



Universidad  
Señor de Sipán

**FACULTAD DE INGENIERÍA, ARQUITECTURA Y  
URBANISMO**

**ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**

**TESIS**

**Análisis de algoritmos de aprendizaje automático para la  
detección de cáncer de cuello uterino utilizando imágenes  
de papanicolaou**

**PARA OPTAR EL TÍTULO PROFESIONAL DE  
INGENIERO(A) DE SISTEMAS**

**Autor(es)**

Bach. Crisanto Matallana Jesus Elmer

ORCID: <https://orcid.org/0000-0001-8246-1940>

Bach. Vilchez Chaname Loisabett

ORCID: <https://orcid.org/0000-0002-8641-7215>

**Asesor**

Mg. Bravo Ruiz Jaime Arturo

ORCID: <https://orcid.org/0000-0002-5913-990X>

**Línea de Investigación**

**Ciencias de la información como herramientas multidisciplinares  
y estratégicas en el contexto industrial y de organizaciones**

**Sublínea de Investigación**

**Informática y transformación digital en el contexto industrial y  
organizacional**

**Pimentel – Perú**

**2024**

**ANÁLISIS DE ALGORITMOS DE APRENDIZAJE AUTOMÁTICO PARA LA  
DETECCIÓN DE CÁNCER DE CUELLO UTERINO UTILIZANDO IMÁGENES DE  
PAPANICOLAOU**

**Aprobación del jurado**

---

Dr. Carlos Willian Atalaya Urrutia

**Presidente del Jurado de Tesis**

---

MG. David Enrique Bances Saavedra

**Secretario del Jurado de Tesis**

---

MG. Jaime Arturo Bravo Ruiz

**Vocal del Jurado de Tesis**



Universidad  
Señor de Sipán

### ANEXO 01: DECLARACIÓN JURADA DE ORIGINALIDAD

Quien(es) suscribe(n) la DECLARACIÓN JURADA, soy(somos) **Crisanto Matallana Jesús Elmer, Vilchez Chaname Loisabett** del Programa de Estudios de **Ingeniería de sistemas** de la Universidad Señor de Sipán S.A.C, declaro (amos) bajo juramento que soy (somos) autor(es) del trabajo titulado:

#### ANÁLISIS DE ALGORITMOS DE APRENDIZAJE AUTOMÁTICO PARA LA DETECCIÓN DE CÁNCER DE CUELLO UTERINO UTILIZANDO IMÁGENES DE PAPANICOLAOU

El texto de mi trabajo de investigación responde y respeta lo indicado en el Código de Ética del Comité Institucional de Ética en Investigación de la Universidad Señor de Sipán, conforme a los principios y lineamientos detallados en dicho documento, en relación con las citas y referencias bibliográficas, respetando el derecho de propiedad intelectual, por lo cual informo que la investigación cumple con ser inédito, original y autentico.

En virtud de lo antes mencionado, firman:

Crisanto Matallana Jesús Elmer	DNI: 74769194	 firma
Vilchez Chaname Loisabett	DNI: 48431457	 Firma

Pimentel, 24 de Diciembre de 2022.

# Crisanto Matallana Jesus Elmer Vilchez Chaname L...

## Análisis de algoritmos de aprendizaje automático para la detección de cáncer de cuello uterino utili

Universidad Señor de Sipán

### Detalles del documento

Identificador de la entrega  
trn:oid:::26396:409724982

Fecha de entrega  
26 nov 2024, 11:07 a.m. GMT-5

Fecha de descarga  
26 nov 2024, 11:08 a.m. GMT-5

Nombre de archivo  
tesis final-turnitin.docx

Tamaño de archivo  
1.9 MB

23 Páginas

5,464 Palabras

31,501 Caracteres



Página 1 of 30 - Portada

Identificador de la entrega trn:oid:::26396:409724982



Página 2 of 30 - Descripción general de integridad

Identificador de la entrega trn:oid:::26396:409724982

## 11% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

### Filtrado desde el informe

- ▶ Bibliografía
- ▶ Texto mencionado
- ▶ Coincidencias menores (menos de 8 palabras)

### Fuentes principales

- 4% Fuentes de Internet
- 2% Publicaciones
- 9% Trabajos entregados (trabajos del estudiante)

### Marcas de integridad

N.º de alerta de integridad para revisión

- Texto oculto**  
154 caracteres sospechosos en N.º de páginas  
El texto es alterado para mezclarse con el fondo blanco del documento.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

## **Dedicatoria**

A mi madre, fuente inagotable de amor, apoyo y sabiduría. Gracias por tu esfuerzo incansable, por ser mi guía en los momentos más difíciles y por creer siempre en mis sueños. Este logro es tanto tuyo como mío, y no podría haberlo alcanzado sin tu fortaleza y sacrificio.

A mi amada, por ser mi compañera en este viaje. Gracias por tu paciencia, comprensión y amor incondicional, que me han dado la motivación y energía para seguir adelante, incluso en los días más duros. Tu presencia ha hecho de este camino algo mucho más llevadero y significativo.

Jesus Crisanto

A mi madre, Ketty Marlene Chaname Chaname, por ser mi pilar incondicional, por su amor, su fortaleza, y por enseñarme que los sueños se alcanzan con esfuerzo y dedicación.

A mi hermana, por su apoyo constante, su alegría, y por estar siempre a mi lado en los momentos más importantes.

A mis abuelos, María Ruth Chaname Llontop y Gregorio Chaname Chanduvi, cuyo amor y sabiduría han sido una fuente de inspiración a lo largo de mi vida. Sus consejos y su ejemplo siempre me guiarán.

Loisabett Vilchez

## **Agradecimientos**

A mi madre, mi pilar fundamental, por ser siempre mi ejemplo de fortaleza y dedicación. Gracias por brindarme tu apoyo incondicional, por tus palabras de aliento en los momentos de duda y por enseñarme el verdadero valor del esfuerzo. Sin tu amor y sacrificio, este logro no habría sido posible.

A mi querida enamorada, quien ha estado a mi lado durante todo este proceso. Gracias por tu paciencia, por creer en mí cuando más lo necesitaba y por tu amor constante. Tus palabras de ánimo y tu presencia han sido una fuente de inspiración y motivación para superar cada obstáculo.

