
VII. RECOMENDACIONES.....	42
REFERENCIAS.....	45
ANEXOS.....	61

Índice de tablas

Tabla 1 Criterios de inclusión y exclusión de la población.....	22
Tabla 2 Tipo y cantidad de imágenes mamográficas.....	23
Tabla 3 Resultado del diagnóstico con 7632 imágenes en CNN.....	28
Tabla 4 Resultado del diagnóstico con 7,632 imágenes en RF.....	29
Tabla 5 Resultado del diagnóstico con 7,632 imágenes en NB.....	30
Tabla 6 Comparación de los algoritmos CNN, RF y NB	30
Tabla 7 Resumen de las hipótesis específicas de la comparación	33
Tabla 8 Matriz de operacionalización de variables	62
Tabla 9 Matriz de consistencia	64
Tabla 10 Instrumentos de recolección de datos de imágenes.....	67

Índice de figuras

Figura 1 Arquitectura tecnológica para el entorno de desarrollo.....	68
Figura 2 Arquitectura tecnológica para el entorno de producción.....	69
Figura 3 Panel principal del sistema	70
Figura 4 Ventana emergente para seleccionar una imagen	70
Figura 5 Resultado del diagnóstico	71
Figura 6 Estadísticas de resultados de los algoritmos	71
Figura 7 Matriz de verificación de originalidad	75
Figura 8 Pseudocódigo del algoritmo CNN	76
Figura 9 Flujograma de algoritmo CNN.....	77
Figura 10 Pseudocódigo del algoritmo RF	78
Figura 11 Flujograma de algoritmo RF.....	79
Figura 12 Pseudocódigo del algoritmo NB.....	80
Figura 13 Flujograma de algoritmo NB.....	81
Figura 14 Panel principal del sistema	82
Figura 15 Apartado para visualizar los videos	82
Figura 16 Tarjetas de direccionamiento para cada algoritmo	83
Figura 17 Página para la carga de imagen con CNN	83
Figura 18 Página para el diagnóstico con CNN	84
Figura 19 Página para la carga de imagen con RF.....	84
Figura 20 Página para el diagnóstico con RF	85
Figura 21 Página para la carga de imagen con NB	85
Figura 22 Página para el diagnóstico con NB	86
Figura 23 Tabla de estadísticas de los resultados.....	86

Resumen

El objetivo de la investigación fue comparar la eficiencia diagnóstica del cáncer de mama en mujeres con los algoritmos CNN (Convolutional Neural Networks - Redes Neuronales Convolucionales), RF (Random Forest - Bosque Aleatorio) y NB (Naive Bayes - Bayesiana Ingenua). Se usó la matriz de confusión del sistema para comparar y plasmar los resultados de la sensibilidad, la especificidad, la precisión, la exactitud, el tiempo de entrenamiento y el tiempo de diagnóstico de cáncer de mama de los algoritmos mencionados.

Se consideró un total de 7632 imágenes mamográficas entre benignos (2520) y malignos (5112) para el diagnóstico de la enfermedad. La investigación fue de tipo aplicada, con un enfoque cuantitativo y diseño no experimental y tipo de diseño transversal descriptivo. Se usaron librerías gratuitas tales como Django, Keras, Tensorflow, OpenCV-Python, entre otras, para el desarrollo de lenguaje de programación Python. Además, se usó los criterios de inclusión y exclusión en la investigación para diferenciar qué imágenes no están incluidas y cuáles sí están incluidas para la población. Se utilizó el tipo y la cantidad de imágenes mamográficas para precisar la fuente (Data Science Kaggle) tipo (benigno y maligno), muestreo, el tiempo de identificación y tiempo de entrenamiento.

Los resultados de la comparación indicaron que NB tuvo una repercusión positiva en la sensibilidad y precisión, debido a que estos indicadores fueron mayores a los obtenidos por los algoritmos CNN y RF; asimismo, NB tuvo menor tiempo de entrenamiento e identificación. La especificidad y la exactitud no fueron mayores a los resultados obtenidos por el algoritmo RF, pero fueron mayores a lo obtenido por el algoritmo CNN. Se recomendó emplear el algoritmo regresión logística, con la finalidad de manejar datos de alta dimensionalidad, lo cual permite identificar características relevantes, manejar datos no lineales y capturar relaciones complejas en los datos para una investigación a futuro.

Palabras clave: Redes neuronales convolucionales, bayesiana ingenua, random forest, tiempo de identificación, exactitud.

Abstract

The purpose of the research was to compare the diagnostic efficiency of breast cancer in women with the CNN (Convolutional Neural Networks - Convolutional Neural Networks), RF (Random Forest - Random Forest), and NB (Naive Bayes - Naive Bayesian) algorithms. The system's confusion matrix was used to compare and capture the results of the sensitivity, specificity, precision, accuracy, training time, and breast cancer diagnosis time of the aforementioned algorithms. A total of 7,632 mammographic images between benign (2,520) and malignant (5,112) were considered for the diagnosis of the disease. The research was of the applied type, with a quantitative approach and non-experimental design and type of descriptive cross-sectional design. Free libraries such as Django, Keras, Tensorflow, OpenCV-Python, among others, were used for the development of the Python programming language. In addition, the inclusion and exclusion criteria were used in the research to differentiate which images are not included and which are included for the population. The type and quantity of mammographic images were used to specify the source (Data Science Kaggle), type (benign and malignant), sampling, identification time, and training time.

The results of the comparison indicated that NB had a positive impact on sensitivity and precision, because these indicators were higher than those obtained by the CNN and RF algorithms; likewise, NB had less training and identification time. The specificity and accuracy were not higher than the results obtained by the RF algorithm, but they were higher than those obtained by the CNN algorithm. It was recommended to use the logistic regression algorithm, in order to handle high-dimensional data, which allows identifying relevant characteristics, handling non-linear data, and capturing complex relationships in the data for future research.

Keywords: Convolutional Neural Networks, Naive Bayesian, Random Forest, identification time, accuracy

I. INTRODUCCIÓN

En este capítulo se presenta la realidad problemática que se basa en la detección preliminar del cáncer de mamá de estado maligno o benigno por medio de imágenes mamográficas. Además, este estudio fue justificado de forma tecnológica, social y teórica. El problema de la investigación fue el siguiente:

¿Cuál fue el algoritmo con la mejor eficiencia diagnóstica del cáncer de mama en mujeres entre CNN, NB y RF?

De igual manera, el objetivo de la investigación fue comparar la eficiencia diagnóstica del cáncer de mama en mujeres con los algoritmos CNN (Convolutional Neural Network - Redes Neuronales Convolucionales), NB (Naive Bayes – Bayesiana Ingenua) y RF (Random Forest – Bosque Aleatorio), teniendo en cuenta los diversos datos existentes, se resalta que comparar diversos algoritmos ayuda a un diagnóstico más detallado; por otro lado, se debe tener en cuenta los diversos métodos que emplean la detección del cáncer de mama (ultrasonido mamario, mamografía de diagnóstico, imagen por resonancia magnética, biopsia), ya que éstos varían según su objetivo y resultado final.

En primer lugar, el estudio se enfocó en los algoritmos existentes actualmente que ayudan en la detección y comprobación de cáncer de mama en mujeres, Además, se sintetizó las investigaciones no fundamentadas que necesitan nuevas interacciones de diversos datos (algoritmos) comparados, ante ello la búsqueda se hace indiferente en cuanto a los resultados arrojados. Los algoritmos CNN, RF y NB permiten contribuir a la solución de la misma problemática.

Las cantidades de diagnóstico benigno y maligno que engloba el cáncer de mama en mujeres contribuyen a realizar estudios de identificación y diagnóstico a gran escala que determinen las causas del problema teniendo resultados positivos como también negativos (Nasien et al., 2022, p. 1). Durán et al. (2019) mencionaron que esta enfermedad mamaria es uno de los orígenes más habituales de muerte en las mujeres y se da cuando se realiza un aumento de células dentro del tejido mamario (p. 3). El cáncer de

mama es peligroso debido a las multiplicaciones de células que se encuentran dentro los senos, ante ello nacen tratamientos y diagnósticos mediante la inteligencia artificial (IA) y algoritmos que pronostican esta enfermedad (Safdar et al., 2022, p. 2).

Dewangan et al. (2022) citaron a Zhang et al. (2020), quienes mencionaron que los grupos de datos del diseño CNN de detección de cáncer de mama pueden ser comprobados bajo una perspectiva de verificación cruzada y su ejecución solo ha demorado instantes; pero, el primordial problema es la baja sensibilidad de diagnóstico (p. 4). Cada algoritmo existente emplea formas de validación por intermedio de las pruebas de ejecución. Khan et al. (2019) establecieron un modelo de Red Neuronal Convolutiva (CNN) anticipadamente entrenado con VGGNet (Visual Geometry Group Net o Red del Grupo de Geometría Visual) para determinar los tejidos cancerosos mamarios (p. 4).

Se encontraron estudios que comparan algoritmos de detección de cáncer para optar por un mejor desempeño de los algoritmos al momento de realizar una prueba. Por otra parte, no se han encontrado estudios que utilicen algoritmos como CNN, RF y NB que ayuden a una mejor efectividad, al momento de diagnosticar el cáncer de mama. Gonçalves et al. (2022) citaron a Baffa y Lattari. (2019), quienes propusieron un nuevo algoritmo CNN para la organización de ilustraciones termo gráficas utilizando la base de datos DMR- IR, en las cuales se establecieron un total de 300 imágenes atónitas y resolutivas aplicando un incremento de información a modelos enfermos para adquirir una simetría en la base de datos. La CNN designada en la investigación de estos autores, procuraron imágenes en gradación de grises y en color, y manifestaron que las imágenes con tonos actuaban deseablemente, por lo que su desenlace para las ilustraciones atónitas obtuvo un 98% de precisión (en imágenes con tonos) y para las ilustraciones resolutivas (dinámicas) el 95% de precisión (p. 2). En otras palabras, al precisar imágenes utilizando CNN como base algorítmica se puede contraer etapas que diagnostiquen mejor los resultados.

Considerando los estudios realizados existen sistemas que hayan tenido un diagnóstico con más del 85% de precisión que comparan uno a más algoritmos para la detección del cáncer mamario, en esta investigación se propuso una comparación de los siguientes algoritmos, el CNN, RF y NB, de tal manera que indiquen los resultados en precisión ante los tumores de mama benignos y malignos.

Los estudios que comparan algoritmos para el diagnóstico de cáncer de mama son escasos en cada país y ante esto hay un desequilibrio de búsqueda de información como datasets (conjunto de datos de imágenes de cáncer de mama), ya que estas clases de datos son fundamentales en cuanto a la investigación de los algoritmos. Mamdouh (2021) mencionó que el diagnóstico de cáncer de mama es muy importante en el área de Medicina y Biomédica. Lo cual la combinación de algoritmos como deep learning ayuda en la precisión del diagnóstico de cáncer de mama (p. 8). Esto conlleva a que los algoritmos que son utilizados para el diagnóstico de cáncer de mama son importantes al momento de obtener pruebas de detección, en el cual tiene que ser preciso para el resultado final.

La justificación tecnológica de esta investigación se determinó en la necesidad de resaltar la eficacia y precisión de los algoritmos, ante ello se planteó una comparación de algoritmos eficaces y precisas al momento del diagnóstico, haciendo la comparación de tres algoritmos, tales como, CNN, RF y NB. Wang et al. (2018) mencionaron que tener un diagnóstico de cáncer de mama preciso es de suma importancia, que afecta directamente al tratamiento y seguridad de los pacientes, por otro lado, no solo requiere de una precisión, sino que también de una alta confiabilidad y solidez (p. 1).

La justificación teórica de esta investigación se determinó en la necesidad de profundizar aquellos enfoques teóricos que resaltan el uso de diversas tecnologías para diagnosticar el cáncer de mama, ante ello mencionan o sugieren que al usar diversas tecnologías y compararlas podrían ser satisfactorias y muy precisas al momento de hacer una prueba, debido que mientras más exactitud tenga el algoritmo mejor será su

diagnóstico. Al respecto, Rawat et al. (2022) examinaron seis algoritmos de aprendizaje supervisado por sus capacidades de pronóstico y detección en el diagnóstico preliminar de cáncer de mama (p. 5).

La justificación social de esta investigación está basada en el crecimiento de los casos con cáncer de mama. Al respecto, los especialistas de la American Society of Clinical Oncology (2022) mencionaron que 2'261,419 casos nuevos de cáncer de mama fueron diagnosticados en mujeres de todo el mundo y murieron 684,996 mujeres en el 2020, siendo la quinta causa de muerte. Existen diversos algoritmos que permiten el diagnóstico de enfermedades mediante imágenes, incluyendo el diagnóstico de cáncer de mama, lo que permite oportunidades para la mejora de los diagnósticos con la comparación de los algoritmos ya mencionados.

El problema general de la presente investigación fue: ¿Cuál fue el algoritmo con la mejor eficiencia diagnóstica del cáncer de mama en mujeres entre CNN, NB y RF? Los problemas específicos de la presente investigación son:

PE1: ¿Cuál fue el algoritmo con la mayor sensibilidad para el diagnóstico del cáncer de mama en mujeres entre CNN, NB y RF?

PE2: ¿Cuál fue el algoritmo con la mayor especificidad para el diagnóstico del cáncer de mama en mujeres entre CNN, NB y RF?

PE3: ¿Cuál fue el algoritmo con la mayor precisión para el diagnóstico del cáncer de mama en mujeres entre CNN, NB y RF?

PE4: ¿Cuál fue el algoritmo con la mayor exactitud para el diagnóstico del cáncer de mama en mujeres entre CNN, NB y RF?

PE5: ¿Cuál fue el algoritmo con el menor tiempo de entrenamiento para el diagnóstico del cáncer de mama en mujeres entre CNN, NB y RF?

PE6: ¿Cuál fue el algoritmo con el menor tiempo de identificación para el diagnóstico del cáncer de mama en mujeres entre CNN, NB y RF?

La presente investigación tuvo como objetivo general comparar la eficiencia diagnóstica del cáncer de mama en mujeres con los algoritmos CNN, NB y RF. Los objetivos específicos de la investigación son los siguientes:

OE1: Comparar la sensibilidad para el diagnóstico del cáncer de mama en mujeres con los algoritmos CNN, NB y RF.

OE2: Comparar la especificidad para el diagnóstico del cáncer de mama en mujeres con los algoritmos CNN, NB y RF.

OE3: Comparar la precisión para el diagnóstico del cáncer de mama en mujeres con los algoritmos CNN, NB y RF.

OE4: Comparar la exactitud para el diagnóstico del cáncer de mama en mujeres con los algoritmos CNN, NB y RF.

OE5: Comparar el tiempo de entrenamiento para el diagnóstico del cáncer de mama en mujeres con los algoritmos CNN, NB y RF.

OE6: Comparar el tiempo de identificación para el diagnóstico del cáncer de mama en mujeres con los algoritmos CNN, NB y RF.

La hipótesis general de la investigación fue: “El algoritmo NB tuvo mayor eficiencia diagnóstica del cáncer de mama en mujeres que los algoritmos CNN y RF”. Al respecto, Liu et al. (2022) explicaron:

Random Forest es un algoritmo de aprendizaje inspeccionado que tiene como fin buscar frecuentemente las cualidades de asociación para el desarrollo. El forest que se utiliza, es una incorporación del forest de dictámenes, que se refleja con procedimientos de guardado (p. 4).

Por otro lado, Burcak y Uguz (2022) tuvieron 8% de precisión y 91% de sensibilidad en imágenes histopatológicas aumentadas en 200x con el algoritmo NB (Naive Bayes) en el modelo de diagnóstico de cáncer de mama basado en DCNN “Deep Convolutional Neural Networks o Redes Neuronales Convolucionales Profundas” la cual procesa datos en forma de imágenes (p. 526). Como soporte teórico a la hipótesis general de la investigación, ElKorany y El sharkawy (2023) destacaron:

Los modelos Inception-V3, ResNet50 y AlexNet pre entrenados del algoritmo CNN en imágenes mamográficas respecto al tejido denso-glandular obtuvieron 92.86%, 97.62% y 95.24% en precisión; tejido graso 95.24%, 97.62%, 97.62% en precisión y tejido graso-glandular 97.56%, 97.56%, 100% en precisión respectivamente (p. 5).

Como soporte teórico a la hipótesis general de la investigación, Liew et al. (2021) resaltaron:

CNN de una sola tarea se utiliza para presagiar la perfidia y la CNN de múltiples tareas se utiliza para predecir anunciar la malicia y el grado de maximización de la imagen conjuntamente con la necesidad mayor del 83.13% (p. 2).

Las hipótesis específicas de la investigación fueron las siguientes:

HE1: El algoritmo NB tuvo mayor sensibilidad para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

Singh Harmandeep et al. (2022) propusieron un sistema de diagnóstico asistido por computadora teniendo a los algoritmos de NB Y RF, donde NB tuvieron una sensibilidad del 76.5% y exactitud del 6% con el K-fold (evalúa el rendimiento de un modelo de aprendizaje automático de manera más robusta), una especificidad y exactitud del 65% y 68.1% con el Hold-Out “técnica de partición de datos utilizada en el aprendizaje automático” (p. 6). Asimismo, Singh Harmandeep et al. (2022) tuvieron una sensibilidad del 76.5%, especificidad del 58% y

una exactitud del 57% con el Leave One Out “técnica de validación cruzada donde se entrena el modelo con todos los datos excepto uno, que se utiliza como conjunto de prueba” (p. 6).

HE2: El algoritmo NB tuvo mayor especificidad para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

Algehyne et al. (2022) en su investigación, obtuvieron un 98.34% de especificidad, mediante la extracción de características de las imágenes de cáncer de mama, utilizando como algoritmo principal Naive bayes. (p. 13). Por otro lado, Tran et al. (2022), mencionaron que, en su investigación obtuvieron un 96.90% de especificidad, usando como algoritmo base Random forest aplicando también la extracción de características de las imágenes mamográficas (p. 16).

HE3: El algoritmo NB tuvo mayor precisión para el diagnóstico del cáncer de mama que los algoritmos CNN y RF.

Sherina et al. (2020) usaron diversos algoritmos para la identificación de cáncer de mama, entre ellas Naive Bayes, donde usó el modelo PCA para el cálculo de clasificación, a consecuencia encontró que la precisión es del 95% (p. 62). Asimismo, Sherina et al. (2020) mencionaron que en su investigación el algoritmo RF (Random Forest) obtuvo un 94.16% de precisión, con un tamaño de muestra muy reducido, para ambas muestras se usaron 683 imágenes, las cuales 546 eran para el entrenamiento de los algoritmos y 137 para las pruebas (p. 62).

HE4: El algoritmo NB tuvo mayor exactitud para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

Abdulla et al. (2021) obtuvieron una exactitud 97.9% de diversos algoritmos, entre ellos Naive bayes, permitiendo así acceder a más funciones como embolsado y refuerzo, como estudios recientes han utilizado el enfoque de aprendizaje profundo, ya que puede extraer

características adecuadas automáticamente (p. 1977). Por otro lado, Abdulla et al. (2021) mencionaron que diferentes estudios emplearon la red neuronal de convolución (CNN) para clasificar los tumores de mama, un estudio evaluó tres conjuntos de datos con diferentes tamaños y logró una precisión muy alta que alcanzó el 97% (p. 1977).

HE5: El algoritmo NB tuvo menor tiempo de entrenamiento para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

Monja (2020) utilizó diversos algoritmos entre ellas Naive bayes, que sirvió para el proceso de entrenamiento con diversas fuentes de datos (dataset), el cual se tardó 23 ms (p. 39). Por otro lado, Paul et al. (2015) mencionaron que el modelo Random forest (bosque aleatorio) necesitó 12 minutos para el entrenamiento en la detección y clasificación de cáncer de mama (p. 101).

HE6: El algoritmo NB tuvo menor tiempo de identificación para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

Jayanthi y Wadhwa (2021) utilizaron 5 algoritmos entre ellos Naive Bayes y Random Forest demostrando una tasa de error muy baja y el tiempo de identificación más corto, tardando un alrededor de 0.08 segundos (p. 4444). Por otro lado, Thilagaraj et al. (2022) obtuvieron un tiempo de identificación de 16 segundos usando el algoritmo CNN con el modelo AFS en la clasificación de imágenes de cáncer de mama mediante la implementación de mejoras DCNN con el modelo de escuela de peces artificiales (p. 11).