Jesus Crisanto

A la universidad, por brindarme la formación académica y los recursos necesarios para desarrollar mis conocimientos. Gracias por ser un espacio de crecimiento personal y profesional, donde he podido superar retos y forjarme como profesional.

A mi asesor, Mg. Jaime Arturo Bravo Ruiz, por su invaluable guía, paciencia y dedicación a lo largo de este proceso. Su experiencia y consejos fueron esenciales para el éxito de este trabajo, y su apoyo constante me motivó a continuar adelante.

A los docentes que me acompañaron en este camino académico, por su compromiso con la enseñanza, por compartir su saber y por motivarme a dar lo mejor de mí. Sus lecciones no solo dejaron una huella en mi desarrollo profesional, sino también en mi vida personal.

A todos ustedes, mi más profundo agradecimiento.

## Índice de contenidos

DEDICATORIA .....	4
AGRADECIMIENTOS .....	6
ÍNDICE DE TABLAS .....	8
ÍNDICE DE FIGURAS .....	8
RESUMEN.....	10
I. INTRODUCCIÓN .....	12
II. MATERIALES Y MÉTODO .....	15
III. RESULTADOS Y DISCUSIÓN.....	25
2.1. Resultados .....	25
2.1. Discusión.....	31
IV. CONCLUSIONES Y RECOMENDACIONES.....	33
3.1. Conclusiones.....	33
3.2. Recomendaciones.....	34
V. REFERENCIAS.....	35
I. ANEXO .....	<b>¡Error! Marcador no definido.</b>

## Índice de Tablas

TABLA I:.....	15
TABLA II: SELECCIÓN DE DATASET .....	17
TABLA III: DIVISIÓN DE IMÁGENES POR CADA CLASE .....	18
TABLA IV: SELECCIÓN DE ALGORITMOS DE APRENDIZAJE AUTOMÁTICO .....	19
TABLA V: EVALUACIÓN DEL USO DE LA CPU Y EL TIEMPO DE RESPUESTA PARA LOS CLASIFICADORES .....	25
TABLA VI: MÉTRICAS DE EXACTITU, PRECISIÓN. RECALL Y F1-SCORE .....	29

## Índice de Figuras

FIG. 1 DIAGRAMA DEL MÉTODO UTILIZADO. <b>NOTA:</b> ELABORACIÓN PROPIA .....	16
<b>FIG. 3</b> ARQUITECTURA DEL ALGORITMO DENSENET121. <b>NOTA:</b> ELABORACIÓN PROPIA.....	20
<b>FIG. 4</b> ARQUITECTURA DEL ALGORITMO CNN. <b>NOTA:</b> ELABORACIÓN PROPIA. ....	21
<b>FIG. 5</b> ARQUITECTURA DEL ALGORITMO CNN CON CAPAS DE DROPOUT. <b>NOTA:</b> ELABORACIÓN PROPIA.....	23
<b>FIG. 6</b> ARQUITECTURA DEL ALGORITMO SVM CON EXTRACCIÓN DE CARACTERÍSTICAS. <b>NOTA:</b> ELABORACIÓN PROPIA.....	23
<b>FIG. 7</b> MEDIDAS DE CONSUMO DE RECURSOS PARA CUATRO CLASIFICADORES DE APRENDIZAJE AUTOMÁTICO <b>FUENTE:</b> ELABORACIÓN PROPIA. ....	26
<b>FIG. 8</b> MATRIZ DE CONFUSIÓN DEL ALGORITMO DENSENET121. ....	27
<b>FIG. 9</b> MATRIZ DE CONFUSIÓN DEL ALGORITMO CNN .....	27
<b>FIG. 10</b> MATRIZ DE CONFUSIÓN DEL ALGORITMO DROPOUT.....	28
<b>FIG. 11</b> MATRIZ DE CONFUSIÓN DEL ALGORITMO SVM.....	28

**Fig. 12** RESULTADOS DE LAS MÉTRICAS DE DESEMPEÑO DE LOS CUATRO ALGORITMOS DE APRENDIZAJE AUTOMÁTICO ..... 29

## Resumen

La enfermedad del cáncer del cuello uterino requiere de un diagnóstico certero y anticipado por consiguiente que el objetivo de la investigación fue evaluar la efectividad de algoritmos de aprendizaje automático en la detección de cáncer cervical a partir de imágenes de Papanicolaou. Para ello, se implementaron redes neuronales convolucionales (CNN), DenseNet121 con capas de CNN, CNN con dropout y SVM con extracción de características, sin utilizar transferencia de aprendizaje. El dataset utilizado constó de 4049 imágenes, de las cuales el 80% se destinó al entrenamiento y el 20% a la validación. Se llevó a cabo un exhaustivo análisis del consumo de CPU, el uso de RAM y el tiempo de respuesta para cada clasificador de aprendizaje automático. Además, se documentó detalladamente el proceso de implementación de los algoritmos, incluyendo la construcción de una matriz de confusión y el cálculo de métricas de desempeño como precisión, sensibilidad, especificidad y F1-score. Los resultados obtenidos demostraron que CNN combinado con dropout fue altamente efectiva en la detección de cáncer cervical, con altos niveles de precisión (90%), exactitud (90.5%) y puntuación F1 (90.5%). Estos hallazgos respaldan la efectividad de los algoritmos de aprendizaje automático en la detección precisa de cáncer cervical. En conclusión, el estudio evidenció que los algoritmos de aprendizaje automático son una herramienta prometedora para la detección temprana y precisa del cáncer de cáncer cervical, lo que podría tener un impacto significativo en la mejora de los cuidados de salud para las mujeres.