II. MARCO TEÓRICO

En el presente capítulo se muestran los antecedentes relacionados a la investigación con estudios internacionales donde revelan los beneficios de utilizar diversos algoritmos para el diagnóstico preliminar de cáncer de mama. Se identificaron algoritmos y herramientas útiles para desarrollar nuevas propuestas que se plantearon en esta investigación, luego se dieron a conocer las teorías relacionadas sobre la detección de cáncer de mama con diversos algoritmos. Por último, se mencionó el marco conceptual el cual detalla los modelos teóricos, conceptos, argumentos e ideas que se desarrollaron en la investigación.

En la investigación, los antecedentes empleados fueron recopilados internacionalmente, dado que los algoritmos utilizados son más precisos y detallados en el diagnóstico de cáncer de mama mediante imágenes. De la misma manera, la gran parte de los artículos científicos recopilados con relación al diagnóstico de cáncer de mama tuvieron resultados de precisión, sensibilidad y tiempo entre los indicadores más resaltantes.

Nasien et al. (2022) verificaron el nivel de precisión de la retropropagación del algoritmo ANN (red neuronal artificial) mediante el algoritmo de red de retro programación para resolver problemas de identificación y predicción de comprobación de modelos. Nasien et al. (2022) elaboraron un nuevo algoritmo mediante fuentes relacionadas con Redes Neuronales Artificiales (ANN) mediante el método de propagación hacia atrás. Los autores concluyeron que la precisión del método ANN Back Propagation alcanzó el 96.93% con un error del 3.07% en predecir el cáncer de mama a través del proceso de entrenamiento y comprobación del sistema. Asimismo, Nasien et al. (2022) recomendaron esta investigación como futura referencia para otras investigaciones utilizando otros algoritmos como CNN, DNN, GA y ACO para una mejor eficiencia en el diagnóstico de cáncer de mama.

Safdar et al. (2022) evaluaron la precisión de los procedimientos de aprendizaje automático usando métodos o algoritmos como SVM, LR y

KNN. Safdar et al. (2022) realizaron etapas como: descripción del conjunto de datos, procesamiento (transformación de datos), clasificación (distinguir tumores benignos de malignos), K-modelo (KNN [K-Nearest Neighbor] - algoritmo clasificador de predicción de la precisión) para realizar el sistema CAD, además de emplear los métodos de curva ROC (evaluar rendimiento del algoritmo) y AUC (comparación de clasificadores). Los autores concluyeron que la precisión de los algoritmos SVM, LR y KNN de entrenamiento alcanzó el 97.7%, 94% y 100%. Safdar et al. (2022) recomendaron utilizar la clasificación microscópica de anomalías, tomando como referencia el algoritmo ANN (red neuronal artificial).

Rawat et al. (2022) determinaron que un hiperplano puede ayudar a separar los puntos negativos y positivos de la mamografía. Rawat et al. (2022) identificaron varias metodologías que ayuden en el procesamiento de imágenes, de tal manera que se pueda minimizar la probabilidad de muerte por año, por lo que es importante aplicar variadas técnicas de aprendizaje automático para aumentar la precisión en diagnóstico del cáncer de mama. Como resultado del estudio concluyeron que los pacientes con cáncer de mama con una temprana detección tienen más probabilidades de ser curados. Asimismo, Rawat et al. (2022) recomendaron la implementación de los métodos de aprendizaje con algoritmos genéticos tales como: ACO (Ant Colony Optimization u optimización de colonias de hormigas), PSO (Particle Swarm Optimization u optimización de enjambre de partículas), etc.

Liu et al. (2022) analizaron cómo predecir de manera efectiva la metástasis del cáncer de mama, dado que los algoritmos XGBoost, Random Forest y Gradient-enhanced son más eficientes (0.724967, 0.745329 y 0.730603, respectivamente) en la precisión. Liu et al. (2022) usaron como muestra a 127 mujeres con cáncer de mama las cuales fueron diagnosticadas patológicamente. Como consecuencia se logró una evaluación que funcionó bien en datos clínicos, dando a conocer que el aprendizaje automático y las características artificiales tienen una detección muy eficiente en imágenes. Asimismo, Liu et al. (2022) concluyeron que para

evitar o reducir la influencia se debe extraer y caracterizar las recurrencias de las imágenes histopatológicas, ya que serán el foco de investigación en el futuro. Liu et al. (2022) recomendaron que el indicador de precisión puede aumentar en otras investigaciones a futuro, utilizando los algoritmos XGBoost, Random Forest y Gradient-enhanced incluyendo la tecnología artificial.

Sugiharti et al. (2022) determinaron que las etapas de integración de CNN- XGBoots en el diagnóstico de cáncer de mama permite calcular la precisión y la detección. Sugiharti et al. (2022) usaron como muestra la recolección de datos que consta de 162 imágenes de muestras de cáncer de mama, de las cuales se dividieron en negativa y positiva. Los autores concluyeron que el aumento de datos y el aprendizaje de CNN-XGBoost ayudan a un mejor entrenamiento de datos y pruebas en las cuales el 70% son de entrenamiento, el 30% para su aprendizaje y la precisión incrementó un 2% (de 88% al 90%). Asimismo, Sugiharti et al. (2022) recomendaron que se puede maximizar el conjunto de datos con el mismo algoritmo CNN-XGBoost añadiendo parámetros distintos.

Ma et al. (2022) pronosticaron la supervivencia de las mujeres con cáncer de mama en China. Ma et al. (2022) realizaron un diseño retrospectivo que consistía en dividir aleatoriamente un conjunto de entrenamiento para la validación interna y externa del modelo. Como consecuente del análisis el modelo de predicción tuvo una buena discriminación y calibración del modelo, por lo que la importancia de este es saber la tasa de supervivencia y el tratamiento del cáncer de mama. Asimismo, Ma et al. (2022) recomendaron que para futuros estudios se debe enfatizar la adherencia a la terapia para ayudar a los médicos y pacientes a tomar decisiones médicas precisas e individuales de los pacientes.

Matsangidou et al. (2022) maximizaron la calidad asistencial que ofrecen las nuevas ciencias para la medicina personalizada. Matsangidou et al. (2022) tomaron como diseño a profesionales en el ámbito de la salud especializados en cáncer, científicos informáticos e interacción humano-

computadora (HCI). Para esto, se hizo un estudio que diagnosticó la realidad y validez de la RV para la aflicción en personas con cáncer. Como resultado de la investigación se concluyó que la tecnología RV junto a los análisis de sistemática, ofrecen entornos relevantes virtuales utilizando aplicaciones móviles en pacientes con cáncer. De igual modo, Matsangidou et al. (2022) recomendaron que el uso de aplicaciones móviles con RV sostienen características de interacción social, ya que puede optimizar el estudio a personas con cáncer.

Suchodolska y Senkus (2022) recopilaron estudios de tecnología móvil para verificar resultados secundarios en personas con cáncer de mama no avanzado. Suchodolska y Senkus (2022) realizaron un control de efecto basado en guías del Instituto Joanna Briggs para determinar artículos que concedan razones del desarrollo y de aplicaciones móviles para personas con quimioterapia para el cáncer de mama. Los autores concluyeron que las tecnologías móviles desempeñan estrategias para el control de cáncer de mama, dando prioridad a los estudios digitales, otorgando viabilidad y beneficios. Suchodolska y Senkus (2022) recomendaron que se necesita más indagación para ratificar estos recursos, garantizando la realidad y garantía para los usuarios que empleen esta tecnología.

Tran et al. (2022) propusieron un método de muestra ascendente (ENUS: muestreo superior diseñado propuesto para manejar el desequilibrio de datos) para aumentar la predicción en los algoritmos de aprendizaje automático como: RF, Neural Network, KNN, SVM y XGBoost, conjuntamente con los modelos NNet, NNet-ML y árbol de decisión (DT). Tran et al. (2022) utilizaron como diseño el lenguaje de programación R para observar y adentrar modelos predictivos en la precisión y sensibilidad. Concluyeron que los modelos junto al sueño ENUS obtuvieron 3.74% más de precisión, 8,36% de sensibilidad y con una predicción del 2.%. Tran et al. (2022) recomendaron que los datos agrupados que tengan similitud con datos demográficos se usarán para desarrollar las maquetas con algoritmos de aprendizaje como el XGBoost, RF, KNN u otros.

Haydar y Ali (2022) estudiaron algoritmos de aprendizaje automático (KNN, ANN, CNN, RNN, SVM, NB y AdaBoost) para pronosticar y diagnosticar el cáncer de mama y hallar qué algoritmo es más eficiente ante el rendimiento de cada indicador de precisión, especificidad, exactitud y sensibilidad. Haydar y Ali (2022) emplearon comparación de estudios de aprendizaje automático para usar como metodología la extracción y clasificación de imágenes (resonancia magnética) utilizando histogramas, métodos y algoritmos. Concluyeron que la clasificación y extracción de características contribuyen al diagnóstico de cáncer de mama, optando por una eficiencia (96%), precisión (97%) en los algoritmos ANN y SVM. Haydar y Ali (2022) recomendaron a futuro que, con diferentes bases de datos y empleando los algoritmos (KNN, ANN, CNN y RNN) u otros pueden obtener mejores resultados con aumento en la precisión.

Sun et al. (2022) analizaron el desempeño del examen en el diagnóstico de cáncer de mama. Sun et al. (2022) utilizaron un estudio retrospectivo enfocado en la recolección de ilustraciones CEM entre los años 2018 - 2020, donde clasificaron a pacientes con lesiones mamarias, las cuales fueron un total de 161 mujeres (47 benignos, con un 19.2% y 114 malignos, con un 70.8%). Asimismo, recomendaron que los métodos como la utilización de algoritmos postdesarrollados, pueden probablemente ser más exactos y concisos además de descifrables.

Agouri et al. (2022) analizaron el delinear de un ángulo computarizado apoyado en redes neuronales convolucionales complejas para una organización competente de imágenes histopatológicas de cáncer de mama. Agouri et al. (2022) optaron por tomar una metodología de imágenes patológicas que provoca un lineamiento con especificación en las ilustraciones. Como resultado de la investigación concluyeron que la metodología propuesta basada en imágenes histológicas BC relacionadas con HE (datos de entrenamiento de 328 muestras) se distingue lo benigno de lo maligno. Asimismo, sugirieron que el algoritmo CNN puede ser usado,

interpretado y evaluado en distintos modelos para el proceso de extracción de características en distintos tipos de cáncer.

Singh et al. (2022) analizaron el seguimiento sistemático en distintas estructuras y moldes geométricos en la clasificación de la enfermedad mamaria. Singh et al. (2022) propusieron la metodología de extracción de lesión de masa exacta y extracción de características optando por un análisis comparativo de las clasificaciones de textura dando a conocer una estimación del 73.0% en la sensibilidad y 92.0% en el diagnóstico. Como resultado de la investigación concluyeron que el marco de trabajo de aprendizaje automático, emplea una reducción de las características y textura. Singh et al. (2022) recomendaron que el estudio y la utilización de los algoritmos de selección pueden explorar otros temas incluidos en el aprendizaje interno para la clasificación de las masas mamarias.

Naji et al. (2021) diagnosticaron el cáncer de mama, empleando algoritmos (SVM, Random Forest, Logistic Regression, Decision Tree (C4.5), KNN Network) de aprendizaje. Naji et al. (2021) emplearon el método de obtención de información procesada (integridad de datos, elección de atributos, detallar roles y supresión de propiedades) para identificar el algoritmo que se asemeje en la detección del cáncer de mama. Concluyeron que junto al diagnóstico de Wisconsin WBCD y los algoritmos utilizados como SVM, KNN, Random Forest, Logistic Regression y Decision Tree obtuvieron una mayor eficiencia (97.2%), precisión (97.5%). Naji et al. (2021) recomendaron emplear los algoritmos (SVM, Random Forest, Logistic Regression, Decision Tree (C4.5), KNN Network) para optar una base de datos de ilustraciones de cáncer, además de combinar otros algoritmos que tengan una precisión más clara para esta enfermedad.

Skarping et al. (2021) aplicaron métodos apoyados en el aprendizaje profundo para el análisis automático de mamografías digitales como herramienta para la evaluación de la respuesta al tratamiento del cáncer de mama usando el algoritmo red neuronal convolucional (CNN). Skarping et al.

(2021) usaron DM (mamografías digitales) con 1485 imágenes para presagiar resultados patológicos (PCR). Concluyeron que el sistema (IA) reconoce el PCR del DM resultando una sensibilidad del 46% y 90% de especificidad. Asimismo, Skarping et al. (2021) recomendaron que el sistema IA en predicción de respuestas, puede incluirse en otras investigaciones utilizando el algoritmo CNN con diferentes metodologías y un tamaño de muestra más grande.

En relación con las tecnologías y teorías mencionadas, el algoritmo Random Forest es uno de los algoritmos de clasificación de imágenes más utilizados en la detección de cáncer de mama en mujeres. Una de las ventajas es que proporcionó una evaluación interna de la precisión ante la imagen, tomando en cuenta que, si se mejora el algoritmo, este podría obtener una estimación de exactitud muy elevada y realista, teniendo en cuenta que su capacidad de predicción no disminuye (García et al., 2016, p. 359). Por otro lado, Random Forest es uno de los algoritmos de clasificación de imágenes más utilizados. Por lo que una de sus ventajas es proporcionar una evaluación interna de la precisión en forma de validación cruzada. Sin embargo, esta estimación subestima el error de clasificación de las imágenes por píxeles, ya que si hay error entraría en un estado de entrenamiento y validación de píxeles (García et al., 2016, p. 360).

En la actualidad, la mamografía es el método de detección más eficaz para la detección de esta enfermedad. Sin embargo, un diagnóstico que realizó un especialista no siempre es válido por diferentes razones tales como, el descuido o la vista cansada, o la calidad de la mamografía. Por lo que existen diversos métodos en las cuales estas enfermedades pueden ser clasificadas o detectadas por computadoras para la clasificación de regiones, en las cuales se clasifican por un tejido sano, aplicando algoritmos de Deep Learning como son las redes neuronales convolucionales (Durán et al., 2019, p. 89).

En los últimos años se desarrollaron diversos métodos en los cuales se hace un estudio analógico de las imágenes, las cuales son computarizadas para el diagnóstico de enfermedades. Los estudios realizados en la detección temprana de cáncer de mamá, es con una población abierta de mujeres asintomáticas de más de 40 años de edad, las cuales son llamadas "tamizaje", ante ello se permite realizar de forma especial y precisa los hallazgos y clasificadores que tiene esta enfermedad, tanto como normales y benignos (Díaz et al., 2011, p. 8).

El tiempo de aprendizaje se ve afectado por el proceso de escalado de las imágenes y las partes insignificantes de las imágenes pueden eliminarse del proceso de aprendizaje (Murthy y Balaji 2022, p. 458). Por otro lado, muchas suelen ser pérdidas o incurridas durante el entrenamiento y la validación de la precisión benigna y maligna de las imágenes mamográficas (Murthy y Balaji, 2022, p. 459).

Ahmad et al. (2022) utilizaron un método basado en gráficos para clasificar el cáncer de mama y obtuvieron una precisión del 88.90%, pero tenían una gran complejidad de tiempo [200 seg] (p. 2). Por otro lado, mencionaron que los resultados experimentales indicaron que la exactitud, precisión, sensibilidad y especificidad indican un 99.50%, 98.10%, 98.90% y 97.50% respectivamente, para así poder reducir los errores patológicos cometidos durante el proceso de diagnóstico (Ahmad et al., 2022, p. 2).

Los resultados de precisión de diagnóstico del algoritmo junto a la evaluación de los análisis manuales distribuidos por SBCE obtuvieron una especificidad del 94% en el algoritmo CNN (Holloway et al., 2022, p. 9). Adicionalmente, indicaron en su investigación, "Medición de similitud en la clasificación de mamografías digitales" que el análisis de precisión detallada y ROC utilizó la medición Weka 3.6 (validación cruzada), adherida a las propiedades seleccionadas y evaluaciones de afinidad arrojando una especificidad de 100% (Alimudin et al., 2022, p. 8).

III. METODOLOGÍA

Este capítulo explica que esta investigación fue de tipo aplicada, con un enfoque cuantitativo, diseño no experimental y tipo de diseño transversal descriptivo. También se mencionan las mediciones de razón, las cuales fueron: sensibilidad, especificidad, precisión, exactitud y las mediciones de valor: tiempo de entrenamiento y tiempo de identificación para los algoritmos CNN, RF y NB. Asimismo, se determinó la población lo cual está basada en las fotografías mamográficas de la plataforma de Data Science Kaggle y por último se muestran los aspectos éticos de la investigación.

Finalmente, se efectuó la comparación de los algoritmos para el diagnóstico de cáncer de mama en mujeres mediante imágenes mamográficas basado en los algoritmos CNN, RF y NB en la muestra. Conjuntamente, se detallaron los instrumentos y técnicas de recolección de datos para recopilar la muestra y optar por el muestreo, además se realizó los procedimientos para el procesamiento de las imágenes, también se realizó la medición de las variables e indicadores. Por último, se ejecutaron los Códigos de Ética de la Universidad César Vallejo y los Código de Ética del Colegio de Ingenieros del Perú para adoctrinar las normas para la investigación.

3.1 Tipo y diseño de investigación

La presente investigación fue de tipo aplicada, lo que demuestra que pertenece al enfoque cuantitativo, lo que resultó ser equivalente a la investigación aplicada, debido a que en el desarrollo del proyecto se utilizaron diversos los algoritmos propuestos por diferentes autores para el diagnóstico preliminar de enfermedades. Nieto (2018) explicó que el propósito del tipo de investigación aplicada es mejorar, completar y optimizar el desempeño de cualquier sistema gracias al desarrollo de la ciencia y la tecnología. En otras palabras, este tipo de investigación no puede clasificarse en verdadera, falsa o probable, efectiva o ineficaz.

El enfoque de la presente investigación fue cuantitativo, ya que se basa en la recolección de datos para el análisis para así probar la hipótesis requerida mediante procedimientos estadísticos (Otero, 2018, p. 3). Por otro lado, Meneses (2022) explicó que el enfoque cuantitativo es lineal y sigue un enfoque positivista. Se basa en proposiciones teóricas y utiliza un enfoque hipotético-deductivo para probar, verificar o refutar hipótesis, sin regresar a etapas previas (p. 437).

El diseño de la investigación fue no experimental. Asimismo, Calderón y Alzamora (2019) mencionaron que en un estudio no experimental, el investigador observa los fenómenos en su estado natural, sin intervenir en su desarrollo, registrando los eventos tal y como ocurren sin realizar modificaciones o influencias externas (p. 73). Por otro lado, Calderón y Alzamora (2019) mencionaron que los diseños de corte transversal son aquellos en los que se recopilan datos en un único momento, sin importar la duración o el momento específico en que se realiza la medición. Estos métodos se caracterizan por evaluar la muestra una sola vez, sin tener en cuenta el tiempo que tomó para realizarlo (p. 73).

3.2 Variables y operacionalización

Se determinó que las variables de la investigación fueron las siguientes: Sensibilidad, Especificidad, Precisión, Exactitud, Tiempo de entrenamiento y Tiempo de identificación. La matriz de operacionalización de variables se ubica en el **ANEXO 1**.

Definición conceptual

La precisión es una etapa del desarrollo de medición que se enfoca a cómo alcanzar la medida en cuestión, para este detalle la utilización de instrumentos mide una variable entrenando la exactitud es el valor que se asemeja al valor real. Además, señala el nivel de relación o afinidad al asignar este procedimiento, realizando bajo los mismos criterios dispuestos.

Gargouri et al. (2022) definieron que el estudio del sistema planteado consciente en el diagnóstico de masas en ilustraciones mamográficas. Por otra parte, las contribuciones desarrolladas, se basaron en un criterio heurístico donde las cualidades se equilibran aleatoriamente, para incrementar una longitud interclase anticipada y disminuir el trayecto intraclase (p. 2).

Definición operacional

Karunanayake et al. (2022) señalaron que cada vez que se determina la precisión de un método en un grupo de fotografías, es importante distinguir los fraccionamientos. Dado esto, la precisión promedio (80%), pero una simplificación en la precisión (20%) en pocas ilustraciones. De modo que, es razonable no introducir los casos errados en el desvío central de la medición (p. 10). Además, Nguyen et al. (2022), indicaron que el método de localización describe aspirantes con función cardinal práctico para disminuir el tiempo y el importe de las comprobaciones erradas en las etapas de la indagación experimental (p. 4). Seguidamente, Peña (2022) indicó que la exactitud es de un aspecto que engloba y está dirigido a determinar la ejecución general del ejemplar al conocer cuántas verdades de clasificación se adquirieron en completo (p. 7).

3.3 Población (criterios de selección), muestra y muestreo, unidad de análisis

3.3.1 Población

Este estudio tuvo como población a 7632 imágenes mamográficas de tipo radiografías (rayos x) adquiridas de la plataforma de Data Science Kaggle, las cuales están clasificadas en benignos con una totalidad de 2520 imágenes y malignos con un total de 5112 (Maqsood et al., 2022, p. 21).

Tabla 1 Criterios de inclusión y exclusión de la población

INCLUSIÓN	EXCLUSIÓN
<ul style="list-style-type: none"> • De tipo mamográfica 	<ul style="list-style-type: none"> • Imágenes distorsionadas
	<ul style="list-style-type: none"> • De tipo histopatológicas
	<ul style="list-style-type: none"> • De tipo ultrasónico

3.3.2 Muestra y Muestreo

Se determinó que la muestra de la presente investigación se conforma en la totalidad 7632 imágenes mamográficas adquiridas de la plataforma de Data Science Kaggle, las cuales están clasificadas en benignos con un total de 2520 imágenes y malignos con un total de 5112. La galería de imágenes en la categoría (In Breast dataset) fue obtenida en el siguiente enlace: <https://data.mendeley.com/datasets/ywsbh3ndr8/5>.

3.3.3 Unidad de análisis

La unidad de análisis para la presente investigación estuvo conformada por los datasets basada en las fotografías de cáncer de mama benigno y maligno que se obtuvieron de la plataforma de Data Science Kaggle. En la tabla 2 se aprecia la división de fotografías de tipo monográfico del cáncer de mama clasificados en benigno y maligno.

Tabla 2 Tipo y cantidad de imágenes mamográficas

Fuente	Tipo	Muestro	Imágenes de entrenamiento	Imágenes de identificación
Data Science Kaggle	Benigno	2520	2016	504
	Maligno	5112	4089	1023
Total de Imágenes		7632	6105	1527

3.4 Técnicas e instrumentos de recolección de datos

La técnica utilizada fue la observación y se utilizó un instrumento para registrar los datos obtenidos de los tres algoritmos utilizados, el cual fue una ficha de recolección de datos de Microsoft Excel utilizando las variables descritas en este estudio. Además, este estudio utilizó la validez de contenido con el apoyo teórico de las siguientes variables: exactitud, precisión, tiempo de identificación, tiempo de entrenamiento, sensibilidad y especificidad, logrando aprobar el instrumento de recolección de datos. Los Instrumentos de recolección de datos de imágenes se ubican en el anexo 3.

3.5 Procedimientos

Al tener las imágenes mamográficas y el algoritmo para el preprocesamiento de las 7632 imágenes, se puede caracterizar por ser benignas y malignas, obteniendo un resultado de diagnóstico y así poder determinar el tipo de cáncer de mama, de tal manera que alcance distinguir los diversos resultados obtenidos, para así calcular la sensibilidad, especificidad, exactitud, precisión, tiempo de entrenamiento y tiempo de identificación de los diagnósticos. A continuación, se muestra los pasos del procedimiento:

- A. Se utilizó una ficha o tabla de registro para la recolección de datos que permitirá clasificar y analizar las imágenes mamográficas.
- B. Los campos establecidos en la tabla o ficha son: código de la imagen mamográfica, tipo de imagen, sexo, positivo en cáncer (diagnóstico) y resultado del contenido.
- C. Una vez obtenido el algoritmo se procederá al pre procesamiento de las imágenes estimadas.
- D. Se evaluó las cualidades y características para detectar el cáncer de mama.
- E. Una vez añadidas estas características se consideró extraer un diagnóstico que permita calcular la sensibilidad, especificidad, exactitud, precisión, tiempo de identificación y tiempo de entrenamiento.

A continuación, se muestra los criterios a tomar para la recolección de imágenes:

- Código de imagen mamográfica
- Tipo de imagen (mamográfica de rayos x)
- Clasificación (benigno y maligno)
- Sexo

3.6 Método de análisis de datos

Los rendimientos alcanzados del sistema fueron incluidos en las tablas exhibidas, destinando sus correspondientes fórmulas para alcanzar los porcentajes de todos los indicadores. Las variables de esta investigación fueron las siguientes: sensibilidad, exactitud, especificidad, precisión, tiempo de identificación y tiempo de entrenamiento. Por lo tanto, se usó la misma aplicación para los cálculos de los indicadores que se mostraron en la matriz de confusión del sistema.

3.7 Aspectos éticos

Gamarra y Santos (2019) mencionaron que el inadecuado uso de exámenes de diagnóstico por laboratorio genera desventajas y gastos por emplear improcedentemente medios o recursos, campos de trabajos que atentan con la finalidad de la calidad y el intervalo de resolución en los resultados (p. 23). Además, Insua (2018) expresó que la ética biomédica alude a la beneficencia, donde señala que se usa como una forma efectiva de realizar los procedimientos o métodos, dando énfasis en beneficio a los tratados (p. 231).

Esta investigación cumple diversos aspectos éticos, morales y profesionales que implanta la Universidad César Vallejo, que son expuestos en el Código de Ética en el artículo 1, donde se ajusta que los trabajos de investigación que son desarrollados dentro de la universidad tienen que llevar a término los límites de compromiso, integridad y académico para respaldar la regularidad en el juicio de ética, de tal manera que ayuda a proteger los derechos y propiedad intelectual de cada investigador. También fomenta las buenas prácticas de investigación, promoviendo la integridad científica y fortaleciendo la educación (Universidad César Vallejo, 2022, p. 5). Por otro lado, el artículo 9 menciona que cada integrante de la investigación debe confirmar que se realizó de manera estricta y legal, por lo que debe cumplir con las condiciones hasta la culminación de dicha investigación (Universidad César Vallejo, 2022, p. 10).

En resumen, los artículos recomiendan que todos los miembros realicen adecuadamente los siguientes estudios para garantizar su derecho a postularse, ya que el estudio del informe tuvo que pasar por varios procesos de revisión para ser aprobado. También menciona que debe hacerse en el formato ISO 690 y 690-2:2017 para evitar plagio, infracciones o incumplimientos, ya que se deben citar las ideas u opiniones encontradas.

La investigación de este proyecto se ajusta y relaciona con los artículos del Código de Ética del Colegio de Ingenieros del Perú, como el artículo 13, que especifica que el Código de Ética determina las responsabilidades y obligaciones relacionadas con este método disciplinario. La actividad profesional debe estar relacionada con las metas y objetivos de la institución, por lo que esta investigación sigue siendo una idea importante, para cumplir con las normas y reglas establecidas para el desarrollo de esta investigación (Colegio de Ingenieros del Perú, 2022, p. 2).

IV. RESULTADOS

Este capítulo explica los resultados alcanzados en la investigación aludiendo a los indicadores de precisión, especificidad, sensibilidad, exactitud, tiempo de entrenamiento y tiempo de identificación. De igual manera, se examinó el producto de los resultados CNN, RF y NB en paralelismo o comparación con el algoritmo fusionado, teniendo como diagnóstico a las imágenes mamográficas del dataset.

4.1 Resultado de los indicadores

A continuación, se presentan los resultados de las pruebas obtenidas y realizadas con un total de 7632 imágenes, el algoritmo CNN, el algoritmo RF y el algoritmo Naive Bayes referente a los indicadores.

4.1.1 Resultados de los indicadores con el algoritmo CNN

En la tabla 3 se presentan los resultados con 7,632 imágenes mamográficas divididas en malignos (5,112) y benignos (2,520) del dataset “Data Science Kaggle”. Expresa que, de 4,918 verdaderos, VP (verdaderos positivos): 3,320, VN (verdaderos negativos): 1,598; de 2,714 falsos, FP (falsos positivos): 1,792, FN (falsos negativos): 922, por ende, un total de positivos de 5,112 y un total de negativos de 2,520; con un total en tiempo de identificación de 138.2233 y un tiempo de entrenamiento de 3.7991 en ms (milisegundos). Por otro lado, el algoritmo CNN obtuvo una sensibilidad de 78.265%, una especificidad de 77.1386%, una exactitud de 64.4392% y una precisión de 64.9452%.

Tabla 3 Resultado del diagnóstico con 7632 imágenes en CNN

A L G O R I T M O C N N	VP	VN	FP	FN	Tiempo de Entrenamiento	Tiempo de Identificación
	3320	1598	1792	922	3.7991 milisegundos	138.2233 milisegundos
	Total de Verdaderos: 4918		Total de Falsos: 2714			
	Total de positivos: 5112					
	Total de negativos: 2520					
	Sensibilidad	Especificidad	Exactitud	Precisión		
	78.265%	77.1386%	64.4392%	64.9452%		

4.1.2 Resultados de los indicadores con el algoritmo RF

En la tabla 4 se presentan los resultados con 7,632 imágenes mamográficas divididas en malignos (5,112) y benignos (2,520) del dataset “Data Science Kaggle”. Expresa que de 683 verdaderos VP (verdaderos positivos): 180, VN (verdaderos negativos): 503; de 81 falsos FP (falsos positivos): 77, FN (falsos negativos): 4, por ende, un total de positivos de 257 y un total de negativos de 507; con un total en tiempo de identificación de 0.0039 y un tiempo de entrenamiento de 0.0618 en ms (milisegundos). Por otro lado, el algoritmo RF obtuvo una sensibilidad de 97.8261%, una especificidad de 87.7241%, una exactitud de 89.3979% y una precisión de 70.0389%.

Tabla 4 Resultado del diagnóstico con 7,632 imágenes en RF

ALGORITMO RF	VP	VN	FP	FN	Tiempo de Entrenamiento	Tiempo de Identificación
	180	503	77	4	0.0618 milisegundos	0.0039 milisegundos
	Total de Verdaderos: 683		Total de Falsos: 81			
	Total de positivos: 257					
	Total de negativos: 507					
	Sensibilidad	Especificidad	Exactitud	Precisión		
	97.8261%	87.7241%	89.3979%	70.0389%		

4.1.3 Resultados de los indicadores con el algoritmo

En la tabla 5 se presentan los resultados con 7,632 imágenes mamográficas divididas en malignos (5,112) y benignos (2520) del dataset “Data Science Kaggle”. Expresa que de 671 verdaderos VP (verdaderos positivos): 156, VN (verdaderos negativos): 515; de 93 falsos FP (falsos positivos): 93, FN (falsos negativos): 0, por ende, un total de positivos de 249 y un total de negativos de 515; con un total en tiempo de identificación de 0.0006 y un tiempo de entrenamiento de 0.0043 en ms (milisegundos). Por otro lado, el algoritmo NB obtuvo una sensibilidad de 100%, una especificidad del 84.7039%, una exactitud de 87.8272% y una precisión de 72.6506%.

Tabla 5 Resultado del diagnóstico con 7,632 imágenes en NB

ALGORITMO NB	VP	VN	FP	FN	Tiempo de Entrenamiento	Tiempo de Identificación
	156	515	93	0	0.0043 milisegundos	0.0006 milisegundos
	Total de Verdaderos: 671		Total de Falsos: 93			
	Total de positivos: 249					
	Total de negativos: 515					
	Sensibilidad	Especificidad	Exactitud	Precisión		
	100%	84.7039%	87.8272%	72.6506%		

4.1.4 Comparación de los algoritmos CNN, RF y NB

En la tabla 6 se mostrará la comparación en cuanto a los indicadores de sensibilidad, especificidad, exactitud y precisión en la unidad de proporción (porcentual) y los tiempos de identificación y tiempo de entrenamiento en milisegundos. Entre los algoritmos CNN RF y NB.

Tabla 6 Comparación de los algoritmos CNN, RF y NB

	CNN	RF	NB
Sensibilidad	78.265%	97.8261%	100%
Especificidad	77.1386%	87.7241%	84.7039%
Precisión	64.9452%	70.0389%	72.6506%
Exactitud	64.4392%	89.3979%	87.8272%
Tiempo de Entrenamiento	3.7991 (ms)	0.0618 (ms)	0.0043 (ms)
Tiempo de Identificación	138.2233 (ms)	0.0039 (ms)	0.0006 (ms)
Verdaderos Positivos	3320	180	156
Verdaderos Negativos	1598	503	515
Falsos Positivos	1792	77	93
Falsos Negativos	922	4	0

4.2 Prueba de hipótesis específicas

Se muestran las pruebas de hipótesis para cada una de las 6 hipótesis de la investigación empleada.

4.2.1 HE1 - Primera hipótesis específica

HE10: El algoritmo NB no tuvo mayor sensibilidad para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

HE11: El algoritmo NB tuvo mayor sensibilidad para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

La sensibilidad para el algoritmo NB fue 100% y para los algoritmos CNN y RF fueron 78.265% y 97.8261%, respectivamente. Por lo expuesto, se rechazó la hipótesis nula y se aceptó la hipótesis alternativa con respecto a que se tuvo mayor sensibilidad con el algoritmo NB para el diagnóstico de cáncer de mama en mujeres que con los algoritmos CNN y RF.

4.2.2 HE2 - Segunda hipótesis específica

HE20: El algoritmo NB no tuvo mayor especificidad para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

HE21: El algoritmo NB tuvo mayor especificidad para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

La especificidad para el algoritmo NB fue 84.7039% y para los algoritmos CNN y RF fueron 77.1386% y 87.7241%, respectivamente. Por lo expuesto, se aceptó la hipótesis nula y se rechazó la hipótesis alternativa, ya que no se tuvo mayor especificidad con el algoritmo NB para el diagnóstico del cáncer de mama en mujeres que con los algoritmos CNN y RF.

4.2.3 HE3 - Tercera hipótesis específica

HE30: El algoritmo NB no tuvo mayor precisión para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

HE31: El algoritmo NB tuvo mayor precisión para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

La precisión para el algoritmo NB fue 72.6506% y para los algoritmos CNN y RF fueron 64.9452% y 70.6506%, respectivamente. Por lo expuesto, se rechazó la hipótesis nula y se aceptó la hipótesis alternativa con respecto a que se tuvo mayor precisión con el algoritmo NB para el diagnóstico del

cáncer de mama en mujeres que con los algoritmos CNN y RF.

4.2.4 HE4 - Cuarta hipótesis específica

HE40: El algoritmo NB no tuvo mayor exactitud para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

HE41: El algoritmo NB tuvo mayor exactitud para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

La exactitud para el algoritmo NB fue 87.8272% y para los algoritmos CNN y RF fueron 64.4392% y 89.3979%, respectivamente. Por lo expuesto, se aceptó la hipótesis nula y se rechazó la hipótesis alternativa con respecto a que no se tuvo mayor exactitud con el algoritmo NB para el diagnóstico del cáncer de mama en mujeres que con los algoritmos CNN y RF.

4.2.5 HE5 - Quinta hipótesis específica

HE50: El algoritmo NB no tuvo menor tiempo de entrenamiento para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

HE51: El algoritmo NB tuvo menor tiempo de entrenamiento para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

El tiempo de entrenamiento del algoritmo NB fue 0.0043 milisegundos y para los algoritmos CNN y RF fueron 3.7991 y 0.0618 milisegundos, respectivamente. Por lo expuesto, se rechazó la hipótesis nula y se aceptó la hipótesis alternativa con respecto a que se tuvo menor tiempo de entrenamiento con el algoritmo NB para el diagnóstico del cáncer de mama en mujeres que con los algoritmos CNN y RF.

4.2.6 HE6 - Sexta hipótesis específica

HE60: El algoritmo NB no tuvo menor tiempo de identificación para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

HE61: El algoritmo NB tuvo menor tiempo de identificación para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.

El tiempo de identificación del algoritmo NB fue 0.0006 milisegundos y para los algoritmos CNN y RF fueron 138.2233 y 0.0039 milisegundos, respectivamente. Por lo expuesto, se rechazó la hipótesis nula y se aceptó la hipótesis alternativa con respecto a que se tuvo menor tiempo de

identificación con el algoritmo NB para el diagnóstico del cáncer de mama en mujeres que con los algoritmos CNN y RF.

4.3 Prueba de hipótesis general

HG0: El algoritmo NB no tuvo mayor eficiencia diagnóstica del cáncer de mama en mujeres que los algoritmos CNN y RF

HG1: El algoritmo NB tuvo mayor eficiencia diagnóstica del cáncer de mama en mujeres que los algoritmos CNN y RF

Después de la comprobación de las hipótesis específicas HE1, HE2, HE3, HE4, HE5, HE6, solo se aceptaron las hipótesis específicas HE1, HE3, HE5 y HE6, por lo que se aceptó la hipótesis general nula con respecto a que el algoritmo NB no tuvo mayor eficiencia diagnóstica del cáncer de mama en mujeres que los algoritmos CNN y RF.

Tabla 7 Resumen de las hipótesis específicas de la comparación

Índice	Hipótesis Específicas	Resultado
HE1	El algoritmo NB tuvo mayor sensibilidad para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.	Aceptada
HE2	El algoritmo NB tuvo mayor especificidad para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.	Rechazada
HE3	El algoritmo NB tuvo mayor precisión para el diagnóstico del cáncer de mama que los algoritmos CNN y RF.	Aceptada
HE4	El algoritmo NB tuvo mayor exactitud para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.	Rechazada
HE5	El algoritmo NB tuvo menor tiempo de entrenamiento para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.	Aceptada
HE6	El algoritmo NB tuvo menor tiempo de identificación para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF.	Aceptada
HG	El algoritmo NB tuvo mayor eficiencia diagnóstica del cáncer de mama en mujeres que los algoritmos CNN y RF.	Rechazada

V. DISCUSIÓN

Los algoritmos CNN, RF y NB tuvieron resultados positivos para el diagnóstico de 7632 imágenes mamográficas del cáncer de mama en mujeres, dado que se logró: (a) sensibilidades de 78.265%, 97.8261% y 100%; (b) especificidades de 77.1386%, 87.7241% y 84.7039%; (c) precisiones de 64.9452%, 70.0389% y 72.6506%; (d) exactitudes de 64.4392%, 89.3979% y 87.8272%; (e) tiempos de entrenamiento de 3.7991 ms, 0.0618 ms y de 0.0043 ms y (f) tiempos de identificación de 138.2233 ms, 0.0039 ms y 0.0006 ms, respectivamente. Para lo cual, se constató que de las cuatro variables de razón (sensibilidad, especificidad, precisión y exactitud), la sensibilidad obtuvo los porcentajes más altos entre los tres algoritmos, mientras que para las variables de valor (tiempo de entrenamiento y tiempo de identificación), el tiempo de entrenamiento del algoritmo CNN fue mayor al tiempo de entrenamiento de los algoritmos RF y NB, asimismo el tiempo de entrenamiento del algoritmo RF fue mayor al tiempo de entrenamiento del algoritmo NB. Por otro lado, el tiempo de identificación del algoritmo CNN fue mayor al tiempo de identificación de los algoritmos RF y NB, asimismo el tiempo de identificación del algoritmo RF fue mayor al tiempo de identificación del algoritmo NB.

La sensibilidad del algoritmo CNN fue 78.265%, el cual fue menor al resultado que obtuvieron Kumbhare et al. (2023), quienes diagnosticaron el cáncer de mama con los algoritmos CNN y Aprendizaje Federado conjuntamente, obteniendo 94.11953% de sensibilidad. El resultado de Kumbhare et al. (2023) fue mayor al logrado en esta investigación, porque solo usaron 2,620 imágenes mamográficas que incorporaron casos benignos, malignos y normales separando 30% en datos de prueba y 70% en entrenamiento, a diferencia de esta investigación que utilizó 7,632 imágenes mamográficas (casi el triple de imágenes), de las cuales 1,527 se usaron para la identificación y 6,105 para el entrenamiento entre benignos y malignos. De la misma forma, la precisión del algoritmo CNN fue 64.9452%, el que fue menor al resultado que obtuvieron Kumbhare et al. (2023), quienes diagnosticaron el cáncer de mama con los algoritmos CNN y

Aprendizaje Federado conjuntamente, obteniendo 94.42129% de precisión.

La sensibilidad del algoritmo NB fue 100%, el que fue mayor al resultado que obtuvo Díaz (2021), quien realizó una comparación de algoritmos clasificadores donde el algoritmo NB obtuvo 89% de sensibilidad. El resultado de Díaz (2021) fue menor debido a que solo empleó 200 muestras de datos de tejidos tumorosos generados en la herramienta analizadora de datos genómicos "GEO2R" y sustraídos del bio proyecto informático GSE-10886. Esta investigación tuvo 11% como diferencia porcentual con la sensibilidad del estudio de Díaz (2021), debido a que fue entrenada y probada con mucha mayor cantidad de imágenes.