**Palabras Clave:** Aprendizaje profundo, papanicolaou, cáncer cervical, detección.

## **Abstract**

Cervical cancer disease requires an accurate and early diagnosis; therefore, the objective of the research was to evaluate the effectiveness of machine learning algorithms in the detection of cervical cancer from Papanicolaou images. For this purpose, convolutional neural networks (CNN), DenseNet121 with CNN layers, CNN with dropout and SVM with feature extraction, without using transfer learning, were implemented. The dataset used consisted of 4049 images, of which 80% was for training and 20% for validation. A thorough analysis of CPU consumption, RAM usage and response time was carried out for each machine learning classifier. In addition, the implementation process of the algorithms was documented in detail, including the construction of a confusion matrix and the calculation of performance metrics such as accuracy, sensitivity, specificity and F1-score. The results obtained demonstrated that CNN combined with dropout was highly effective in detecting cervical cancer, with high levels of accuracy (90%), precision (90.5%) and F1-score (90.5%). These findings support the effectiveness of machine learning algorithms in the accurate detection of cervical cancer. In conclusion, the study evidenced that machine learning algorithms are a promising tool for early and accurate cervical cancer detection, which could have a significant impact on improving healthcare for women.

**Palabras Clave:** Machine learning, pap smear, cancer cervix, detection.

## I. INTRODUCCIÓN

El cáncer cervical, una enfermedad que afecta desproporcionadamente a mujeres jóvenes en países en desarrollo, se ha transformado en una preocupación global de salud. Las tasas alarmantes, como los 5 casos nuevos por cada 100,000 mujeres canadienses y 36 por cada 100,000 bolivianas [1], subrayan la urgente necesidad de estrategias de detección más efectivas. En el Perú, el cáncer cervical se posiciona en el segundo lugar en la lista de principales causas de fallecimiento entre las mujeres, con un preocupante registro de 4270 nuevos casos identificados en el año 2020 y seis mujeres peruanas perdiendo la vida diariamente debido a esta enfermedad [2], [3]. Tras un análisis profundo de esta situación, se identifica una causa crucial: la falta de información y concienciación sobre la relevancia de la detección temprana. Este déficit de conocimiento se traduce en la alarmante cifra del 65% de pacientes con cáncer cervical que retrasan o suspenden su tratamiento, siendo los extensos períodos de espera para obtener una cita uno de los principales motivos [2].

Por otro lado, [4] existen diversas técnicas para diagnosticar esta enfermedad, siendo la más común y accesible a la población la toma de la muestra de papanicolaou o también llamada cribado cervical, tomada por un obstetra o ginecólogo, y posteriormente analizada de manera tradicional en un microscopio por un patólogo.

Entre tanto [5] su detección temprana y precisa es crucial para obtener mejores resultados del tratamiento y reducir el impacto en la salud pública. En los últimos años, los avances en inteligencia artificial y aprendizaje automático han brindado nuevas posibilidades para mejorar la precisión y eficiencia del diagnóstico de varios tipos de cáncer [6]. En particular, el uso de algoritmos de aprendizaje automático aplicados a imágenes de papanicolaou ha despertado un notable interés en la comunidad científica y médica debido a su potencial para mejorar la detección y clasificación de células cancerosas.

En este contexto, la detección manual, propensa a errores y menos eficiente en grandes volúmenes de muestras [7]–[10], presenta limitaciones que podrían superarse mediante la implementación de algoritmos de aprendizaje automático y procesamiento de imágenes. En ese sentido, el propósito principal de esta investigación es examinar

detalladamente algoritmos de aprendizaje automático para la detección de cáncer cervical usando imágenes de papanicolaou. A partir de ello, surgió la necesidad de plantear la pregunta de investigación ¿Qué algoritmo de aprendizaje automático será el que presenta mejores resultados para la detección del cáncer de cervical utilizando imágenes de papanicolaou? Para lo cual se determinó la siguiente hipótesis, el algoritmo Support Vector Machines (SVM) es el mejor en detectar el cáncer cervical utilizando imágenes de papanicolaou. Para lograrlo, se recopiló y analizó un extenso dataset de imágenes de muestras de Papanicolaou, que incluirá tanto muestras normales como aquellas que presenten anomalías indicativas de la enfermedad. A través de un riguroso análisis de las características morfológicas y cromáticas de las células, se buscó establecer un conjunto de criterios que sirvan como base para la clasificación automatizada y precisa de las muestras, contribuyendo así a una detección temprana y efectiva del cáncer cervical.

Así mismo, el presente informe se justificó en que las tecnologías basadas en aprendizaje automático han demostrado ser una valiosa herramienta en diversos campos, incluyendo la medicina. En el ámbito de la detección de cáncer de cervical a través de imágenes de Papanicolaou, el uso de algoritmos de aprendizaje automático se ha revelado como una estrategia prometedora. Estas técnicas permiten un análisis automatizado y detallado de las muestras, mejorando la eficacia en la identificación de anomalías celulares, un aspecto crucial en la detección temprana y precisa de esta enfermedad. La aplicación de esta tecnología en el análisis de muestras citológicas para la detección de cáncer cervical representa un paso significativo hacia el mejoramiento de la salud femenina y la prevención de esta enfermedad.

En ese sentido, Yoman et al [11] proponen un método que utiliza un algoritmo de extracción de características profundas de las imágenes utilizando redes DarkNet19 o DarkNet53. Las características se clasifican mediante el algoritmo de máquina de vectores de soporte (SVM). Se concluyó que el método propuesto resultó exitoso logrando una alta precisión del 99.47% para el dataset de Mendeley LBC. Por otro lado, Newaz et al. [12] utiliza técnicas de aprendizaje automático siendo los algoritmos utilizados, el clasificador Random