La especificidad del algoritmo NB fue 84.7039%, el que fue menor al resultado que obtuvo Díaz (2021), quien diagnosticó el cáncer de mama con el algoritmo clasificador NB y obtuvo 98% de especificidad. El resultado de Díaz (2021) fue mayor, porque caracterizó cuatro subtipos de características moleculares y genéticos del cáncer de mama (Luminal A, Luminal B, Her2 enriquecido y Basal o triple negativo) en 200 muestras de tejidos tumorosos. Esta investigación tuvo 13.2961% como diferencia porcentual con la especificidad del estudio de Díaz (2021), dado que no se usó subtipos del cáncer de mama y tampoco algoritmos clasificadores como KNN Y SVM, mientras que la presente investigación empleó el algoritmo CNN que trabaja con pixeles como datos de entrada y los algoritmos RF y NB que trabajan a través de extracción de características. De la misma manera, la precisión del algoritmo NB fue 72.6506% el que fue menor al resultado que obtuvo Díaz (2021), quien diagnosticó la enfermedad del cáncer de mama utilizando el clasificador NB que obtuvo 90% de precisión.

La exactitud de los algoritmos RF y NB fueron 89.3979% y 87.8272%, los que fueron mayores a los resultados que obtuvieron Painuli et al. (2022), quienes realizaron una revisión exhaustiva de la literatura científica sobre técnicas de aprendizaje automático y profundo del cáncer de mama donde los algoritmos RF y NB obtuvieron 70.86% y 57.24% de exactitud, respectivamente. Los resultados de la revisión exhaustiva de Painuli et al. (2022) fueron menores, debido a que usaron 358 pacientes (358 imágenes

entre MG “mamográficas” y MRI “resonancia magnética”) del cáncer de mama del dataset TCGA-BRCA que contiene 230, 167 imágenes de modalidades MG y MRI proporcionadas por el grupo The Cancer Imaging Archive (TCIA).

Con el mismo enfoque, la precisión del algoritmo NB fue 72.6506%, el que fue menor al resultado de Olatunde et al. (2022), quienes compararon algoritmos seleccionados con una validación cruzada donde el algoritmo NB obtuvo 95% de precisión. El resultado de Olatunde et al. (2022) fue mayor al logrado en esta investigación, dado que utilizaron un total de 519 imágenes digitalizadas donde se usó 25% en la prueba y 75% en el entrenamiento con la validación cruzada, que divide el conjunto de datos en 10 partes para luego realizar un proceso iterativo de entrenamiento y evaluación, mientras que en esta investigación comparativa se usó 7,632 imágenes mamográficas mas no utilizo ninguna validación cruzada.

Por otro lado, la precisión y exactitud del algoritmo RF fueron 70.0389% y 89.3979% respectivamente, los que fueron menores a los resultados que obtuvieron Chen et al. (2023), quienes compararon dos grupos de experimentos donde el algoritmo RF obtuvo una precisión de 94.7% y una exactitud de 96.5% en función al modelo de dividir el dataset por 8:2 y 94.6% de precisión y 95.3% de exactitud en función al modelo 7:3. Los resultados de Chen et al. (2023) fueron mayores, debido a que llevaron a cabo dos grupos de experimentos de acuerdo con una división diferente del dataset de la muestra (8:2 para el primer grupo y 7:3 para el segundo grupo). Cabe resaltar que Cheng et al. (2023) desarrollaron una comparación utilizando el dataset del Instituto de Investigación de Medicina Clínica de la Universidad de Wisconsin - WDCB con 569 imágenes digitales (357 benignos y 212 malignas), mientras que esta investigación utilizó 7,632 imágenes mamográficas, las cuales 2,520 fueron benignas y 5,112 malignas.

Los tiempos de entrenamiento de los algoritmos NB y RF fueron 0.0043 ms y 0.0618 ms, respectivamente. Estos resultados fueron menores a los resultados de Singh et al. (2017), quienes evaluaron los rendimientos de los algoritmos NB y RF en base a diversos conjuntos de datos, obteniendo tiempos de entrenamiento 18.897 ms y 0.096 ms, respectivamente. Los tiempos de entrenamiento de Singh et al. (2017) fueron mayores, debido a que evaluaron el impacto de tres tipos de datos diferentes (solo texto, solo numérico y texto + numérico) en el rendimiento del clasificador de los algoritmos NB y RF, donde los problemas de clasificación se exploraron en términos de precisión media. Asimismo, Singh et al. (2017) examinaron los tipos de datos a través de ocho conjuntos de datos diferentes tomados de UCI para entrenar modelos para los tres algoritmos, mientras que en este estudio comparativo se usó solo un conjunto de datos.

El tiempo de entrenamiento del algoritmo CNN fue 3.7991 ms, el cual fue mayor al tiempo de entrenamiento obtenido por Thilagaraj et al. (2022), quienes exploraron diversas técnicas de aprendizaje automático y técnicas de enjambre artificial de automatización y lograron un tiempo de entrenamiento de 0.20 ms para el algoritmo CNN. Esta diferencia en el tiempo se debe a que Thilagaraj et al. (2022) utilizaron un conjunto de datos más reducido, compuesto solo por 322 imágenes digitales del conjunto de datos MIAS, mientras que en la presente investigación se emplearon un total de 7,632 imágenes. Además, Thilagaraj et al. (2022) utilizaron la metodología Artificial Fish School para mejorar la calidad de la imagen, lo que pudo haber contribuido a su menor tiempo de entrenamiento.

El tiempo de identificación del algoritmo CNN fue de 138.2233 ms, el cual resultó ser mayor al tiempo de identificación obtenidos por Thilagaraj et al. (2022), quienes exploraron diversas técnicas de aprendizaje automático y técnicas de enjambre artificial de automatización, logrando un tiempo de identificación de 0.16 ms para el algoritmo CNN. La disparidad en los resultados se debe a que Thilagaraj et al. (2022) utilizaron un conjunto de

datos más reducido, compuesto solo por 322 imágenes digitales del conjunto de datos MIAS, mientras que en la presente investigación se empleó 7,632 imágenes clasificadas entre benignas y malignas. Además, Thilagaraj et al. (2022) aplicaron la metodología Artificial Fish School para mejorar la calidad de la imagen, lo que pudo haber contribuido a su menor tiempo de identificación.

VI. CONCLUSIONES

Las conclusiones de la investigación fueron las siguientes:

1. La sensibilidad del 100% del algoritmo NB fue un resultado positivo y mayor a la sensibilidad de 89% que obtuvo Díaz (2021), debido a que en la presente investigación se usó mayor cantidad de imágenes entrenadas y probadas (7,632) mientras que Díaz (2021) solo empleó muestras de tejidos tumorosos (200).
2. La especificidad del algoritmo NB fue 84.7039%, fue un resultado menor en comparación a la especificidad de 98% que obtuvo Díaz (2021), dado que empleó subtipos del cáncer de mama y uso únicamente algoritmos clasificadores, mientras que la presente investigación usó solo dos algoritmos clasificadores NB y RF, los que permiten extraer características de forma diferente (independiente y aleatoriamente).
3. La precisión y la exactitud del algoritmo RF de la presente investigación fueron 70.0389% y 89.3979%, resultados menores a la precisión de 94.7% y exactitud de 96.5% que obtuvieron Chen et al. (2023) debido a que solo usaron 357 imágenes benignas y 212 imágenes malignas y adicionalmente dividieron el conjunto de datos WDCB en dos grupos (primer grupo 8:2 y segundo grupo 7:3). Por otro lado, la presente investigación usó 2,520 imágenes benignas y 5,112 imágenes malignas y no empleó ningún tipo de división en el conjunto de datos.
4. Las exactitudes de los algoritmos RF y NB fueron 89.3979% y 87.8272% respectivamente, resultados mayores a las exactitudes de 70.86% y 57.24% de los algoritmos RF y NB que obtuvieron Painuli et al. (2022), debido a que estos autores realizaron un estudio de revisión donde emplearon 358 imágenes entre mamográficas y de resonancia magnética, mientras que la presente investigación usó un solo grupo de gran cantidad de imágenes mamográficas.

5. Los tiempos de entrenamiento y de identificación del algoritmo CNN fueron 3.7991 ms y 138.2233 ms, los cuales fueron mayores a los tiempos de entrenamiento e identificación de 0.20 ms y 0.16 ms del algoritmo CNN que obtuvieron Thilagaraj et al. (2022), ya que solo emplearon 322 imágenes digitales, lo que pudo haber cooperado con la reducción de los tiempos, mientras que en la presente investigación se utilizó 7,632 imágenes mamográficas para el cálculo de ambos indicadores de tiempo.
6. Sobre la base a los datos mencionados, se concluye que el algoritmo NB fue el mejor en términos de sensibilidad, el algoritmo RF y NB fueron mejores en exactitud, mientras que la especificidad del algoritmo NB y la precisión y la exactitud del algoritmo RF fueron menores en comparación a otros estudios que emplearon los mismos algoritmos. Por otro lado, los tiempos de entrenamiento e identificación del algoritmo CNN fueron mayores en comparación a otros estudios que usaron menor cantidad de imágenes.
7. Con respecto a los a los algoritmos CNN, NB y RF comparados en la presente investigación, el algoritmo NB fue mayor en términos de sensibilidad y menor en tiempos de entrenamiento e identificación. El algoritmo RF fue mayor en términos de especificad y exactitud, mientras que el algoritmo CNN fue menor en sensibilidad, especificidad, precisión y exactitud y fue mayor en los tiempos de entrenamiento y de identificación.

VII. RECOMENDACIONES

Las recomendaciones para futuras investigaciones son las siguientes:

1. Recopilar datos de alta calidad: Es importante contar con conjuntos de datos completos y representativos para entrenar los algoritmos. Cuanta más diversidad y calidad tengan los datos, mejor será el rendimiento de los algoritmos.
2. Realizar el preprocesamiento de datos: Se sugiere investigar y desarrollar técnicas de preprocesamiento de datos más avanzadas y personalizadas. Esto implica realizar una limpieza y normalización adecuada de los datos antes de entrenar los algoritmos, eliminando datos inconsistentes, manejando valores atípicos y escalando las características. Investigar en este aspecto contribuirá a mejorar la calidad de los datos utilizados en los algoritmos y por lo tanto, su desempeño en el diagnóstico de cáncer de mama.
3. Seleccionar características relevantes. Es importante investigar y desarrollar métodos para realizar un análisis de las características disponibles y seleccionar aquellas que sean más relevantes para el diagnóstico de cáncer de mama. Esto ayudará a reducir el ruido en los datos y mejorar la eficiencia de los algoritmos al centrarse en las características más informativas y discriminativas de la enfermedad.
4. Ajustar parámetros adecuadamente. Se recomienda investigar y explorar diferentes configuraciones de parámetros para cada algoritmo utilizado en el diagnóstico de cáncer de mama. Realizar una búsqueda exhaustiva de parámetros o utilizar técnicas avanzadas de optimización, como la optimización bayesiana, la que puede ayudar a encontrar la combinación óptima de parámetros para mejorar el rendimiento de los algoritmos.
5. Incrementar los datos mediante técnicas de aumento. Se sugiere investigar y desarrollar técnicas de aumento de datos específicas para el diagnóstico de cáncer de mama. Estas técnicas permitirán generar nuevas muestras sintéticas a partir de los datos existentes, lo que

ayudar a diversificar y ampliar el conjunto de datos de entrenamiento, mejorando así la capacidad de los algoritmos para detectar y diagnosticar la enfermedad.

6. Acceder a recursos de hardware adecuados. Se recomienda aprovechar recursos de hardware potentes, como GPU, para acelerar el entrenamiento de modelos de aprendizaje automático y reducir los tiempos de ejecución.
7. Utilizar bibliotecas preinstaladas. Las bibliotecas preinstaladas de aprendizaje automático, como TensorFlow, Keras y Scikit-learn simplifican el uso de los algoritmos en proyectos de deep learning, machine learning, entre otros.
8. Utilizar una combinación de diversos algoritmos en el diagnóstico de cáncer de mama, ya que ofrece beneficios significativos. Los algoritmos como máquinas de vectores de soporte, árboles de decisión, redes neuronales artificiales, K-Nearest Neighbors (KNN) y regresión logística son especialmente adecuados para el análisis y lectura de características, debido a su capacidad para manejar datos de alta dimensionalidad, lo cual permite identificar características relevantes, manejar datos no lineales y capturar relaciones complejas en los datos. Al combinar estos algoritmos, se puede mejorar la precisión, el rendimiento y la detección temprana del cáncer de mama, lo que se traduce en una mejor atención médica y resultados más favorables y precisos para los radiólogos.
9. Probar algoritmos adicionales, ya que amplía el aspecto de herramientas disponibles para el diagnóstico de cáncer de mama, lo que puede ayudar a mejorar la precisión y la detección temprana de la enfermedad. Es importante evaluar y comparar el rendimiento de estos algoritmos en conjunto con los mencionados anteriormente para determinar la combinación más adecuada en un contexto específico.

REFERENCIAS

ABDULLA et al. (2021) Breast Cancer Classification Using Machine Learning Techniques: A Review [en línea], 2021. [consulta: 3 julio 2023]. DOI <https://doi.org/%22>. Disponible en: <https://www.proquest.com/docview/2623927246/E3920E0646094C6CPQ/5>.

ABUNASSER, B.S., AL-HIEALY, M.R.J., ZAQOUT, I.S. y ABU-NASER, S.S., 2022. Breast Cancer Detection and Classification using Deep Learning Xception Algorithm. *International Journal of Advanced Computer Science and Applications* [en línea], vol. 13, no. 7. [Consulta: 17 octubre 2022]. DOI 10.14569/ijacsa.2022.0130729. Disponible en: <https://www.proquest.com/docview/2707472956?pq-origsite=gscholar&fromopenview=true>.

AGOURI, H., AZIZI, M., EL ATTAR, H., EL KHANNOUSSI, M., IBRAHIMI, A., KABBAJ, R., KADIRI, H., BEKARSABEIN, S., ECHCHARIF, S., MOUNJID, C. y EL KHANNOUSSI, B., 2022. Assessment of deep learning algorithms to predict histopathological diagnosis of breast cancer: first Moroccan prospective study on a private dataset. *BMC Research Notes* [en línea], vol. 15, no. 1. [Consulta: 22 septiembre 2022]. DOI 10.1186/s13104-022-05936-1. Disponible en: <https://bmcresearchnotes.biomedcentral.com/articles/10.1186/s13104-022-05936-1#Sec2>.

ALIMUDIN, E., HANUNG ADI NUGROHO y TEGUH BHARATA ADJI, 2022. Similarity measurement on digital mammogram classification. *TELKOMNIKA (Telecommunication Computing Electronics and Control)* [en línea], vol. 20, no. 4, pp. 834-845. [Consulta: 6 octubre 2022]. Disponible en: <http://telkomnika.uad.ac.id/index.php/TELKOMNIKA/article/view/10698/11442>.

AHMAD, S., ULLAH, T., AHMAD, I., AL-SHARABI, A., ULLAH, K., KHAN, R.A., RASHEED, S., ULLAH, I., UDDIN, Md.N. y ALI, Md.S., 2022. A Novel Hybrid Deep Learning Model for Metastatic Cancer Detection. En: S. NISAR (ed.), *Computational Intelligence and Neuroscience* [en línea], vol.2022, pp. 1-14. [Consulta: 27 septiembre 2022]. DOI 10.1155/2022/8141530. Disponible en: <https://www.proquest.com/docview/2683805650/fulltextPDF/3204A684CA C4673PQ/3?accountid=37408>.

AMERICAN SOCIETY OF CLINICAL ONCOLOGY (2022). Cáncer de mama: Estadísticas. Disponible en: <https://www.cancer.net/es/tipos-dec%C3%A1ncer/c%C3%A1ncer-de-mama/estad%C3%ADsticas>.

ARCINIEGAS, S., 2023. Sistema para la detección y clasificación de anomalías en mamografías digitales basado en aprendizaje profundo. [Uniautonoma.edu.co](http://repositorio.uniautonoma.edu.co) [en línea], [consulta: 1 julio 2023]. DOI <http://repositorio.uniautonoma.edu.co:8080/xmlui/handle/123456789/780>. Disponible en: <https://repositorio.uniautonoma.edu.co/handle/123456789/780>.

ALGEHYNE, E.A., MUHAMMAD, L.J., NASEH ATEAHALLAH ALGEHAINY, OSAMA ABDULAZIZ ALAMRI y ALZHRANI, A.K., 2022. Fuzzy Neural Network Expert System with an Improved Gini Index Random Forest- Based Feature Importance Measure Algorithm for Early Diagnosis of Breast Cancer in Saudi Arabia. [en línea], vol. 6, no. 1, [consulta: 17 julio 2023]. DOI <https://doi.org/10.3390/bdcc6010013>. Disponible en: <https://www.mdpi.com/2504-2289/6/1/13>.

BAFFA, M.F.O y LATTARI, G., 2019. Convolutional Neural Networks for Static and Dynamic Breast Infrared Imaging Classification. 2018 31st SIBGRAP Conference on Graphics, Patterns and Images (SIBGRAP)

[en línea], [Consulta: 19 noviembre 2022]. DOI 10.1109/sibgrapi.2018.00029. Disponible en: <https://ieeexplore.ieee.org/abstract/document/8614326>.

BURCAK, K., C. y Uguz, H., 2022. A New Hybrid Breast Cancer Diagnosis Model Using Deep Learning Model and ReliefF [en línea], vol. 39, No. 2, pp. 521- 529 [Consulta: 8 julio 2023]. DOI: <https://doi.org/10.18280/ts.390214>. Disponible en: <https://www.iieta.org/journals/ts/paper/10.18280/ts.390214>

CALDERÓN, J., P., S. y ALZAMORA, L., 2019. DISEÑOS DE INVESTIGACIÓN PARA TESIS DE POSGRADO. [en línea], vol. 7, no. 2, [consulta: 7 julio 2023]. DOI <https://doi.org/10.32544/psicologia.v7i2.660>. Disponible en: <http://revistas.uigv.edu.pe/index.php/psicologia/article/view/660>

CANCHIG, J. y CHILLA, B., 2023. Desarrollo de una aplicación web y móvil para el análisis de calidad de suelos en las parroquias rurales del Cantón Latacunga. Utc.edu.ec [en línea], [consulta: 09 julio 2023]. DOI <https://doi.org/PI-002467>. Disponible en: <http://repositorio.utc.edu.ec/handle/27000/10432>.

CHEN, H., WANG, N., DU, X., MEI, K., ZHOU, Y. y CAI, G., 2023. Classification Prediction of Breast Cancer Based on Machine Learning. [en línea], vol. 2023, [consulta: 6 julio 2023]. DOI <https://doi.org/10.1155/2023/6530719>. Disponible en: <https://www.hindawi.com/journals/cin/2023/6530719/>.

CÓDIGO DE ÉTICA DEL COLEGIO DE INGENIEROS DEL PERÚ. [en línea], [2022]. S.I.: Disponible en: https://www.cip.org.pe/publicaciones/reglamentosCNCD2018/codigo_de_etica_del_cip.pdf.

- DEWANGAN, K.K., DEWANGAN, D.K., SAHU, S.P. y JANGHEL, R., 2022. Breast cancer diagnosis in an early stage using novel deep learning with hybrid optimization technique. *Multimedia Tools and Applications* [en línea], vol. 81, no. 10, pp. 13935-13960. [Consulta: 19 septiembre 2022]. DOI 10.1007/s11042-022-12385-2. Disponible en: <https://link.springer.com/article/10.1007/s11042-022-12385-2>.
- DÍAZ, N. 2021. Análisis comparativo de clasificadores para la detección de subtipos de cáncer. *Uss.edu.pe* [en línea], [consulta: 6 julio 2023]. DOI <https://hdl.handle.net/20.500.12802/8386>. Disponible en: <https://repositorio.uss.edu.pe/handle/20.500.12802/8386>.
- DÍAZ, A. M., PONCE, L., BRUNO, E., VIDAL, DAVID GONZÁLEZ BÁRCENA, CÉSAR, G., SAMPERIO, J., HICKS GÓMEZ, C., IBARRA PÉREZ, P., MORALES, J., LUIS, R., ARIAS, H., MONTEVERDE, R.-T., ELÍAS, F. y SALAMANCA, G., 2011. vol. 54. [Consulta: 27 septiembre 2022]. Disponible en: https://www.pveu.unam.mx/informacion/medicina/FacMed_EneFeb2011.pdf#page=4.
- DURÁN, LÓPEZ. L., DOMÍNGUEZ. MORALES, J. P., LUNA, PEREJÓN. F., AMAYA RODRÍGUEZ. I., CIVIT, MASOT. J., VICENTE, DÍAZ. S., y LINARES, BARRANCO. A., 2019. idUS - Depósito de Investigación Universidad de Sevilla. *Idus.us.es* [en línea], [Consulta: 15 noviembre 2022]. DOI 978-84-120057-2-1. Disponible en: <https://idus.us.es/handle/11441/88870>.
- ELSHENNAWY, N.M., IBRAHIM, D.M., SARHAN, A.M. y ARAFA, M., 2022. Deep-Risk: Deep Learning-Based Mortality Risk Predictive Models for COVID-19. *Diagnostics* [en línea], vol. 12, no. 8, pp. 1847. [Consulta: 4 diciembre 2022]. DOI 10.3390/diagnostics12081847. Disponible en: <https://www.mdpi.com/2075-4418/12/8/1847/htm>.

ELKORANY, A.S. y ELSHARKAWY, Z.F., 2023. Efficient breast cancer mammograms diagnosis using three deep neural networks and term variance. [en línea], vol. 13, no. 1, [consulta: 25 junio 2023]. DOI <https://doi.org/10.1038/s41598-023-29875-4>. Disponible en: <https://www.nature.com/articles/s41598-023-29875-4>.

GARCÍA, F., ALONSO-SARRÍA, F., GOMARIZ-CASTILLO, F. Modificación del algoritmo Random Forest para su empleo en clasificación de imágenes de Teledetección. En Aplicaciones de las Tecnologías de la Información Geográfica (TIG) para el desarrollo económico sostenible XVII Congreso Nacional de Tecnologías de Información Geográfica. 2016. Disponible en: https://www.researchgate.net/profile/Fulgencio-Canovas-Garcia/publication/304825355_Modificacion_del_algoritmo_Random_Forest_para_su_empleo_en_clasificacion_de_imagenes_de_teledeteccion/links/577be67a08aec3b743366b69/Modificacion-del-algoritmo-Random-Forest-para-su-empleo-en-clasificacion-de-imagenes-de-teledeteccion.pdf.

GONZÁLEZ, A. 2022. Panamahitek.com [en línea]. [Consulta: 5 diciembre 2022]. Disponible en: <https://panamahitek.com/implementacion-de-un-clasificador-random-forest-en-python/?fbclid=IwAR3IIUPAfbnpV5MffJZ1RuIzDNkA7Gc07tWg0P0EJbxY9uxDmJHcNY2kNJ4>.

GONZÁLEZ, L., 2019. Naive Bayes — Práctica con Python - Aprende IA. Aprende IA [en línea]. [Consulta: 6 diciembre 2022]. Disponible en: <https://aprendeia.com/naive-bayes-practica-con-python-machine-learning/>.

GAMARRA, C. y SANTOS, Y., 2019. Aplicación del algoritmo para predecir el riesgo de cáncer de mama en las pacientes del Hospital de la Solidaridad de Villa El Salvador. *Autonoma.edu.pe* [en línea], [Consulta: 1 octubre 2022]. DOI <https://hdl.handle.net/20.500.13067/954>.

Disponible

en:

<https://repositorio.autonoma.edu.pe/handle/20.500.13067/954>.

GARGOURI, N., MOKNI, R., DAMAK, A., SELLAMI, D. y ABID, R., 2022. An automatic breast computer-aided diagnosis scheme based on a weighted fusion of relevant features and a deep CNN classifier. *IET Image Processing* [en línea], vol. 16, no. 12, pp. 3394-3406. [Consulta: 26 septiembre 2022]. DOI 10.1049/ipr2.12572. Disponible en: <https://ietresearch.onlinelibrary.wiley.com/doi/epdf/10.1049/ipr2.12572>.

GONÇALVES, C.B., SOUZA, J.R. y FERNANDES, H., 2022. CNN architecture optimization using bio-inspired algorithms for breast cancer detection in infrared images. *Computers in Biology and Medicine* [en línea], vol. 142, pp. 105205. [Consulta: 3 octubre 2022]. DOI 10.1016/j.combiomed.2021.105205. Disponible en: <https://www.sciencedirect.com/science/article/abs/pii/S0010482521009999>.

HAYDAR, C. S y ALI, A. M, 2022. Breast cancer recognition based on performance evaluation of machine learning algorithms. *Indonesian Journal of Electrical Engineering and Computer Science* [en línea], vol. 27, no. 2, pp. 980. [Consulta: 18 octubre 2022].

DOI10.11591/ijeecs.v27.i2.pp980-989. Disponible

en:

<https://ijeecs.iaescore.com/index.php/IJECS/article/view/27351>.

HOLLOWAY, C.M.B., SHABESTARI, O., EBERG, M., FORSTER, K., MURRAY, P., GREEN, B., ESENSOY, A.V., EISEN, A. y SUSSMAN, J., 2022. Identifying Breast Cancer Recurrence in Administrative Data: Algorithm Development and Validation. *Current Oncology* [en línea], vol. 29, no. 8, pp. 5338-5367. [Consulta: 6 octubre 2022]. DOI 10.3390/currenco129080424. Disponible en: <https://www.mdpi.com/1718-7729/29/8/424>.

INSUA, J., 2018. Principialismo, bioética personalista y principios de acción en medicina y en servicios de salud. *Persona y Bioética* [en línea], vol. 22, no. 2, pp. 223-246. [Consulta: 2 octubre 2022]. DOI 10.5294/pebi.2018.22.2.3. Disponible en: http://www.scielo.org.co/scielo.php?pid=S012331222018000200223&script=sci_abstract&tlng=pt.

JAYANTHI, N., y WADHWA, G., 2021. Classification of Breast Cancer Detection Using K-Nearest Neighbor Algorithm Trained with Wisconsin Dataset - ProQuest. *Proquest.com* [en línea], 2021. [Consulta: 24 octubre 2022]. DOI",. Disponible en: <https://www.proquest.com/docview/2563510801/fulltextPDF/D414745A2C104379PQ/13?accountid=37408&parentSessionId=oERK%2BP38CjC%2BfxEg2DhdfXsEj8Vfr3ODBUaIWrKrfqk%3D>.

JIMÉNEZ BUILES, J.A., RAMÍREZ BEDOYA, D.L. y BRANCH BEDOYA, J.W., 2019. Metodología de desarrollo de software para plataformas educativas robóticas usando ROS-XP. *Revista Politécnica* [en línea], vol. 15, no. 30, pp. 55-69. [Consulta: 23 noviembre 2022]. DOI 10.33571/rpolitec.v15n30a6. Disponible en: <https://revistas.elpoli.edu.co/index.php/pol/article/view/1620>.

KARUNANAYAKE, N., LOHITVISATE, W. y MAKHANOV, S.S., 2022. Artificial life for segmentation of fusion ultrasound images of breast abnormalities. *Pattern Recognition* [en línea], vol. 131, pp. 108838. [Consulta: 27 septiembre 2022]. DOI 10.1016/j.patcog.2022.108838. Disponible en: <https://www.sciencedirect.com/science/article/abs/pii/S0031320322003193>.

KHAN, S., ISLAM, N., JAN, Z., UD DIN, I. y RODRIGUES, J.J.P.C., 2019. A novel deep learning-based framework for the detection and classification of breast cancer using transfer learning. *Pattern Recognition Letters* [en línea], vol. 125, pp. 1-6. [Consulta: 19 noviembre 2022]. DOI 10.1016/j.patrec.2019.03.022. Disponible en: <https://www.sciencedirect.com/science/article/abs/pii/S0167865519301059?via%3Dihub>.

KUMBHARE, S., KATHOLE, ATUL B. y SHINDE, S., 2023. Federated learning aided breast cancer detection with intelligent Heuristic-based deep learning framework. [en línea], vol. 86, [consulta: 3 julio 2023]. DOI <https://doi.org/10.1016/j.bspc.2023.105080>. Disponible en: <https://www.sciencedirect.com/science/article/pii/S174680942300513X?via%3Dihub>.

LIEW, X.Y., HAMEED, N. y CLOS, J., 2021. An investigation of XGBoost-based algorithm for breast cancer classification. *Machine Learning with Applications* [en línea], vol. 6, pp. 100154. [Consulta: 19 septiembre 2022]. DOI 10.1016/j.mlwa.2021.100154. Disponible en: <https://reader.elsevier.com/reader/sd/pii/S2666827021000773?token=A7D8076BB68549D7918F13337921A810AB2235DA4018496F128CD74B2F17D1B9A249297D6FE62B091A8A3F885BABFB3F&originRegion=us-east-1&originCreation=20220919165150>.

LIU, J., ZHOU, Z., KONG, S. y MA, Z., 2022. Application of random forest based on semi-automatic parameter adjustment for optimization of anti-breast cancer drugs. *Frontiers in Oncology* [en línea], vol. 12. [Consulta: 5 octubre 2022]. DOI 10.3389/fonc.2022.956705. Disponible en: <https://www.frontiersin.org/articles/10.3389/fonc.2022.956705/full>.

LIU, X., YUAN, P., LI, R., ZHANG, D., AN, J., JU, J., LIU, C., REN, F., HOU, R., LI, Y. y YANG, J., 2022. Predicting breast cancer recurrence and metastasis risk by integrating color and texture features of histopathological images and machine learning technologies. *Computers in Biology and Medicine* [en línea], vol. 146, pp. 105569. [Consulta: 23 septiembre 2022]. DOI 10.1016/j.combiomed.2022.105569. Disponible en: <https://www.proquest.com/docview/2678196976/fulltextPDF/3BF2C736C2604CC3PQ/6>.

MAQSOOD, S., DAMAŠEVIČIUS, R. y MASKELIŪNAS, R., 2022. TTCNN: A Breast Cancer Detection and Classification towards Computer-Aided Diagnosis Using Digital Mammography in Early Stages. *Applied Sciences* [en línea], vol. 12, no. 7, pp. 3273. [Consulta: 6 octubre 2022]. DOI 10.3390/app12073273. Disponible en: <https://www.mdpi.com/2076-3417/12/7/3273>.

MAMDOUH, M.I., AHMED, S.D. y ABDEL, A.R., 2021. Deep Learning Hybrid with Binary Dragonfly Feature Selection for the Wisconsin Breast Cancer Dataset. *International Journal of Advanced Computer Science and Applications* [en línea], vol. 12, no. 3. [Consulta: 17 noviembre 2022]. DOI 10.14569/ijacsa.2021.0120314. Disponible en: <https://thesai.org/Publications/ViewPaper?Volume=12&Issue=3&Code=IJACSA&SerialNo=14>.

MA, Z., HUANG, S., WU, X., HUANG, Y., CHAN, S.W.-C., LIN, Y., ZHENG, X. y ZHU, J., 2022. Development of a Prognostic App (iCanPredict) to Predict Survival for Chinese Women With Breast Cancer: Retrospective Study. *Journal of Medical Internet Research* [en línea], vol. 24, no. 3, pp. e35768. [Consulta: 23 septiembre 2022]. DOI 10.2196/35768. Disponible en: <https://www.jmir.org/2022/3/e35768/PDF>.

MATSANGIDOU, M., P. KASSIANOS, A., PAPAIOANNOU, D., SOLOMOU, T., KRINI, M., KAREKLA, M. y S. PATTICHIS, C., 2022. Virtual Painkillers: Designing Accessible Virtual Reality Experiences for Helping Cancer Patients Manage Pain at Home. *CHI Conference on Human Factors in Computing Systems Extended Abstracts*, DOI 10.1145/3491101.350 disponible en: <https://dl.acm.org/doi/pdf/10.1145/3491101.3503562>.

MENESES, C. 2022. El proyecto de investigación. La hoja de ruta de la investigación. Comillas.edu [en línea], [consulta: 7 julio 2023]. DOI <https://doi.org/0210-9522>. Disponible en: <https://repositorio.comillas.edu/xmlui/handle/11531/76568>.

MONJA, E., 2020 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 [consulta: 7 denoviembre de 2022]. Disponible en: <https://repositorio.uss.edu.pe/handle/20.500.12802/6755>

MURTHY, C.R. y BALAJI, K., 2022. Histopathological analyses of breast cancer using deep learning. *CARDIOMETRY* [en línea], no. 22, pp. 456-461. [Consulta: 27 septiembre 2022]. DOI 10.18137/cardiometry.2022.22.456461. Disponible en: <https://www.proquest.com/docview/2675713671/fulltextPDF/3BF2C736C2604CC3PQ/31>.

NAJI, M.A., FILALI, S.E., AARIKA, K., BENLAHMAR, E.H., ABDELOUHAHID, R.A. y DEBAUCHE, O., 2021. Machine Learning Algorithms For Breast Cancer Prediction And Diagnosis. *Procedia Computer Science* [en línea], vol. 191, pp. 487-492. [Consulta: 20 septiembre 2022]. DOI10.1016/j.procs.2021.07.062. Disponible en:
<https://reader.elsevier.com/reader/sd/pii/S1877050921014629?token=7333CCA8FDBEEB6B54203C14543A973C0C3DDD1C2902F014F392278EE375AC582C5A2ECE46898648191DEC97F25878F8&originRegion=us-east-1&originCreation=20220920132733>.

NASIEN, D. 1, ENJESLINA, V. 1, ADIYA, M.H. 1 y BAHARUM, Z. 2 1 D. of I.E., 2022. Breast Cancer Prediction Using Artificial Neural Networks Back Propagation Method. ProQuest [en línea], pp. 012025. [Consulta: 22 septiembre 2022]. DOI 10.1088/1742-6596/2319/1/012025. Disponible en:
<https://www.proquest.com/docview/2703494122/3BF2C736C2604CC3PQ/11?parentSessionId=58AHbbCPTm7msMmLD3K6tua8WrlIN6XDikL1WEQMRNI%3D>.

NGUYEN, T.K., NGUYEN, T.N.L., NGUYEN, K., NGUYEN, H.V.T., TRAN, L.T.T., NGO, T.X.T., PHAM, P.T.V. y TRAN, M.H., 2022. Machine learning-based screening of MCF-7 human breast cancer cells and molecular docking analysis of essential oils from *Ocimum basilicum* against breast cancer. *Journal of Molecular Structure* [en línea], vol. 1268, pp. 133627. [Consulta: 27 septiembre 2022]. DOI 10.1016/j.molstruc.2022.133627. Disponible en:
<https://reader.elsevier.com/reader/sd/pii/S0022286022012832?token=F1B86A432114F23852C65D3F41962DC25FC0C6128E2ED253A22C6A4DD574755E0D934B4AD3B65763BA8C0999600F3AD5&originRegion=us-east-1&originCreation=20220927035707>.

- NIETO, E., 2018. Tipos de Investigación. Usdg.edu.pe [en línea], [Consulta: 5 octubre 2022]. Disponible en: <http://repositorio.usdg.edu.pe/handle/USDG/34>.
- OLATUNDE, O., S., OLALERE M., NOAH O., A., MISRA, S., AHUJA, R., AGRAWAL, A. y OLURANTI, J., 2022. Comparison of Selected Algorithms on Breast Cancer Classification., DOI https://doi.org/10.1007/978-981-19-1111-8_14. Disponible en: https://link.springer.com/chapter/10.1007/978-981-19-1111-8_14
- OTERO, A. Enfoques de investigación. Métodos para el diseño urbano–Arquitectónico, 2018. [en línea]. [Fecha de consulta: 05/10/2022]. Disponible en: https://www.researchgate.net/profile/Alfredo-Otero-Ortega/publication/326905435_ENFOQUES_DE_INVESTIGACION/links/5b6b7f9992851ca650526dfd/ENFOQUES-DE-INVESTIGACION.pdf
- PAINULI, D., BHARDWAJ, S. y KÖSE, U., 2022. Recent advancement in cancer diagnosis using machine learning and deep learning techniques: A comprehensive review. Computers in Biology and Medicine [en línea], vol.146,pp. 105580. [Consulta: 22 octubre 2022]. DOI 10.1016/j.compbimed.2022.105580. Disponible en: <https://www.proquest.com/docview/2678196663/fulltextPDF/F07652F04B E948CEPQ/4>.
- PAUL, A., DEY, A., MUKHERJEE, D.P., SIVASWAMY, J. y TOURANI, V., 2015. Regenerative Random Forest with Automatic Feature Selection to Detect Mitosis in Histopathological Breast Cancer Images. Lecture Notes in Computer Science [en línea], pp. 94-102. [Consulta: 7 noviembre 2022]. DOI 10.1007/978-3-319-24571-3_12. Disponible en: https://link.springer.com/chapter/10.1007/978-3-319-24571-3_12.

- PEÑA, V., 2022. Despliegue de un modelo de clasificación de tumores de cáncer de mama. *Udea.edu.co* [en línea], [Consulta: 27 septiembre 2022]. DOI <http://hdl.handle.net/10495/29049>. Disponible en: https://bibliotecadigital.udea.edu.co/bitstream/10495/29049/4/PenaJuan_2022_ClasificacionTumoresCancer.pdf.
- RAWAT, V., GULATI, K., KAUR, U., SETH, J.K., SOLANKI, V., VENKATESH, A.N., SINGH, D.P., SINGH, N. y LOGANATHAN, M., 2022. A Supervised Learning Identification System for Prognosis of Breast Cancer. En: A. KAUR (ed.), *Mathematical Problems in Engineering* [en línea], vol. 2022, pp. 1-8. [Consulta: 19 septiembre 2022]. DOI [10.1155/2022/7459455](https://doi.org/10.1155/2022/7459455). Disponible en: <https://www.proquest.com/docview/2709596236/fulltextPDF/EC4B99F67D54145PQ/99>
- SAFDAR, S., RIZWAN, M., GADEKALLU, T.R., JAVED, A.R., RAHMANI, M.K.I., JAWAD, K. y BHATIA, S., 2022. Bio-Imaging-Based Machine Learning Algorithm for Breast Cancer Detection. *Diagnostics* [en línea], vol. 12, no.5, pp. 1134. [Consulta: 22 septiembre 2022]. DOI [10.3390/diagnostics12051134](https://doi.org/10.3390/diagnostics12051134). Disponible en: <https://www.proquest.com/docview/2670132410/fulltextPDF/E78468E888564EECPQ/1?accountid=37408>.
- SALAZAR, J.C, TOVAR CASALLAS A., LINARES, J. C., LOZANO, A. y VALBUENA, Y. L., 2018. Scrum versus XP: similitudes y diferencias. *Tecnología Investigación y Academia* [en línea], vol. 6, no. 2, pp. 29-37. [Consulta: 23 noviembre 2022]. Disponible en: <https://revistas.udistrital.edu.co/index.php/tia/article/view/10496>.

SHERINA S., J., NAYANA R., y MOUNUSHA S., 2020. MACHINE LEARNING TECHNIQUES TO DETECT BREAST CANCER. [en línea], vol.11, [consulta: 3 julio 2023]. DOI <https://doi.org/10.26483/ijarcs.v11i0.6546>. Disponible en: [https://www.proquest.com/docview/2407636076/E31372634C8C4887PQ / 12](https://www.proquest.com/docview/2407636076/E31372634C8C4887PQ/12).

SINGH, A., HALGAMUGE, M.N. y RAJASEKARAN LAKSHMIGANTHAN, 2017. Impact of Different Data Types on Classifier Performance of Random Forest, Naïve Bayes, and K-Nearest Neighbors Algorithms. [en línea], vol. 8, no. 12, [consulta: 13 julio 2023]. DOI <https://doi.org/10.14569/ijacsa.2017.081201>. Disponible en: [https://www.proquest.com/docview/2656454306/78174D70F5FA4F3DPQ/ 11](https://www.proquest.com/docview/2656454306/78174D70F5FA4F3DPQ/11).

SINGH, H., SHARMA, V. y SINGH, D., 2022. Comparative analysis of proficiencies of various textures and geometric features in breast mass classification using k-nearest neighbor. *Visual Computing for Industry, Biomedicine, and Art* [en línea], vol. 5, no. 1. [Consulta: 24 septiembre 2022]. DOI 10.1186/s42492-021-00100-1. Disponible en: <https://vciba.springeropen.com/articles/10.1186/s42492-021-00100-1#Sec11>.

SINGH HARMANDEEP, SHARMA, V. y SINGH, D., 2022. Machine learning based computer aided diagnosis system for classification of breast masses in mammograms. [en línea], vol. 2267, no. 1, [consulta: 9 julio 2023]. DOI <https://doi.org/10.1088/1742-6596/2267/1/012141>. Disponible en: <https://iopscience.iop.org/article/10.1088/1742-6596/2267/1/012141>.

SKARPING, I., LARSSON, M. y FÖRNVIK, D., 2021. Analysis of mammograms using artificial intelligence to predict response to neoadjuvant chemotherapy in breast cancer patients: proof of concept. *European Radiology* [en línea], vol. 32, no. 5, pp. 3131-3141. [Consulta: 23 septiembre 2022]. DOI 10.1007/s00330-021-08306-w. Disponible en: <https://link.springer.com/article/10.1007/s00330-021-08306-w>.