Forest (RF), C4.5, la regresión logística (LR), SVM, la red neuronal convolucional (CNN), y Extreme Learning Machine (ELM). El sistema propuesto sirve de apoyo a la toma de decisiones inteligente para el diagnóstico de cáncer cervical logrando un alto rendimiento con una sensibilidad del 94,25% y una especificidad del 94,69%. Así mismo, Hussain et al. [13] realizaron una investigación en la cual se propone un algoritmo de clasificación el cual combino cuatro arquitecturas de redes neuronales convolucionales profundas (AlexNet, VggNet, ResNet y GoogLeNet) para el análisis de células cancerígenas, cuya conclusión fue que supera a otros algoritmos individuales al demostrar un mejor rendimiento en cuanto a la precisión, recall y tasa de falsos positivos y falsos negativos. También, Ali et al [14] evaluaron diferentes clasificadores y métodos de transformación de características para identificar los mejores algoritmos para cada atributo de clase. Los resultados mostraron que Random Tree funcionó bien para citología. El estudio concluyó que el aprendizaje automático puede mejorar la detección del cáncer cervical en sus primeras etapas ya que tuvo una precisión promedio del 98.65%. Por otra parte, Sabeena et al [15] en la investigación realizada, utilizaron el algoritmo PSPnet Segmentation con un clasificador de pila (stack classifier), en donde se concluyó que este enfoque de segmentación profunda seguido de un enfoque de clasificación en conjunto (ensemble approach) logró una precisión del 99.7% en la clasificación binaria de células cervicales, además una baja tasa de clasificación errónea, lo cual mejora significativamente la clasificación de células cervicales. En esa misma línea, Devi et al [16] nos muestran varios algoritmos de aprendizaje automático, incluyendo Árbol de Decisión, Regresión Logística, Perceptrón Multicapa, Naive Bayes y Random Forest. En cuanto, al desempeño de los algoritmos, se encontró que la Regresión Logística rompe una sensibilidad del 88% al 94% con una precisión del 84% al 89% en la predicción del cáncer de cervical. Agregando a lo anterior, Surendiran et al [17] en su estudio se analizaron varios algoritmos de aprendizaje automático, incluyendo RF, LR, SVM y redes neuronales profundas (Deep Neural Networks). La conclusión fue que el algoritmo de árbol de decisión (DT) superó a los otros enfoques de aprendizaje automático, con un área bajo la curva (AUC) de 0.74 y una diferencia mínima con los otros métodos.

La aplicación de aprendizaje automático en este contexto no solo representa un aporte significativo en el ámbito de la medicina, sino que también abre la puerta a futuras investigaciones y avances en el diagnóstico automatizado de otras enfermedades a través de imágenes médicas, demostrando así su relevancia y trascendencia en el ámbito científico y clínico.

## II. MATERIALES Y MÉTODO

En la tabla 1 se puede visualizar la lista de materiales utilizados en la investigación.

**TABLA I:**  
**LISTA DE MATERIALES**

Item	Nombre	Descripción
1	<b>Dataset Sipakmed</b>	El dataset consta de 4049 imágenes de células aisladas que fueron recortadas manualmente de 966 imágenes de células de clúster de diapositivas de Papanicolaou.
2	<b>Software de edición de texto</b>	Nombre: Google Colab
3	<b>Lenguaje de programación</b>	Nombre: Python
4	<b>Laptops</b>	<ul style="list-style-type: none"> <li>- <b>Laptop 1:</b>  <b>Nombre de equipo:</b> LAPTOP-SGK8PES4  <b>Sistema operativo:</b> Windows 10 Home 64 bits  <b>Modelo del sistema:</b> ASUS TUF Gaming F15 FX506LI_FX506LI  <b>RAM:</b> 8192mb  <b>Procesador:</b> Intel (R) Core i5 10300H</li> <li>- <b>Laptop 2:</b>  <b>Nombre de equipo:</b> DESKTOP-P4TANNO  <b>Sistema operativo:</b> Windows 10 Pro-64-bit (10.0, Build 19045) (19041.vb_release.191206-1406)  <b>Modelo del sistema:</b> ASUS TUF Gaming FA506II_FX506II  <b>RAM:</b> 16384mb  <b>Procesador:</b> AMD Ryzen 7 4800H with Radeon Graphics</li> </ul>
5	<b>Librerías</b>	<ul style="list-style-type: none"> <li>- TensorFlow: Biblioteca de código abierto que facilita la creación y entrenamiento de modelos de aprendizaje automático.</li> <li>- ImageDataGenerator: Módulo de TensorFlow para la generación de datos de imágenes.</li> </ul>

- Conv2D, MaxPooling2D, Flatten, Dense, Dropout y GlobalAveragePooling2D: Capas y modelos para construir redes neuronales
- Sequential y Model: Utilidades de Keras para construir modelos de tipo secuencial y funcional, respectivamente.
- TensorBoard, ModelCheckpoint y EarlyStopping: Callbacks de Keras, permiten visualizar el progreso del entrenamiento, guardar los pesos del modelo durante el entrenamiento y detenerlo prematuramente si no se observa mejora.
- Accuracy\_score, precision\_score, recall\_score, f1\_score, confusion\_matrix y classification\_report: Herramientas de evaluación de modelos desde scikit-learn, estas métricas son fundamentales para evaluar el rendimiento de los modelos de clasificación.
- NumPy: Para operaciones matriciales y manipulación de datos.
- Sys y os: Módulos de sistema operativo, para gestionar archivos y directorios.
- Matplotlib.pyplot y seaborn: Facilitan la representación gráfica de resultados.
- OpenCV (cv2): Herramientas para trabajar con imágenes.
- DenseNet121: Desde tensorflow.keras.applications, para procesamiento de imágenes y aprendizaje profundo.
- Scikit-image y scikit-learn: Para procesamiento de imágenes y extracción de características.
- greycomatrix, local\_binary\_pattern, y wavelet transform (dwt2): Desde pywt
- Joblib: Para la evaluación y persistencia de modelos.
- Google.colab y google.colab.files: Para la carga y descarga de archivos desde Google Colab.

**Nota:** Lista de materiales para la investigación. Elaboración propia



Fig. 1 Diagrama del Método utilizado. **Nota:** Elaboración Propia

Se presenta el método utilizado en la investigación en la fig. 1, la cual consta de 4 etapas, en primer lugar, se procedió a establecer el dataset que cumpla con estándares asociados a los algoritmos y al cáncer cervical, en la segunda etapa se seleccionaron los algoritmos que lograron pasar los criterios establecidos, posteriormente se investigó sobre las arquitecturas de los algoritmos ya seleccionados para después haber sido implementados en el entorno de Google Colab utilizando Python como lenguaje de programación, y por último se analizaron los resultados utilizando distintas métricas y en matrices de confusión.

La selección de dataset se realizó después de una exhaustiva búsqueda en diversos repositorios como GitHub, el Buscador de Google de Datasets y Kaggle, lo que permitió identificar alrededor de 100 conjuntos de datos. Posteriormente, se llevó a cabo la selección del más adecuado para la investigación, considerando criterios de relevancia clínica en virtud de la necesidad de contar con imágenes que proporcionaran información sobre el cáncer cervical.

Además, se tomaron en cuenta otros aspectos cruciales como la cantidad de datos, siendo fundamental contar con al menos 3500 imágenes o más para llevar a cabo el proceso de entrenamiento, pruebas y validaciones de manera efectiva. Por último, se abordó la división de las imágenes, ya que los algoritmos evaluaron distintas características de las células, como el tamaño del núcleo, el tamaño del citoplasma, la relación entre ambos, el área de cada uno, la relación entre el área del núcleo y el citoplasma, el brillo de ambos componentes, así como el diámetro más corto y largo del núcleo, la elongación y redondez del mismo.

A continuación, se presenta una tabla con el listado de los repositorios y los datasets, así como los criterios con los cuales fueron seleccionados. Es importante mencionar que el dataset que obtuvo la puntuación más alta en esta evaluación fue el denominado SipakMed.

**TABLA II: SELECCIÓN DE DATASET**

Repositorio	Nombre dataset	Criterios		
		Relevancia clínica	Cantidad de datos	División de imágenes (c/u contienen una célula)

<b>Kaggle</b>	Cervical Cancer largest dataset (SipakMed)	X	X	x
	Multi Cancer Dataset		X	
	TCGA-KIRP		X	
	cervical cancer (by minhaj 3618)	X		
	Cervical Cancer (Salauddin12)	X		
	Cervical Cancer (Md. Shalauddin)	X		
	Cervical Cancer (Rasheduzzaman Elite)	X	X	
	cervical Cancer (shahin reja)	X		
	Cervical Cancer Mini (Rasheduzzaman Elite)	X	X	
	cleaned-multi-cancer (Ibrahim Ahmad Olaimat)			X
<b>Git hub</b>	CRIC	X	X	
	Herlev	X		x
	SIPaKMeD	x	X	x

**Nota:** Elaboración propia

Luego de haber seleccionado la dataset, se procedió a dividir la cantidad de imágenes de cada una de las clases en otras subcarpetas dentro, una para el entrenamiento y validación (80%) y otra para la validación (20%) lo cual se detalla en la tabla 3.

**TABLA III: DIVISIÓN DE IMÁGENES POR CADA CLASE**

Clase	Tipo_Data	Total Data Set	N°	%	Diagnóstico
Células superficiales - intermedias	train (entrenamiento)	813	650	80%	Células Normales
	val (validación)				
	test (prueba)		163	20%	
Células parabasales	train (entrenamiento)	825	660	80%	Células Normales
	val (validación)				
	test (prueba)		165	20%	
Células coilocitóticas	train (entrenamiento)	793	634	80%	Células Anormales
	val (validación)				
	test (prueba)		159	20%	
Células disquetaróticas	train (entrenamiento)	787	630	80%	Células Anormales
	val (validación)				
	test (prueba)		157	20%	

Células metaplásicas	train (entrenamiento)	831	665	80%	Células Benignas
	val (validación)				
	test (prueba)		166	20%	

**Nota:** Elaboración propia

Para la selección de los algoritmos de aprendizaje automático que se implementarían, se llevó a cabo una revisión sistemática de la literatura explorando las bases de datos Scopus, IEEEExplore y ScienceDirect. De los cuales se extrajeron 203 artículos y, después de un proceso de selección con criterios de inclusión y exclusión, finalmente se trabajó con 59 artículos (ver anexo 1). De estos, se logró extraer información relevante sobre los algoritmos para su análisis y posterior selección, tomando en cuenta que fueran de tipo supervisado, debido a que por naturaleza de la investigación se etiquetaron las imágenes antes de realizar el entrenamiento. Esto permitió que el algoritmo aprendiera con mayor eficiencia y pudiera brindar predicciones precisas al realizar las pruebas y validaciones con otras imágenes. También se consideraron los criterios de precisión, sensibilidad, especificidad y exactitud, ya que se necesitó trabajar con los algoritmos que mostraron mejor desempeño. En la clasificación de esta evaluación, se obtuvo como resultado que los algoritmos CNN, DenseNet121, Dropout y SVM con extracción de características son los que presentan mejores resultados en los cuatro criterios antes mencionados los cuales se pueden apreciar en la tabla N°4.

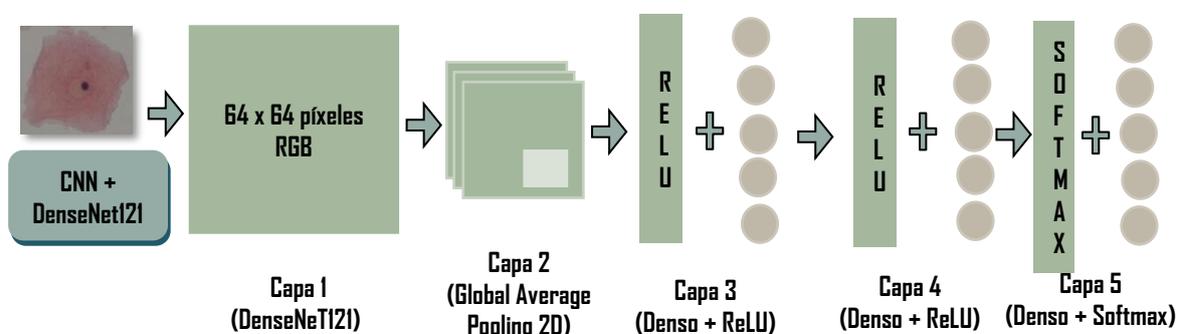
**TABLA IV: SELECCIÓN DE ALGORITMOS DE APRENDIZAJE AUTOMÁTICO**

ITEM	Algoritmo	Criterios				
		Tipo	Precisión	Sensibilidad (Recall)	Especificidad	Exactitud
1	Redes neuronales convolucionales (CNN) [18], [19]	x	99,27%	94,28%	96,01%	-
2	Regresión logística [20]	x	99,07%	95,96%	98,43%	98,57%
3	K-Nearest Neighbors (KNN) [21]	x	92,00%	81,00%	94,00%	-
4	MLP (Perceptrón Multicapa) ResNet-34 y Vgg-19	x	99,64%	-	-	-
5	Random Forest [22]	x	99,16%	99,21%	98,91%	-