SUCHODOLSKA, G. y SENKUS, E., 2022. Mobile applications for early breast cancer chemotherapy-related symptoms reporting and management: A scoping review. *Cancer Treatment Reviews* [en línea], vol. 105, pp. 102364. [Consulta: 21 septiembre 2022]. DOI 10.1016/j.ctrv.2022.102364. Disponible en: <https://reader.elsevier.com/reader/sd/pii/S0305737222000287?token=6ACB498B407C9C7B2F1799D251BDA48AD786C31B32412A24C2CC9CB762F8DF50AE19D005A0B6E551A166DBEA9F3EE4EC&originRegion=us-east-1&originCreation=20220921133618>.

SUN, Y., WANG, S., LIU, Z., YOU, C., LI, R., MAO, N., DUAN, S., LYNN, H.S. y GU, Y., 2022. Identifying factors that may influence the classification performance of radiomics models using contrast-enhanced mammography (CEM) images. *Cancer Imaging* [en línea], vol. 22, no. 1. [Consulta: 22 septiembre 2022]. DOI 10.1186/s40644-022-00460-8. Disponible en: <https://cancerimagingjournal.biomedcentral.com/articles/10.1186/s40644-022-00460-8#Sec1>.

SUGIHARTI, E., ARIFUDIN, R., TRI, D., y BROTO, S., 2022. Integration of convolutional neural network and extreme gradient boosting for breast cancer detection. *Bulletin of Electrical Engineering and Informatics* [en línea], vol. 11, no. 2, pp. 803-813. [Consulta: 23 septiembre 2022]. Disponible en: <https://beei.org/index.php/EEI/article/view/3562/2553>.

THILAGARAJ, M., ARUNKUMAR, N. y GOVINDAN, P., 2022. Classification of Breast Cancer Images by Implementing Improved DCNN with Artificial FishSchool Model. En: D. KOUNDAL (ed.), *Computational Intelligence and Neuroscience* [en línea], vol. 2022, pp. 1-12. [Consulta: 5 octubre 2022].DOI 10.1155/2022/6785707. Disponible en: <https://www.hindawi.com/journals/cin/2022/6785707/>.

TRAN, T., LE, U. y SHI, Y., 2022. An effective up-sampling approach for breast cancer prediction with imbalanced data: A machine learning model-based comparative analysis. En: S. V E (ed.), *PLOS ONE* [en línea], vol. 17, no. 5, pp. e0269135. [Consulta:22 septiembre 2022]. DOI10.1371/journal.pone.0269135. Disponible en: <https://www.proquest.com/docview/2687677848/fulltextPDF/EC4B99F67D54145PQ/20>.

UNIVERSIDAD CÉSAR VALLEJO. Código de ética en investigación de la Universidad César Vallejo. 2022, p. 1-12 Disponible en: <https://www.ucv.edu.pe/wp-content/uploads/2020/11/RCUN%C2%B00262-2020-UCV-Aprueba-Actualizaci%C3%B3n-del-C%C3%B3digo-%C3%89tica-en-Investigaci%C3%B3n-1-1.pdf>

WANG, H., ZHENG, B., YOON, S.W. y KO, H.S., 2018. A support vector machine-based ensemble algorithm for breast cancer diagnosis. *European Journal of Operational Research* [en línea], vol. 267, no. 2, pp. 687-699. [Consulta: 19 septiembre 2022]. DOI 10.1016/j.ejor.2017.12.001. Disponible en: <https://reader.elsevier.com/reader/sd/pii/S0377221717310810?token=B2F85D6ABC6EEF4939C5FFE6414CDC6133FC90273D61B802B4BE49C3DB5BD8C10C56D466D2DDEC5D89EF617E9FF90E82&originRegion=us-east-1&originCreation=20220919180850>.

ZHANG, Y., CHEN, J.-H., LIN, Y., CHAN, S., ZHOU, J., CHOW, D., CHANG, P., KWONG, T., YEH, D.-C., WANG, X., PARAJULI, R., MEHTA, R.S., WANG, M. y SU, M.-Y., 2020. Prediction of breast cancer molecular subtypes on DCE-MRI using convolutional neural network with transfer learning between two centers. *European Radiology* [en línea], vol. 31, no. 4, pp. 2559-2567. [Consulta: 19 noviembre 2022]. DOI 10.1007/s00330-020-07274-x. Disponible en: <https://link.springer.com/article/10.1007/s00330-020-07274-x>.

ZIPES, D., LIBBY, P., BONOW, R., MANN, D., y TOMASELLI, G. Braunwald Tratado de cardiología (11ª ed.). Elsevier Health Sciences. [consulta: 01 de julio de 2023]. ISBN: 978-0-323-46342-3. Disponible en: <https://books.google.com.pe/books?hl=es&lr=&id=LwBGDwAAQBAJ&oi=fnd&pg=PP1&dq=ZIPES,+D.,+LIBBY,+P.,+BONOW,+R.,+MANN,+D.,+y+TOMASELLI,+G.+Braunwald&ots=lvTZUoeii&sig=PMRdxpun7NLMaqaoVHmutgdWb9g#v=onepage&q=ZIPES%2C%20D.%2C%20LIBBY%2C%20P.%2C%20BONOW%2C%20R.%2C%20MANN%2C%20D.%2C%20y%20TOMASELLI%2C%20G.%20Braunwald&f=false>.

ANEXOS

Anexo 1: Matriz de operacionalización de variables

Tabla 8 Matriz de operacionalización de variables

Variable	Definición conceptual	Definición operacional	Indicador	Escala de medición
Sensibilidad	Es una métrica que señala el porcentaje de casos verídicos que fueron diagnosticados de manera correcta (Arciniegas, 2023, p. 60).	La habilidad de un test o prueba para identificar de manera precisa los casos que realmente tienen una enfermedad o condición específica, impidiendo así falsos negativos.	Diferencia de la sensibilidad entre los algoritmos CNN y NB = Sensibilidad del algoritmo NB - Sensibilidad del algoritmo CNN.	Valor
			Diferencia de la sensibilidad entre los algoritmos CNN y RF = Sensibilidad del algoritmo RF - Sensibilidad del algoritmo CNN.	Valor
			Diferencia de la sensibilidad entre los algoritmos NB y RF = Sensibilidad del algoritmo RF - Sensibilidad del algoritmo NB.	Valor
Especificidad	La probabilidad de que la prueba arroje un resultado positivo cuando la enfermedad está realmente presente (Zipes et al., 2019, p. 80).	Capacidad de un test o prueba para identificar de manera precisa los casos que realmente no tienen una enfermedad o condición específica, impidiendo así falsos positivos.	Diferencia de la especificidad entre los algoritmos CNN y NB = Especificidad del algoritmo NB - Especificidad del algoritmo CNN	Valor
			Diferencia de la especificidad entre los algoritmos CNN y RF = Especificidad del algoritmo RF - Especificidad del algoritmo CNN	Valor
			Diferencia de la especificidad entre los algoritmos NB y RF = Especificidad del algoritmo RF - Especificidad del algoritmo NB	Valor
Precisión	Suficiencia que posee el clasificador de no catalogar como positivo una muestra que es negativa (Arciniegas, 2023, p. 60).	Se refiere a la medida de qué tan bien un test o prueba diagnóstica identifica correctamente los casos positivos.	Diferencia de la precisión entre los algoritmos CNN y NB = Precisión del algoritmo NB - Precisión del algoritmo CNN	Valor
			Diferencia de la precisión entre los algoritmos CNN y RF = Precisión del algoritmo RF - Precisión del algoritmo CNN	Valor
			Diferencia de la precisión entre los algoritmos NB y RF = Precisión del algoritmo RF - Precisión del algoritmo NB	Valor

Variable	Definición conceptual	Definición operacional	Indicador	Escala de medición
Exactitud	Alude al porcentaje de casos que el modelo ha acertado (Arciniegas, 2023, p. 60).	Se refiere a la medida de qué tan cercano está el resultado obtenido por una prueba o prueba a la verdad absoluta o al valor de referencia conocido.	Diferencia de la exactitud entre los algoritmos CNN y NB = Exactitud del algoritmo NB - Exactitud del algoritmo CNN	Valor
			Diferencia de la exactitud entre los algoritmos CNN y RF = Exactitud del algoritmo RF - Exactitud del algoritmo CNN	Valor
			Diferencia de la exactitud entre los algoritmos NB y RF = Exactitud del algoritmo RF - Exactitud del algoritmo NB	Valor
Tiempo de entrenamiento	Período necesario para que un modelo o algoritmo de aprendizaje automático procese y aprenda de un conjunto de datos (Abunasser et al, 2022, p. 227).	Período de tiempo necesario para que el modelo de aprendizaje automático se entrene utilizando un conjunto de datos de imágenes mamográficas etiquetadas.	Diferencia del tiempo de entrenamiento entre los algoritmos CNN y NB = Tiempo de entrenamiento del algoritmo NB - Tiempo de entrenamiento del algoritmo CNN	Valor
			Diferencia del tiempo de entrenamiento entre los algoritmos CNN y RF = Tiempo de entrenamiento del algoritmo RF - Tiempo de entrenamiento del algoritmo CNN	Valor
			Diferencia del tiempo de entrenamiento entre los algoritmos NB y RF = Tiempo de entrenamiento del algoritmo RF - Tiempo de entrenamiento del algoritmo NB	Valor
Tiempo de identificación	Implica el procesamiento de las imágenes, la extracción de características relevantes y la clasificación de las mismas (Thilagaraj et al, 2022, p. 11)	Periodo necesario para procesar y analizar las imágenes mamográficas con el objetivo de identificar y confirmar la presencia de anomalías cancerosas.	Diferencia del tiempo de identificación entre los algoritmos CNN y NB = Tiempo de identificación del algoritmo NB - Tiempo de identificación del algoritmo CNN	Valor
			Diferencia del tiempo de identificación entre los algoritmos CNN y RF = Tiempo de identificación del algoritmo RF - Tiempo de identificación del algoritmo CNN	Valor
			Diferencia del tiempo de identificación entre los algoritmos NB y RF = Tiempo de identificación del algoritmo RF - Tiempo de identificación del algoritmo NB	Valor

Anexo 2: Matriz de consistencia

Tabla 9 Matriz de consistencia

PROBLEMA	OBJETIVO	HIPÓTESIS	VARIABLE	INDICADORES
General	General	General		
¿Cuál fue el algoritmo con la mejor eficiencia diagnóstica del cáncer de mama en mujeres entre CNN, NB y RF?	Comparar la eficiencia diagnóstica del cáncer de mama en mujeres con los algoritmos CNN, NB y RF.	El algoritmo NB tuvo mayor eficiencia diagnóstica del cáncer de mama en mujeres que los algoritmos CNN y RF		
Específicos	Específicos	Específicos		
PE1: ¿Cuál fue el algoritmo con la mayor sensibilidad para el diagnóstico del cáncer de mama en mujeres entre CNN, NB y RF?	OE1: Comparar la sensibilidad para el diagnóstico del cáncer de mama en mujeres con los algoritmos CNN, NB y RF	HE1: El algoritmo NB tuvo mayor sensibilidad para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF. (Singh Harmandeep et al., 2022, p. 6).	Sensibilidad (Nasien et al., 2022, p. 5).	Diferencia de la sensibilidad entre los algoritmos CNN y NB = Sensibilidad del algoritmo NB - Sensibilidad del algoritmo CNN. Diferencia de la sensibilidad entre los algoritmos CNN y RF = Sensibilidad del algoritmo RF - Sensibilidad del algoritmo CNN. Diferencia de la sensibilidad entre los algoritmos NB y RF = Sensibilidad del algoritmo RF - Sensibilidad del algoritmo NB. (Singh Harmandeep et al., 2022, p. 6).

PROBLEMA	OBJETIVO	HIPÓTESIS	VARIABLE	INDICADORES
Específicos	Específicos	Específicos		
PE1: ¿Cuál fue el algoritmo con la mayor sensibilidad para el diagnóstico del cáncer de mama en mujeres entre CNN, NB y RF?	OE1: Comparar la sensibilidad para el diagnóstico del cáncer de mama en mujeres con los algoritmos CNN, NB y RF	HE1: El algoritmo NB tuvo mayor sensibilidad para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF. (Singh Harmandeep et al., 2022, p. 6).	Sensibilidad (Nasien et al., 2022, p. 5).	<p>Diferencia de la sensibilidad entre los algoritmos CNN y NB = Sensibilidad del algoritmo NB - Sensibilidad del algoritmo CNN.</p> <p>Diferencia de la sensibilidad entre los algoritmos CNN y RF = Sensibilidad del algoritmo RF - Sensibilidad del algoritmo CNN.</p> <p>Diferencia de la sensibilidad entre los algoritmos NB y RF = Sensibilidad del algoritmo RF - Sensibilidad del algoritmo NB. (Singh Harmandeep et al., 2022, p. 6).</p>
PE2: ¿Cuál fue el algoritmo con la mayor especificidad para el diagnóstico del cáncer de mama en mujeres entre CNN, NB y RF?	OE2: Comparar la especificidad para el diagnóstico del cáncer de mama en mujeres con los algoritmos CNN, NB y RF.	HE2: El algoritmo NB tuvo mayor especificidad para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF. (Algehyne et al., 2022, p. 13; Tran et al., 2022, p. 16).	Especificidad (Nasien et al., 2022, p. 5).	<p>Diferencia de la especificidad entre los algoritmos CNN y NB = Especificidad del algoritmo NB - Especificidad del algoritmo CNN.</p> <p>Diferencia de la especificidad entre los algoritmos CNN y RF = Especificidad del algoritmo RF - Especificidad del algoritmo CNN.</p> <p>Diferencia de la especificidad entre los algoritmos NB y RF = Especificidad del algoritmo RF - Especificidad del algoritmo NB. (Algehyne et al., 2022, p. 13; Tran et al., 2022, p. 16).</p>
PE3: ¿Cuál fue el algoritmo con la mayor precisión para el diagnóstico del cáncer de mama en mujeres entre CNN, NB y RF?	OE3: Comparar la precisión para el diagnóstico del cáncer de mama en mujeres con los algoritmos CNN, NB y RF.	HE3: El algoritmo NB tuvo mayor precisión para el diagnóstico del cáncer de mama que los algoritmos CNN y RF (Sherina et al., 2020, p. 62).	Precisión (Nasien et al., 2022, p. 5).	<p>Diferencia de la precisión entre los algoritmos CNN y NB = Precisión del algoritmo NB - Precisión del algoritmo CNN.</p> <p>Diferencia de la precisión entre los algoritmos CNN y RF = Precisión del algoritmo RF - Precisión del algoritmo CNN.</p> <p>Diferencia de la precisión entre los algoritmos NB y RF = Precisión del algoritmo RF - Precisión del algoritmo NB. (Sherina et al., 2020, p. 62).</p>

PROBLEMA	OBJETIVO	HIPÓTESIS	VARIABLE	INDICADORES
Específicos	Específicos	Específicos		
PE4: ¿Cuál fue el algoritmo con la mayor exactitud para el diagnóstico del cáncer de mama en mujeres entre CNN, NB y RF?	OE4: Comparar la exactitud para el diagnóstico del cáncer de mama en mujeres con los algoritmos CNN, NB y RF.	HE4: El algoritmo NB tuvo mayor exactitud para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF. (Abdulla et al., 2021, p. 1977).	Exactitud (Nasien et al., 2022, p. 5).	<p>Diferencia de la exactitud entre los algoritmos CNN y NB = Exactitud del algoritmo NB - Exactitud del algoritmo CNN.</p> <p>Diferencia de la exactitud entre los algoritmos CNN y RF = Exactitud del algoritmo RF - Exactitud del algoritmo CNN.</p> <p>Diferencia de la exactitud entre los algoritmos NB y RF = Exactitud del algoritmo RF - Exactitud del algoritmo NB. (Abdulla et al., 2021, p. 1977).</p>
PE5: ¿Cuál fue el algoritmo con el menor tiempo de entrenamiento para el diagnóstico del cáncer de mama en mujeres entre CNN, NB y RF?	OE5: Comparar el tiempo de entrenamiento para el diagnóstico del cáncer de mama en mujeres con los algoritmos CNN, NB y RF.	HE5: El algoritmo NB tuvo menor tiempo de entrenamiento para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF (Monja, 2020, p. 39; Paul et al., 2015, p. 101)	Tiempo de Entrenamiento (Nasien et al., 2022, p. 5).	<p>Diferencia del tiempo de entrenamiento entre los algoritmos CNN y NB = Tiempo de entrenamiento del algoritmo NB - Tiempo de entrenamiento del algoritmo CNN.</p> <p>Diferencia del tiempo de entrenamiento entre los algoritmos CNN y RF = Tiempo de entrenamiento del algoritmo RF - Tiempo de entrenamiento del algoritmo CNN.</p> <p>Diferencia del tiempo de entrenamiento entre los algoritmos NB y RF = Tiempo de entrenamiento del algoritmo RF - Tiempo de entrenamiento del algoritmo NB. (Monja, 2020, p. 39; Paul et al., 2015, p. 101).</p>
PE6: ¿Cuál fue el algoritmo con el menor tiempo de identificación para el diagnóstico del cáncer de mama en mujeres entre CNN, NB y RF?	OE6: Comparar el tiempo de identificación para el diagnóstico del cáncer de mama en mujeres con los algoritmos CNN, NB y RF	HE6: El algoritmo NB tuvo menor tiempo de identificación para el diagnóstico del cáncer de mama en mujeres que los algoritmos CNN y RF (Jayanthi y Wadhwa, 2021, p. 4444; Thilagaraj et al., 2022, p. 11).	Tiempo de Identificación (Nasien et al., 2022, p. 5).	<p>Diferencia del tiempo de identificación entre los algoritmos CNN y NB = Tiempo de identificación del algoritmo NB - Tiempo de identificación del algoritmo CNN.</p> <p>Diferencia del tiempo de identificación entre los algoritmos CNN y RF = Tiempo de identificación del algoritmo RF - Tiempo de identificación del algoritmo CNN.</p> <p>Diferencia del tiempo de identificación entre los algoritmos NB y RF = Tiempo de identificación del algoritmo RF - Tiempo de identificación del algoritmo NB. (Jayanthi y Wadhwa, 2021, p. 4444; Thilagaraj et al., 2022, p. 11).</p>

Anexo 3: Instrumentos de recolección de datos de imágenes

Tabla 10 Instrumentos de recolección de datos de imágenes

Índice	Código de imagen	Tipo de imagen	¿Tiene cáncer de mama?		Resultado del diagnóstico preliminar	
			Sí	No	Sí	No
1	DPCM-pre-01					
2	DPCM-pre-02					
3	DPCM-pre-03					
4	DPCM-pre-04					
5	DPCM-pre-05					
6	DPCM-pre-06					
7	DPCM-pre-07					
8	DPCM-pre-08					
9	DPCM-pre-09					
10	DPCM-pre-10					
11	DPCM-pre-11					
12	DPCM-pre-12					
13	DPCM-pre-13					
...	DPCM-pre-...					
7632	DPCM-pre-7632					

Anexo 4: Arquitectura tecnológica para el entorno de desarrollo

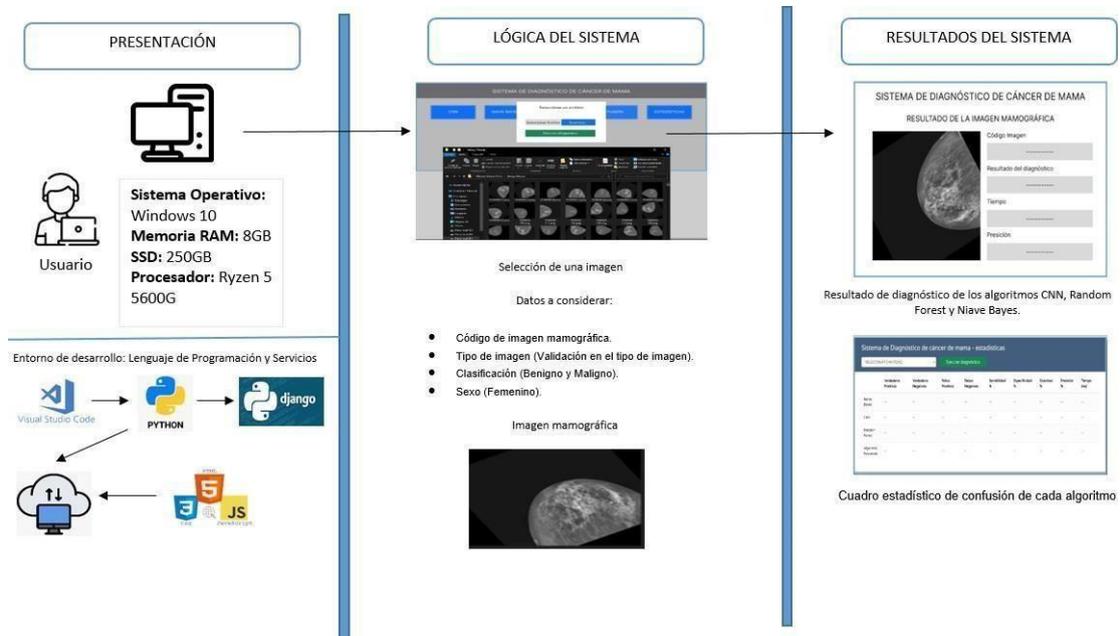


Figura 1 Arquitectura tecnológica para el entorno de desarrollo

En la figura 1 se muestra la relación del desarrollo con el cliente y el servidor para una aplicación web. Se utilizan las siguientes tecnologías: Python, Django, Visual Studio Code, HTML5, AJAX, JavaScript y CSS para presentar el sistema en el navegador web y definir la arquitectura tecnológica.