6	Support Vector Machines (SVM) [18], [23]	x	99,75%	70,00%	48,80%	58,00%
7	Redes Neuronales [21]	x	98,86%	-	-	-
8	Extreme Learning Machine (ELM) [24]	x	79,15%	73,44%	81,25%	82,65%
9	MLP (Perceptrón Multicapa) ResNet-50 y Vgg-19	x	99,23%	-	-	-
18	CYENET (Cervical Net) [25]	x	99,60%	-	-	-
19	EfficientNet-FPN (EfficientNet Feature Pyramid Network) [26]	x	88,00%	88,00%	92,00%	-
20	MLP (Perceptrón Multicapa)	x	99,48%	-	-	-

**Nota:** Elaboración propia

En el desarrollo de este proyecto, se han seleccionado algoritmos de vanguardia como CNN, DenseNet121, Dropout y SVM para abordar la detección del cáncer cervical. La elección de estos algoritmos se fundamenta en las mejores métricas identificadas en artículos científicos relevantes.



**Fig. 2** Arquitectura del algoritmo DenseNet121. **Nota:** Elaboración propia.

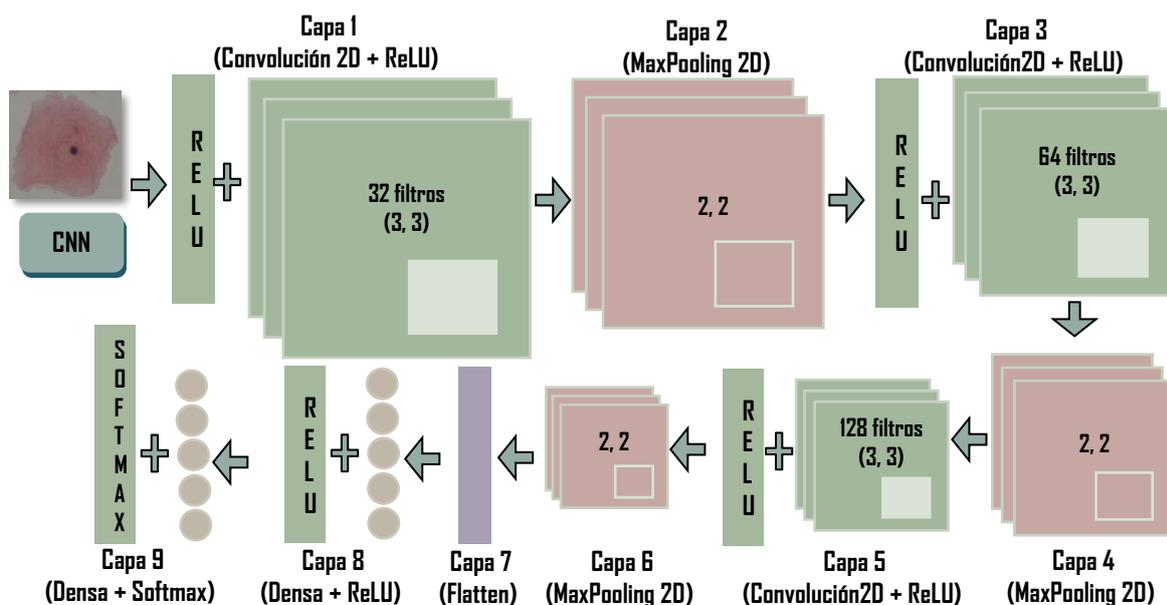
La arquitectura del algoritmo DenseNet121 con capas de CNN (fig. 2), inicia con la carga de la arquitectura DenseNet121 que incluye una red neuronal convolucional profunda usando pesos no preentrenados. La entrada del modelo está diseñada para imágenes 64x64 píxeles con tres canales de color RGB, por lo que la primera capa: `base_model = DenseNet121(weights=None, include_top=False, input_shape=(64, 64, 3))`, incluye bloques densos conectados y capas de normalización, ya que debido a que las imágenes del dataset

tienen distintos tamaños, la normalización hará que todas las tengan dichos parámetros. Los bloques densos fomentan la reutilización de características aprendidas en capas anteriores, permitiendo una representación más rica de las características presentes en las imágenes.

A continuación, se agrega una capa de Global Average Pooling 2D: `GlobalAveragePooling2D()`, que realiza un promedio global de las características en cada mapa de activación de la última capa convolucional. Esta capa tiene la función de reducir la dimensionalidad de las características mientras conserva la información más importante, lo que facilita la generalización del modelo.

Después, se incorporan dos capas densas completamente conectadas: `Dense(150, activation='relu')`, cada una con 150 neuronas y activación ReLU. Estas capas adicionales permiten que la red aprenda patrones más complejos y abstracciones, adaptándose así a las características específicas del dataset en el que se entrenará el modelo.

La capa final del modelo consiste en una capa densa con un número de neuronas igual al número de clases en el dataset: `Dense(len(dataset.class_names), activation='softmax')`. Utiliza la función de activación softmax para asignar probabilidades a cada clase, permitiendo así la clasificación multiclase de las imágenes.



**Fig. 3** Arquitectura del algoritmo CNN. **Nota:** Elaboración propia.

Acto seguido, se introduce un segundo algoritmo CNN (fig. 3), que comienza con una

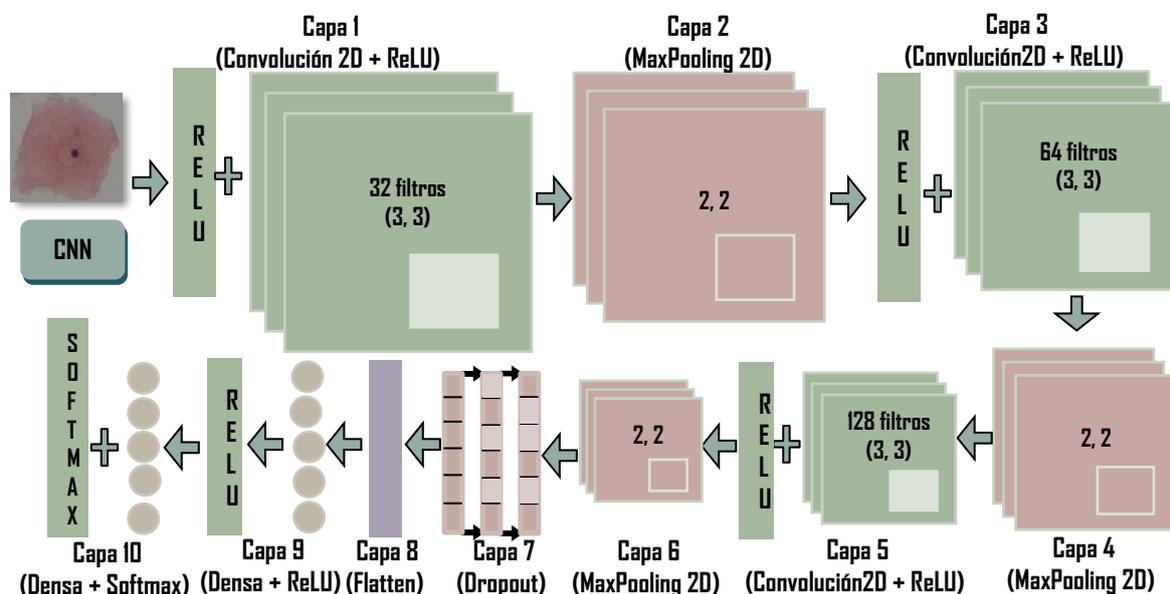
capa de convolución 2D: Conv2D(32, (3,3), activation='relu', input\_shape=(64, 64, 3)), con 32 filtros de tamaño (3,3), utilizando la función de activación ReLU. Esta capa procesa la entrada de imágenes de 64x64 píxeles con tres canales de color RGB, extrayendo características mediante la convolución.

A continuación, se aplica una capa de MaxPooling 2D: MaxPooling2D (2, 2), con un tamaño de ventana de (2,2), reduciendo las dimensiones espaciales de la salida de la capa, ayudando a conservar las características más relevantes y a reducir la carga computacional.

Posteriormente, se repite el patrón con dos capas adicionales de convolución 2D, aumentando progresivamente el número de filtros a 64: Conv2D(64, (3,3), activation='relu'), y luego a 128: Conv2D(128, (3,3), activation='relu'). Después de cada capa de convolución, se aplica una capa de MaxPooling 2D: MaxPooling2D(2, 2), para continuar reduciendo las dimensiones espaciales y aumentar la invariancia a la translación de las características.

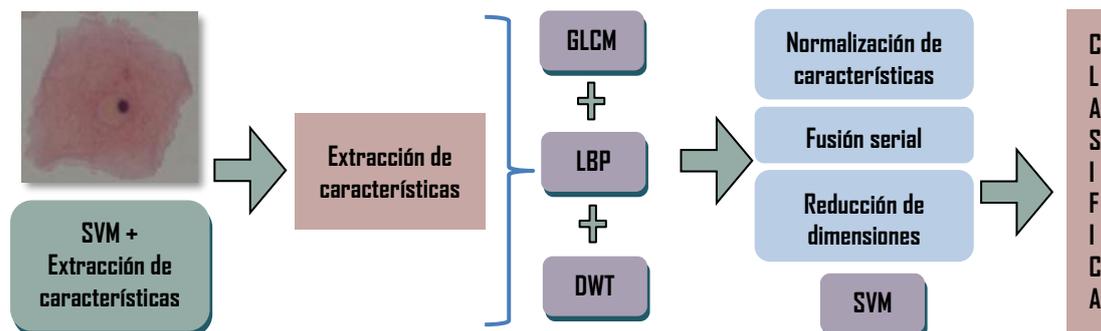
Luego, se utiliza una capa de aplanamiento: Flatten(), para convertir la salida tridimensional de las capas convolucionales en un vector unidimensional. Este vector se alimenta a dos capas densas totalmente conectadas. La primera capa densa: Dense(100, activation='relu') tiene 100 neuronas con la función de activación ReLU, permitiendo la combinación no lineal de las características aprendidas.

Finalmente, la capa de salida consiste en una capa densa con un número de neuronas igual al número de clases en el dataset: Dense(len(dataset.class\_names), activation='softmax'), utilizándose la función de activación softmax.



**Fig. 4** Arquitectura del algoritmo CNN con capas de Dropout. **Nota:** Elaboración propia

La tercera arquitectura, se construyó como una variante del algoritmo CNN original (fig. 4), incorporando capas de Dropout: Dropout(0.5) entre la sexta y séptima capa. Esta capa es un componente crucial para la regularización del modelo, con una proporción del 50%, desactivando aleatoriamente la mitad de las neuronas durante el entrenamiento, mitigando el riesgo de sobreajuste y mejorando la generalización del modelo.



**Fig. 5** Arquitectura del algoritmo SVM con extracción de características. **Nota:** Elaboración propia

Para el cuarto algoritmo (fig. 5), SVM, se incorporó un extractor de características. Esto se debió a que, inicialmente, el rendimiento del SVM por sí solo exhibió métricas notablemente bajas. La introducción de un extractor de características se reveló como una estrategia eficaz para mejorar estas métricas.

Entre las técnicas empleadas como extractores de características, se incluyeron las Matrices de Coocurrencia o GLCM (Gray Level Cooccurrence Matrix), los Patrones Binarios Locales o LBP (Local Binary Pattern), y las Transformadas de Wavelets Discretas o DWT (Wavelets). Estas técnicas, comúnmente utilizadas en el análisis de imágenes médicas en formato BMP, demostraron ser especialmente efectivas, contribuyendo significativamente a la mejora del rendimiento del modelo. Luego se podrá visualizar la implementación de cada uno de los métodos: `extract_textura_glcm` (extractor de características GLCM), `extract_textura_lbp` (LBP) y `extract_textura_dwt` (DWT) utilizando bibliotecas como OpenCV, scikit-image y PyWavelets para su respectiva carga. Luego el método `entrenar_modelo` entrena el modelo SVM utilizando las características extraídas. Finalmente, el método `predecir` toma un dataset de prueba y realiza predicciones utilizando el modelo SVM

previamente entrenado, devolviendo las etiquetas predichas

La implementación de los algoritmos se ha enfocado en la eficiencia de carga, procesamiento y clasificación de imágenes de Papanicolaou, con el propósito de mejorar la detección temprana de posibles casos de cáncer cervical. Para llevar a cabo esta implementación, se optó por el uso del lenguaje de programación Python, junto con TensorFlow (backend) y Keras (API), con el fin de desarrollar y evaluar diversos algoritmos de aprendizaje automático específicamente diseñados para la clasificación de imágenes.