El servidor está configurado con las siguientes especificaciones de hardware:

- Sistema Operativo: Windows 10
- Memoria RAM: 8GB DDR4 (3200 Mhz)
- Disco SSD: 250GB
- Procesador: AMD Ryzen 5 - 5600G (6 nucleos – 12 hilos – 3.90 Ghz)

Estas especificaciones garantizan un rendimiento óptimo del servidor y una experiencia fluida para los usuarios.

Anexo 5: Arquitectura tecnológica para el entorno de producción

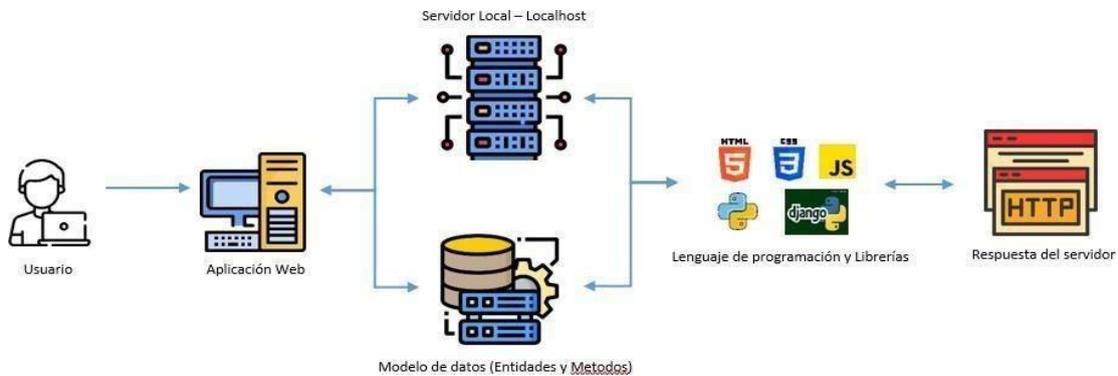


Figura 2 Arquitectura tecnológica para el entorno de producción

En la figura 2 se muestra la arquitectura tecnológica para una aplicación web de gestión de tareas que se ejecuta en el servidor local (localhost).

Componentes del Sistema:

- ▢ Servidor Local (localhost).
- ▢ Aplicación Web.
- ▢ Base de Datos Local.
- ▢ Navegadores Web de los Usuarios.

Especificaciones del Hardware del Servidor:

- ▢ Procesador: Ryzen 5 – 5600 G (6 núcleos – 12 hilos – 3.90 Ghz)
- ▢ Memoria RAM: 8GB DDR4 (3200 Mhz)
- ▢ Almacenamiento: Disco SSD 250Gb
- ▢ Conectividad: 1 Gbps Ethernet
- ▢ Sistema Operativo: Windows 10

Especificaciones del Hardware de los Usuarios (Mínimo Requisito):

Computadora de Escritorio con acceso a internet:

- ▢ Procesador: Intel Core Pentium (2 núcleos, 4 hilos, 2.90 Ghz)
- ▢ Memoria RAM: 4GB DDR2 (1600 Mhz)
- ▢ Almacenamiento: 120GB HDD
- ▢ Sistema Operativo: Windows 7/8/10
- ▢ Conectividad: 1 Gbps Ethernet

Anexo 6: Prototipo del sistema

En la figura 3 se muestra el panel principal de sistema, donde muestra opciones múltiples. Las opciones del sistema son: CNN, NB, RF, estadísticas de los algoritmos y los algoritmos fusionados.



Figura 3 Panel principal del sistema

En la figura 4 se muestra una ventana emergente en la cual permite seleccionar una imagen para su respectivo diagnóstico, posterior a eso el usuario debe seleccionar los algoritmos u opciones que se muestra en la figura 3.



Figura 4 Ventana emergente para seleccionar una imagen

En la figura 5 se muestra el resultado de dicho diagnóstico, permitiendo obtener los siguientes datos, código de la imagen, resultado del diagnóstico, tiempo transcurrido durante el diagnóstico y finalmente la precisión.

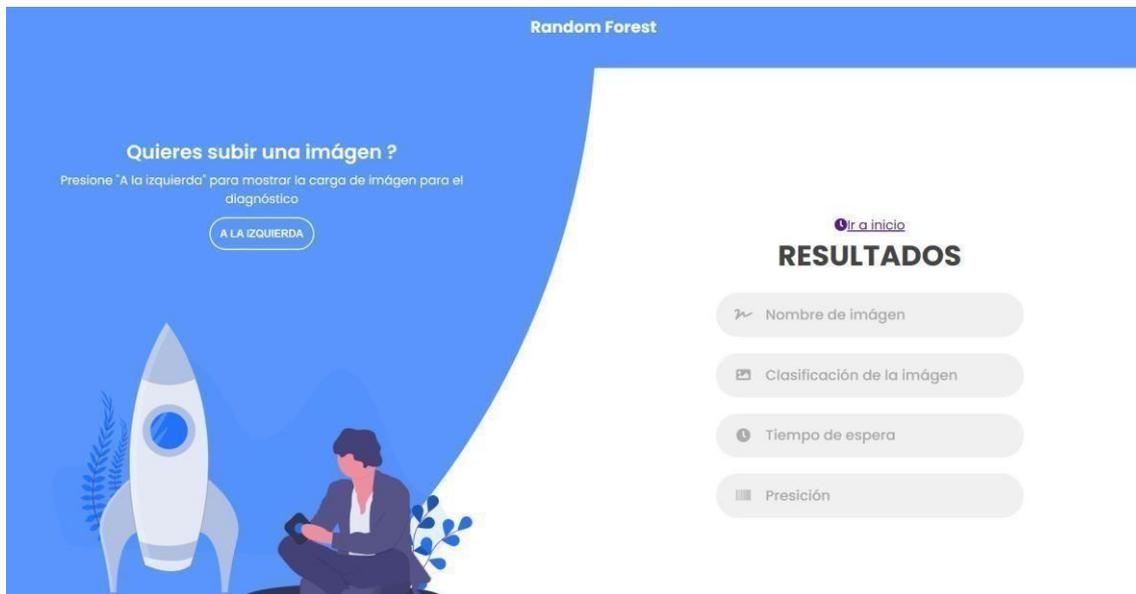


Figura 5 Resultado del diagnóstico

En la figura 6 se muestra el cuadro estadístico de confusión de cada algoritmo para evaluar la sensibilidad, especificidad, precisión, exactitud y tiempo de duración.

Tabla de Estadísticas de los Resultados

	Verdaderos Positivos	Verdaderos Negativos	Falsos Positivos	Falsos Negativos	Sensibilidad	Especificidad	Exactitud	Precisión	Tiempo de Entrenamiento (ms)	Tiempo de Identificación (ms)
Random F										
Naive B.										
CNN										

Figura 6 Estadísticas de resultados de los algoritmos

Anexo 7: Metodología XP

Jiménez et al. (2019) indicaron que la metodología XP es un procedimiento ágil focalizado en experiencias de programación, intercomunicación y trabajo en equipo; contienen normas de gestión, planeamiento, programación, diseño y pruebas para el desarrollo del software (p. 57). Asimismo, cuentan con pruebas funcionales que evalúan las historias de usuario. Por otro lado, Canchig y Chilla (2023) mencionaron que la metodología XP es un enfoque ágil de desarrollo de software que promueve buenas prácticas de codificación, comunicación efectiva y trabajo en equipo. Se centra en planificación, gestión, diseño, codificación y pruebas para producir software de calidad (p. 24).

Salazar et al. (2018) expresaron que la metodología XP se establece de seis fases para la iteración, planificación de entrega, exploración, mantenimiento, producción y fin del proyecto, donde la exploración el usuario establece la descripción absoluta del software ligado con las operatividades que abarca y la fase de planeación explica el tiempo de finalización (p. 34). A la vez, Salazar et al. (2018) señalaron que la metodología XP expresa cualidades o características, estas son:

- Comunicación: comprende el asertividad entre los desarrolladores del proyecto y el trabajo en conjunto, produciendo un entorno profesional adaptable (Salazar et al., 2019, p. 34).
- Simplicidad: es una cualidad donde el usuario comprende las prioridades del producto y del proyecto (Salazar et al., 2019, p. 34).
- Retroalimentación: en la codificación en pareja los comentarios de los demás integrantes del equipo son una retroalimentación, como también las ideas de otros integrantes sobre el desarrollo del producto (Salazar et al., 2019, p. 34).

Canchig y Chilla (2023) describieron los roles en la metodología XP, los cuales son:

- Cliente (Customer): El cliente tiene la autoridad para determinar la funcionalidad y prioridades en cada fase, basándose en el valor que aporta a su negocio. También es responsable de diseñar y llevar a cabo las pruebas de aceptación (Canchig y Chilla, 2023, p. 25).
- Programador (Developer): Implementa las historias del cliente, asignando prioridades según estimaciones de tiempo. Cada iteración agrega funcionalidades según las prioridades establecidas. Además, el programador realiza pruebas de unidad para el código desarrollado o modificado (Canchig y Chilla, 2023, p. 26).
- Encargado de Pruebas (Tester): Se encarga de ejecutar pruebas funcionales de forma regular, coordinar la planificación de las pruebas con los clientes y comunicar los resultados al equipo (Canchig y Chilla, 2023, p. 26).
- Encargado de Seguimiento (Tracker): Monitorea y evalúa las estimaciones realizadas por los programadores, comparándolas con el tiempo real de desarrollo. Esto permite proporcionar datos estadísticos sobre la calidad de las estimaciones y ofrecer oportunidades para su mejora (Canchig y Chilla, 2023, p. 26).
- Entrenador (Coach): El Coach es responsable de liderar y guiar al equipo en la implementación de las 12 prácticas de XP. Es una persona experimentada en el desarrollo con XP y se encarga de facilitar el proceso global (Canchig y Chilla, 2023, p. 26).
- Administrador (Manager): El Manager organiza las reuniones, supervisa el proceso de desarrollo y registra los resultados para su análisis. También se encarga de informar sobre el progreso del desarrollo al inversionista o stakeholders (Canchig y Chilla, 2023, p. 26).

Canchig y Chilla (2023) describieron las fases de la metodología XP, las cuales son:

- **Planificación:** Es el primer paso donde se interactúa con el usuario y el equipo de desarrollo para comprender los requisitos del sistema. Se determinan las iteraciones, su duración y se adapta la metodología según las características del proyecto (Canchig y Chilla, 2023, p. 26).
- **Diseño:** Simple y fácil, simplificando al máximo para facilitar su implementación. Esto reducirá el tiempo y esfuerzo requeridos durante el desarrollo. Durante esta etapa, se pueden crear partes del proyecto, como interfaces físicas, para el uso de usuarios o clientes (Canchig y Chilla, 2023, p. 27).
- **Codificación:** Es indispensable para el desarrollo, ya que es la forma más efectiva de transmitir ideas y lograr un entendimiento mutuo. Permite expresar conceptos de manera clara y facilita la colaboración entre las personas involucradas en un proyecto (Canchig y Chilla, 2023, p. 28).
- **Pruebas:** Son esenciales para validar su correcto funcionamiento y asegurarse de que cumple con las expectativas. Detectar y corregir errores a través de las pruebas aumenta la confianza en el sistema. Si las pruebas son exitosas, la etapa de codificación se considera completada (Canchig y Chilla, 2023, p. 28).

Anexo 8: Matriz de verificación de originalidad

Matriz de verificación de originalidad de una propuesta de investigación o innovación		
Título: Estudio comparativo de la eficiencia diagnóstica del cáncer de mama con los algoritmos CNN, NB y RF		
Referencia de la investigación o innovación similar a la propuesta	Aspectos teóricos, funcionales, técnicos, metodológicos, métricos, algorítmicos o estadísticos de la investigación científica o innovación de la referencia	Aspectos a incluir en la nueva propuesta
Detección de cáncer de mama usando Machine Learning	Se enfoca en evaluar y comparar los algoritmos Random Forest, kNN (k-Nearest-Neighbor) y Naive Bayes.	Evaluación de rendimiento de los algoritmos CNN, RF y NB.
	Se utiliza el conjunto de datos de Wisconsin Diagnosis Breast Cancer como conjunto de entrenamiento para comparar el rendimiento de los algoritmos de aprendizaje automático.	Utilidad de conjunto de datos de kaggle "Breast Cancer" para los entrenamientos y extracción de características de ellas mismas.
	Se evalúa el rendimiento de los algoritmos en términos de parámetros clave como la precisión y la exactitud.	Se evaluó los rendimientos como sensibilidad, especificidad, exactitud, precisión, tiempo de entrenamiento y tiempo de identificación de cada algoritmo propuesto.
Técnicas de Deep Learning para la Detección y diagnóstico de cáncer en los senos	Se utilizan diferentes modalidades de imágenes médicas, como mamografía digital (DM), ultrasonido (US), resonancia magnética (MRI), imágenes microscópicas (histológicas) y termografía infrarroja (IRT), para el diagnóstico del cáncer de mama.	Se utilizaron imágenes mamográficas para el entrenamiento de los algoritmos y la extracción de características.
	No se proporcionan métricas específicas en el texto, pero se menciona que las técnicas de deep learning han demostrado un rendimiento sin precedentes en muchas tareas desafiantes.	
	Se menciona que deep learning ha tenido aplicaciones exitosas en varios campos, incluyendo radiología y ciencias de imágenes.	
Integración de red neuronal convolucional y aumento de gradiente extremo para la detección de cáncer de mama	El objetivo del trabajo es utilizar el aprendizaje automático mediante el uso de algoritmos de machine learning y deep learning para mejorar la detección temprana de cáncer de mama en imágenes médicas.	Como objetivo propuesto es dar a conocer el rendimiento de cada algoritmo y así evaluar cual de ellas es mejor en ciertos aspectos de rendimiento.
	Se menciona el uso de diversas técnicas de aprendizaje automático, como deep learning, y algoritmos específicos como el Convolutional Neural Network (CNN) y el Extreme Gradient Boosting (XGBoost), para la detección de cáncer de mama en imágenes médicas.	Se utilizaron librerías como OpenCV para la extracción de características de la imagen mamográfica y Django para el funcionamiento en el entorno web.
	Se emplean técnicas de data augmentation y transfer learning para superar las deficiencias en los conjuntos de datos utilizados y mejorar la precisión del modelo de detección.	Se empleó un aumento de datos que permite tener un mejor rendimiento a los algoritmos.
	Aspectos no incluidos previamente en otro producto o investigación	Integración de redes neuronales convolucionales, random forest, naive bayes
		Integración de una pagina web para el respectivo diagnostico y comparación de los algoritmos.
		Algoritmos de clasificación

Figura 7 Matriz de verificación de originalidad

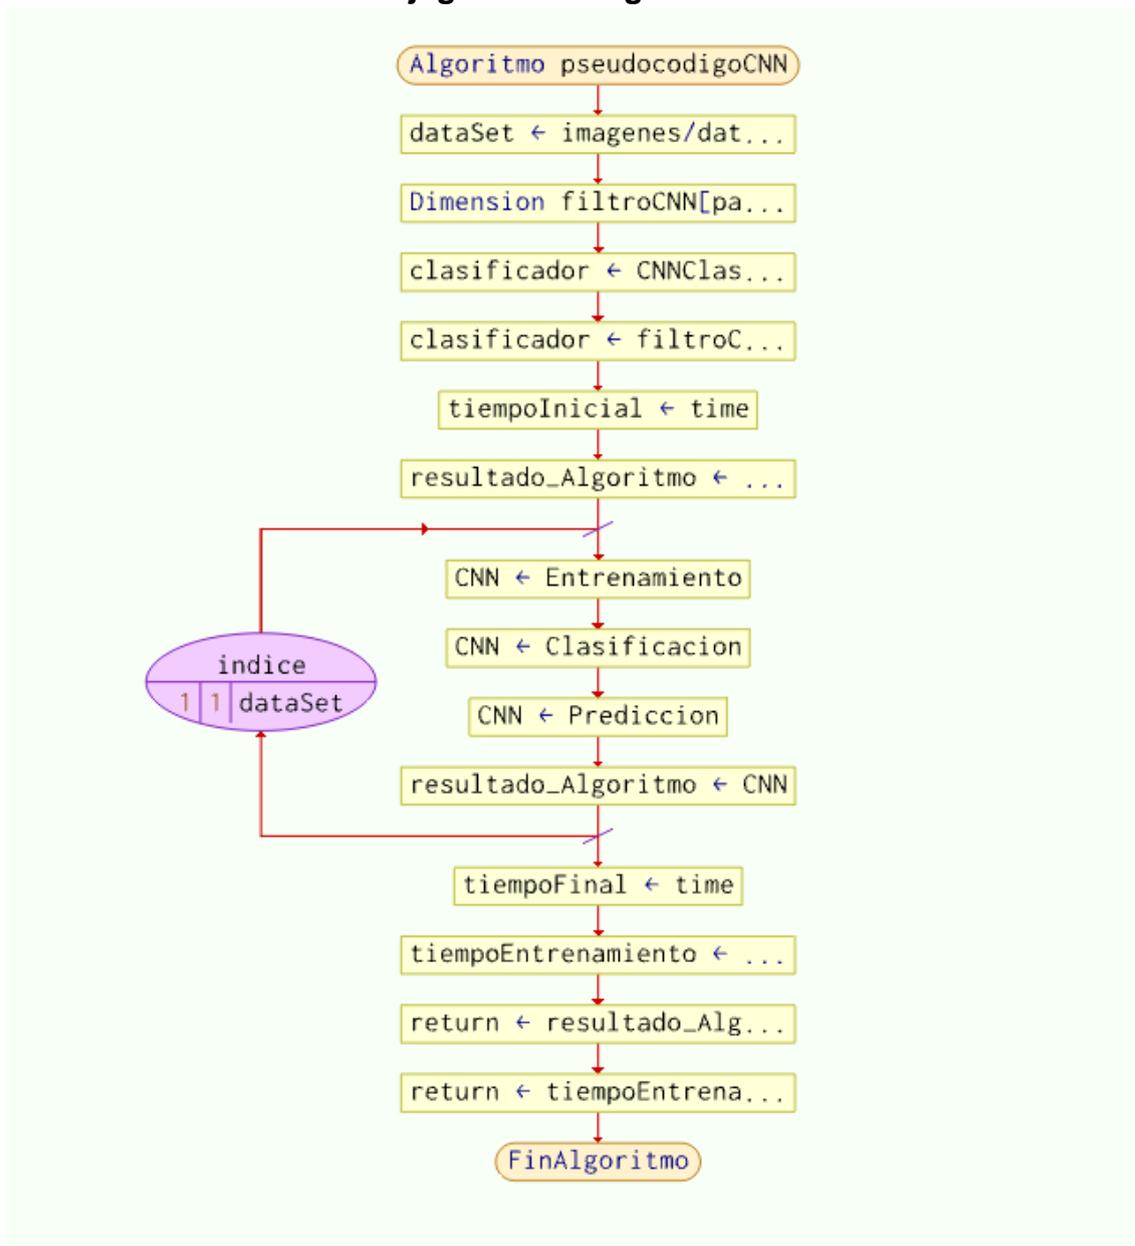
Anexo 9: Pseudocódigo del algoritmo CNN

```
1 Algoritmo pseudocodigoCNN
2   dataSet ← imagenes/datasetImage
3   Dimension filtroCNN[parametro_1]
4   clasificador←CNNClasificador
5   clasificador←filtroCNN[dataSet]
6   tiempoInicial ← time
7   resultado_Algoritmo ← null
8   Para indice←1 Hasta dataSet Con Paso 1 Hacer
9     CNN ← Entrenamiento
10    CNN ← Clasificacion
11    CNN ← Prediccion
12    resultado_Algoritmo ← CNN
13  FinPara
14  tiempoFinal←time
15  tiempoEntrenamiento←tiempoFinal-tiempoInicial
16  return←resultado_Algoritmo
17  return←tiempoEntrenamiento
18 FinAlgoritmo
19
```

Elshennawy et al. (2022), Pseudocódigo del algoritmo CNN

Figura 8 Pseudocódigo del algoritmo CNN.

Flujograma de algoritmo CNN



Elshennawy et al. (2022), Flujograma del algoritmo CNN

Figura 9 Flujograma de algoritmo CNN.

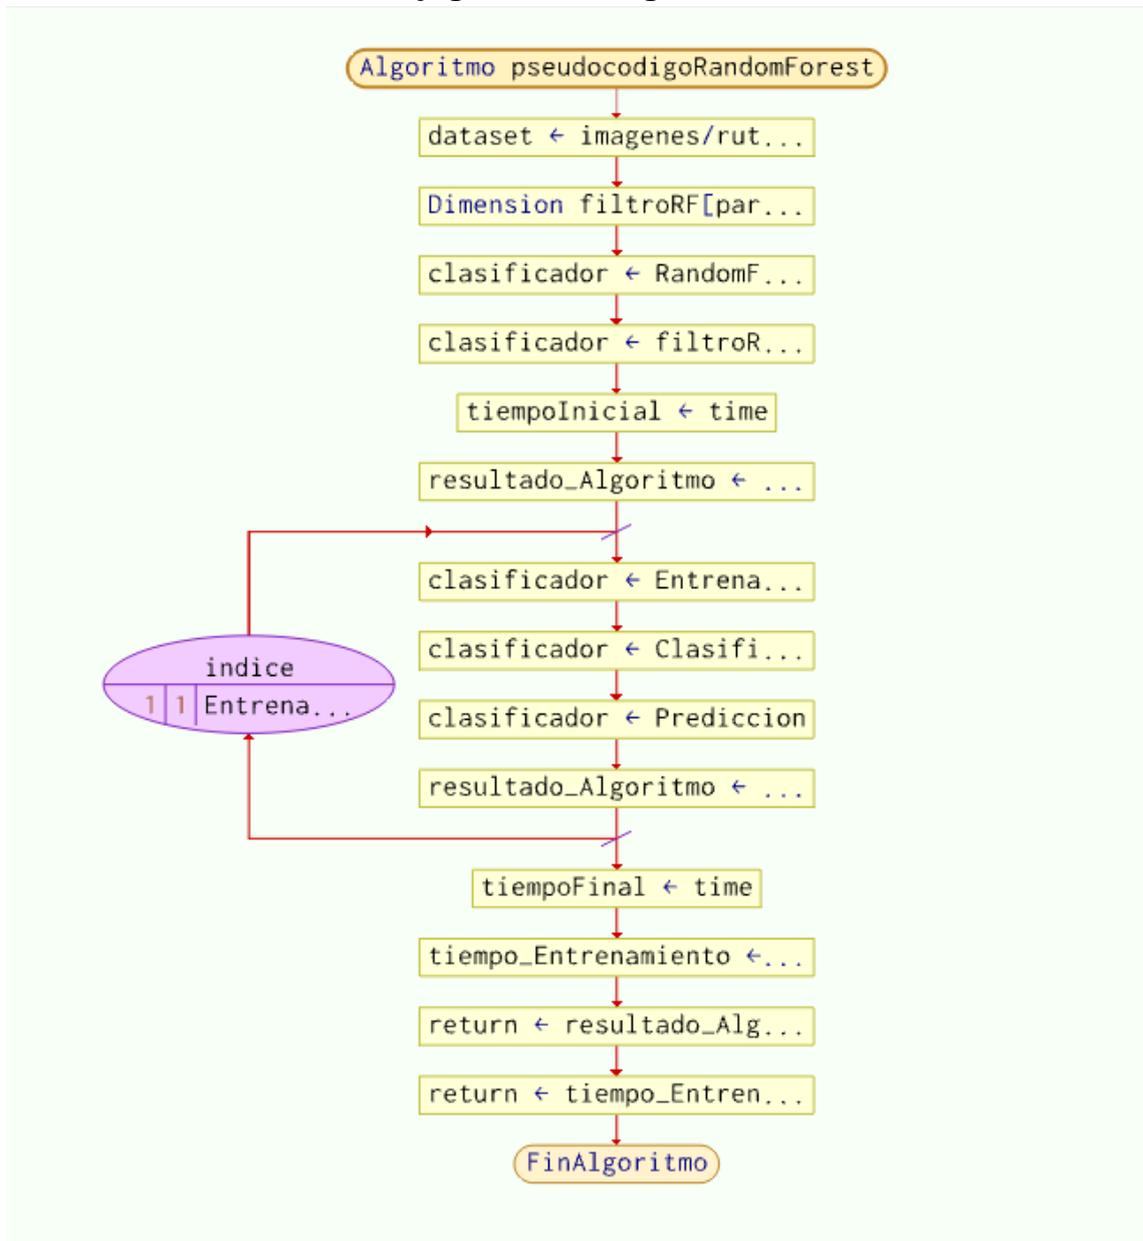
Anexo 10: Pseudocódigo del algoritmo RF

```
1  Algoritmo pseudocodigoRandomForest
2    dataset←imagenes/ruta_imagenes
3    Dimension filtroRF[parametro_1]
4    clasificador←RandomForestClasificador
5    clasificador←filtroRF[entrenamiento_x]
6    tiempoInicial←time
7    resultado_Algoritmo←null
8    Para indice←1 Hasta entrenamiento Con Paso 1 Hacer
9      clasificador←Entrenamiento
10     clasificador←Clasificacion
11     clasificador←Prediccion
12     resultado_Algoritmo←clasificador
13   Fin Para
14   tiempoFinal←time
15   tiempo_Entrenamiento←tiempoFinal-tiempoInicial
16   return←resultado_Algoritmo
17   return←tiempo_Entrenamiento
18 FinAlgoritmo
19
```

González (2022), Pseudocódigo del algoritmo RF

Figura 10 Pseudocódigo del algoritmo RF

Flujograma del algoritmo RF



González (2022), Flujograma del algoritmo RF

Figura 11 Flujograma de algoritmo RF

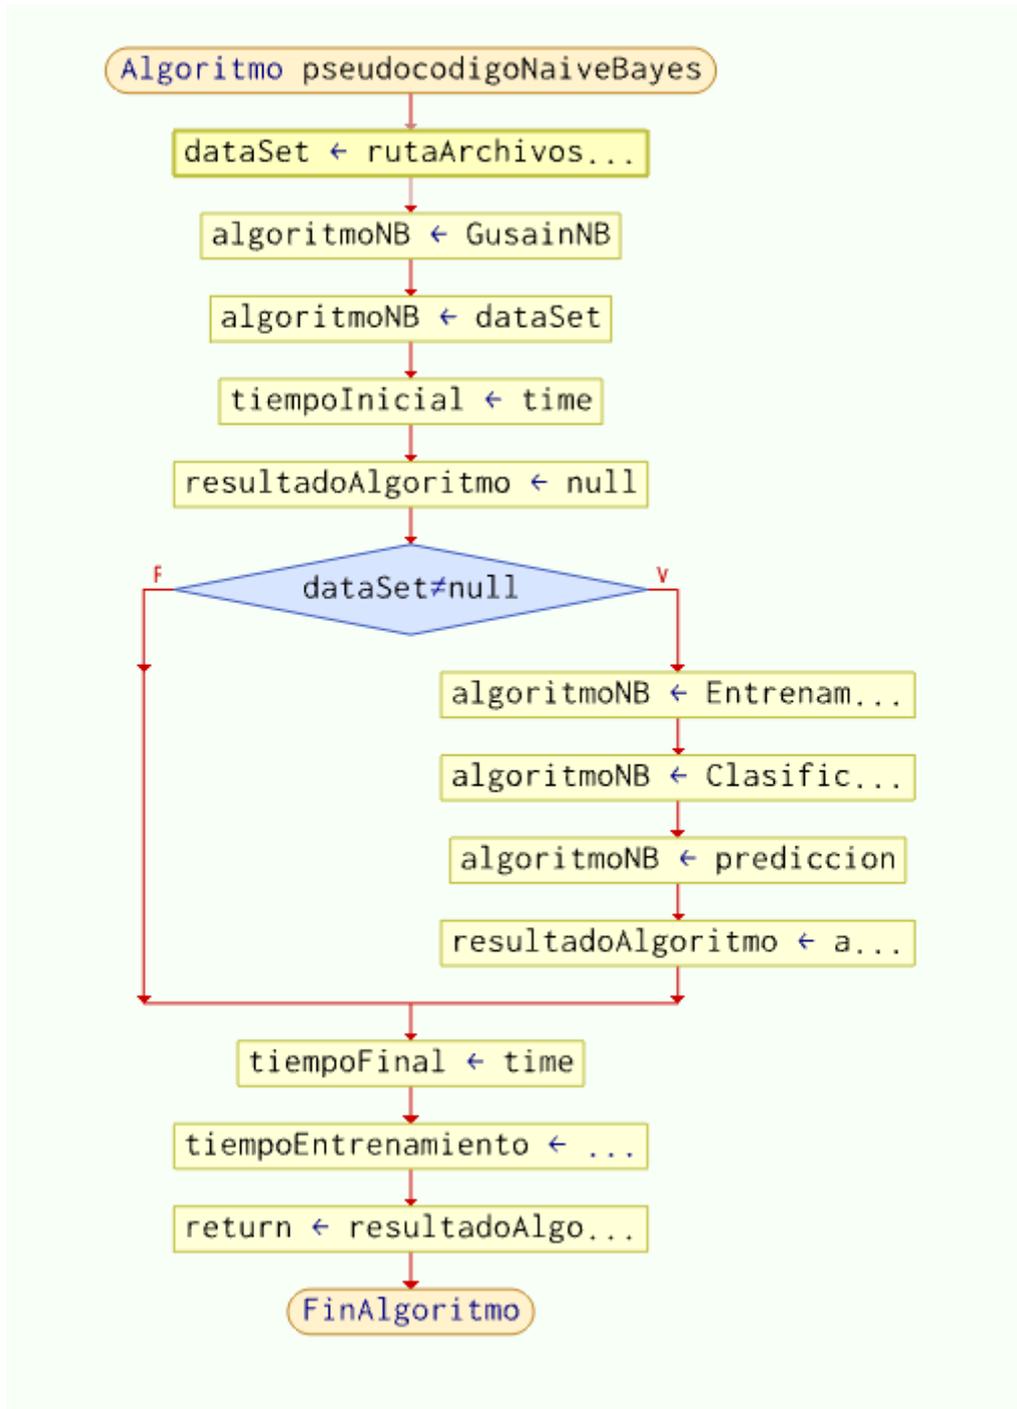
Anexo 11: Pseudocódigo del algoritmo NB

```
1 Algoritmo pseudocodigoNaiveBayes
2   dataSet = rutaArchivos/Imagenes
3   algoritmoNB ← GusainNB
4   algoritmoNB ← dataSet
5   tiempoInicial ← time
6   resultadoAlgoritmo ← null
7   Si dataSet ≠ null Entonces
8     algoritmoNB ← Entrenamiento
9     algoritmoNB ← Clasificacion
10    algoritmoNB ← prediccion
11    resultadoAlgoritmo ← algoritmoNB
12  Fin Si
13  tiempoFinal ← time
14  tiempoEntrenamiento ← tiempoFinal - tiempoInicial
15  return ← resultadoAlgoritmo
16 FinAlgoritmo
17
```

González (2019), Pseudocódigo del algoritmo Naive Bayes

Figura 12 Pseudocódigo del algoritmo NB

Flujograma de algoritmo NB



González (2019), Flujograma del algoritmo Naive Bayes

Figura 13 Flujograma de algoritmo NB

Anexo 12: Manual de usuario

En la figura 14 se muestra el panel principal de sistema de diagnóstico del cáncer de mama donde muestra cuatro opciones, las cuales son: CNN, Random Forest, Naive Bayes y estadísticas (las 3 primeras opciones sirven para dirigirse a la página del diagnóstico mediante una imagen por cada algoritmo y la última opción sirve para dirigirse a la tabla de estadísticas donde se realiza el cálculo de las variables y de los VP, FP, VN y FN). Luego muestra tres botones las cuales son: Información, En el Perú y Para el video (los dos primeros botones muestran un modal con información de la enfermedad del cáncer de mama y el último botón muestra un modal con sugerencia para ver el video orientado a la enfermedad del cáncer de mama).



Figura 14 Panel principal del sistema

En la figura 15 se muestra el apartado para visualizar 3 videos referenciados con la enfermedad del cáncer de mama, donde haciendo clic a cada circulo celeste muestra un video.

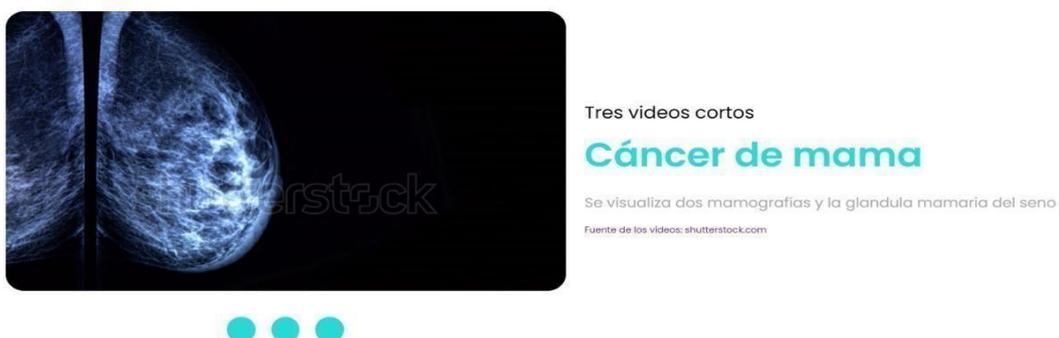


Figura 15 Apartado para visualizar los videos

En la figura 16 se muestra el apartado donde muestra 3 tarjetas con una imagen mamográfica para cada algoritmo CNN, RF y NB. Al hacer clic en cada una de las tarjetas se direccionará a la página a la cual fue elegido para el diagnóstico de la enfermedad del cáncer de mama.



Figura 16 Tarjetas de direccionamiento para cada algoritmo

En la figura 17 se muestra la página del diagnóstico de la enfermedad del cáncer de mama con el algoritmo CNN. El lado izquierdo permite seleccionar una imagen mamográfica (benigno y maligno), una vez cargada la imagen se debe hacer clic al botón diagnosticar para mostrar los campos del diagnóstico.



Figura 17 Página para la carga de imagen con CNN

En la figura 18 se muestra la página del diagnóstico de la enfermedad del cáncer de mama con el algoritmo CNN. El lado derecho permite mostrar los resultados del diagnóstico, los campos del diagnóstico son: nombre de la imagen, clasificación de la imagen, tiempo de espera y precisión.



Figura 18 Página para el diagnóstico con CNN

En la figura 19 se muestra la página del diagnóstico de la enfermedad del cáncer de mama con el algoritmo RF. El lado izquierdo permite seleccionar una imagen mamográfica (benigno y maligno), una vez cargada la imagen se debe hacer clic al botón diagnosticar para mostrar los campos del diagnóstico.

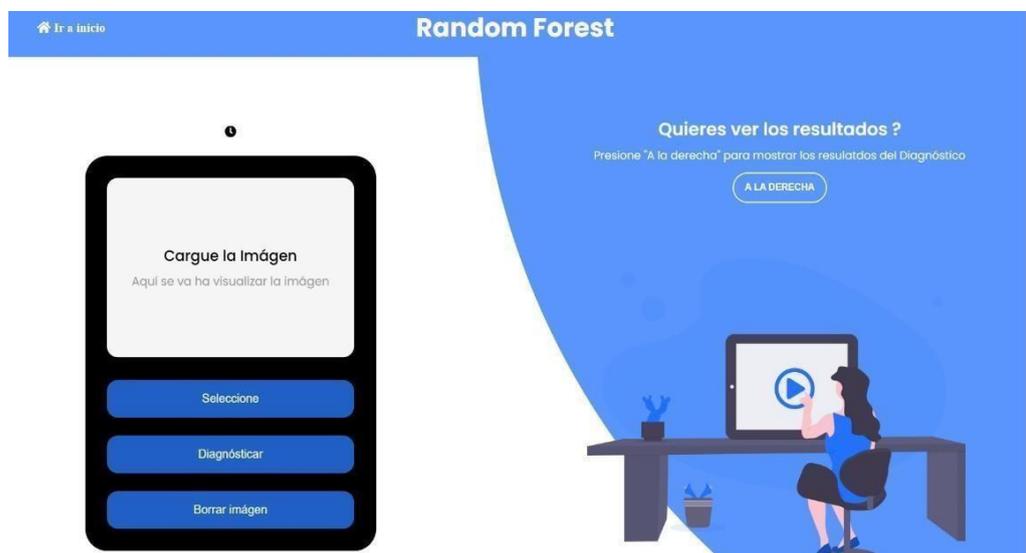


Figura 19 Página para la carga de imagen con RF

En la figura 20 se muestra la página del diagnóstico de la enfermedad del cáncer de mama con el algoritmo RF. El lado derecho permite mostrar los resultados del diagnóstico, los campos del diagnóstico son: nombre de la imagen, clasificación de la imagen, tiempo de espera y precisión.



Figura 20 Página para el diagnóstico con RF

En la figura 21 se muestra la página del diagnóstico de la enfermedad del cáncer de mama con el algoritmo NB. El lado izquierdo permite seleccionar una imagen mamográfica (benigno y maligno), una vez cargada la imagen se debe hacer clic al botón diagnosticar para mostrar los campos del diagnóstico.

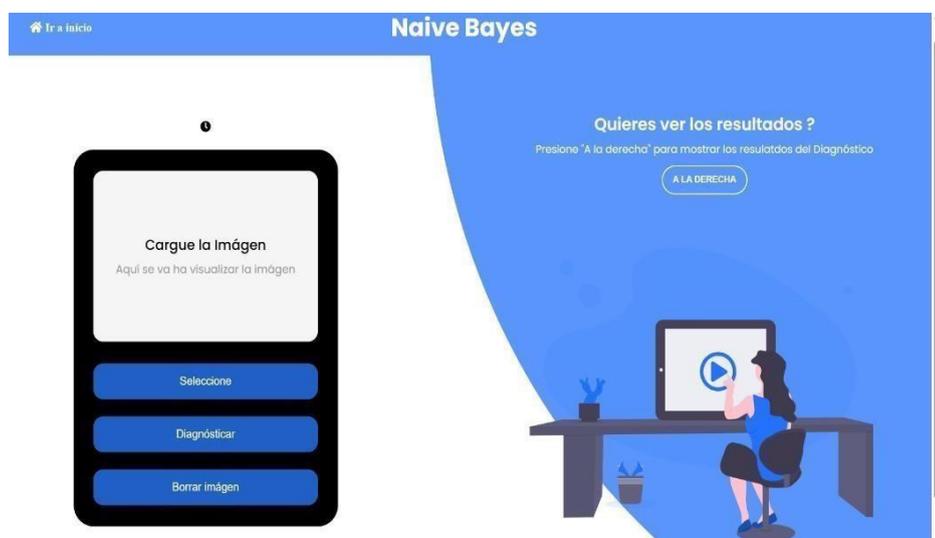


Figura 21 Página para la carga de imagen con NB

En la figura 22 se muestra la página del diagnóstico de la enfermedad del cáncer de mama con el algoritmo NB. El lado derecho permite mostrar los resultados del diagnóstico, los campos del diagnóstico son: nombre de la imagen, clasificación de la imagen, tiempo de espera y precisión.



Figura 22 Página para el diagnóstico con NB

En la figura 23 se muestra la página de estadísticas de los resultados donde permite seleccionar el número de imágenes (30, 50, 100, 200, 300, 400, 500, 600, 700, 800, 900, 1000, 2000, 3000, 4000, 5000 y 7632) a calcular. Una vez seleccionado la cantidad de imágenes se procede hacer clic al botón “ejecutar” para la carga respectiva, donde brinda la sensibilidad, especificidad, precisión y exactitud en símbolo de porcentaje y el tiempo entrenamiento y de identificación en ms, mientras que los VP, VN, FP y FN en número entero para los algoritmos CNN, NB y RF.

Tabla de Estadísticas de los Resultados

	Verdaderos Positivos	Verdaderos Negativos	Falsos Positivos	Falsos Negativos	Sensibilidad	Especificidad	Exactitud	Precisión	Tiempo de Entrenamiento (ms)	Tiempo de Identificación (ms)
Random F										
Naive B										
CNN										

Figura 23 Tabla de estadísticas de los resultados