En este proceso, se importaron librerías esenciales para la carga de los algoritmos, la generación de informes, la medición del espacio de almacenamiento utilizado y la creación de matrices de confusión, así como otras librerías necesarias para cargar ciertos parámetros recomendados.

El procedimiento de implementación incluyó el inicio del temporizador para el entrenamiento y validación de cada algoritmo: `start_time_algoritmo = time.time()`, y la detención del temporizador al finalizar: `end_time_algoritmo = time.time()`. Posteriormente, se obtuvieron y exhibieron las métricas, incluyendo el tiempo de ejecución: `execution_time_algoritmo = end_time_algoritmo - start_time_algoritmo`, los detalles del almacenamiento utilizado: `storage_size_algoritmo = sys.getsizeof(algoritmo)`, y la matriz de confusión: `confusion_mat_algoritmo = confusion_matrix(y_true_algoritmo, y_pred_algoritmo)`. Este enfoque integral permitió una evaluación completa y detallada de la efectividad de los algoritmos implementados. Para asegurar la comprensión y mantenimiento del código, se ha llevado a cabo una documentación exhaustiva. Esto no solo facilita la colaboración entre desarrolladores, sino que también contribuye a la reproducibilidad y calidad del proyecto en general.

Una vez implementados los algoritmos, se procede a una fase crucial de análisis de resultados. Se han diseñado pruebas exhaustivas para verificar el buen funcionamiento del código, identificando posibles errores y asegurando la robustez del sistema. La evaluación del desempeño se realiza a través de la construcción de una matriz de confusión, proporcionando una visión detallada de la efectividad del algoritmo en términos de verdaderos

positivos, verdaderos negativos, falsos positivos y falsos negativos.

Para una evaluación cuantitativa más profunda, se calculan métricas de desempeño como **precisión, sensibilidad, especificidad y F1-score**. Estas métricas ofrecen una comprensión completa de la capacidad del modelo para realizar una detección precisa de cáncer cervical. En conjunto, estos pasos conforman un enfoque integral y coherente para el desarrollo y evaluación de los algoritmos implementados en este proyecto de detección de cáncer cervical.

### III. RESULTADOS Y DISCUSIÓN

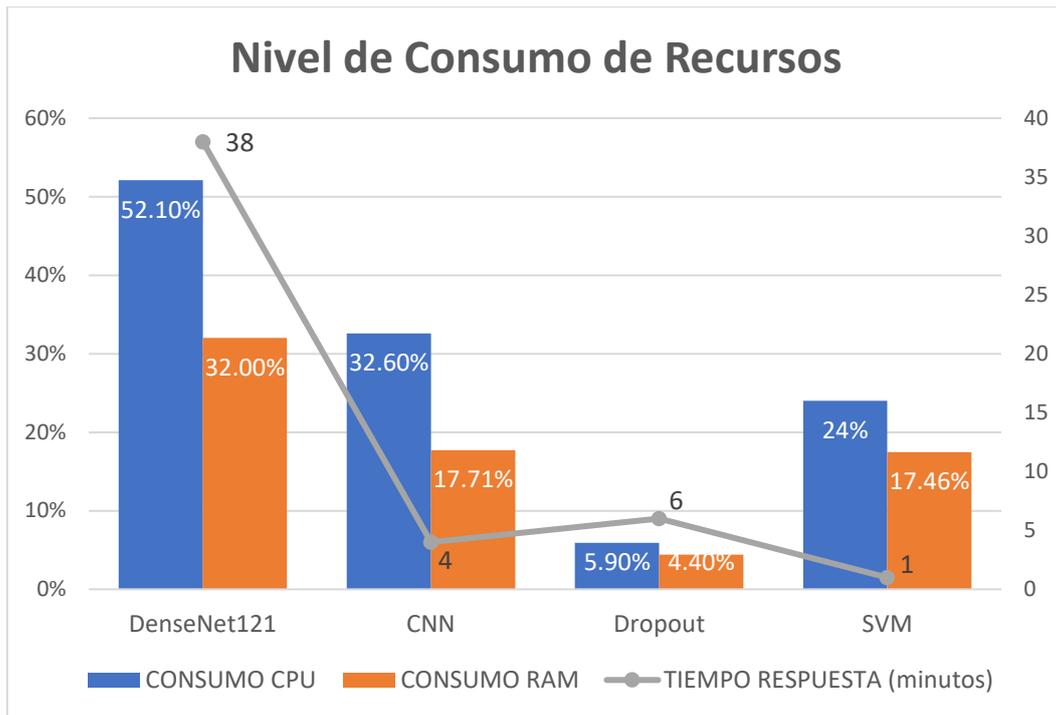
#### 2.1. Resultados

La información detallada sobre el consumo de CPU, el uso de RAM y el tiempo de respuesta para cada clasificador de aprendizaje automático se encuentra en la Tabla 5. Del total de 4049 imágenes en el dataset, se asignó un porcentaje 80% para el entrenamiento y 20% para la validación. Es importante destacar que no se implementó aprendizaje por transferencia, ya que las arquitecturas mencionadas son modelos propios.

**TABLA V: EVALUACIÓN DEL USO DE LA CPU Y EL TIEMPO DE RESPUESTA PARA LOS CLASIFICADORES**

<b>Modelo aplicado</b>	<b>Consumo de CPU</b>	<b>Consumo de RAM</b>	<b>Tiempo de Respuesta</b>
DenseNet121	52.10%	32.00%	38 minutos, 18 segundos, 584 milisegundos
CNN	32.60%	17.71%%	4 minutos, 5 segundos, 856 milisegundos
Dropout	5.90%	4.40%	6 minutos, 5 segundos, 161 milisegundos
SVM	24%	17.46%	1 minuto, 43 segundos, 232 milisegundos

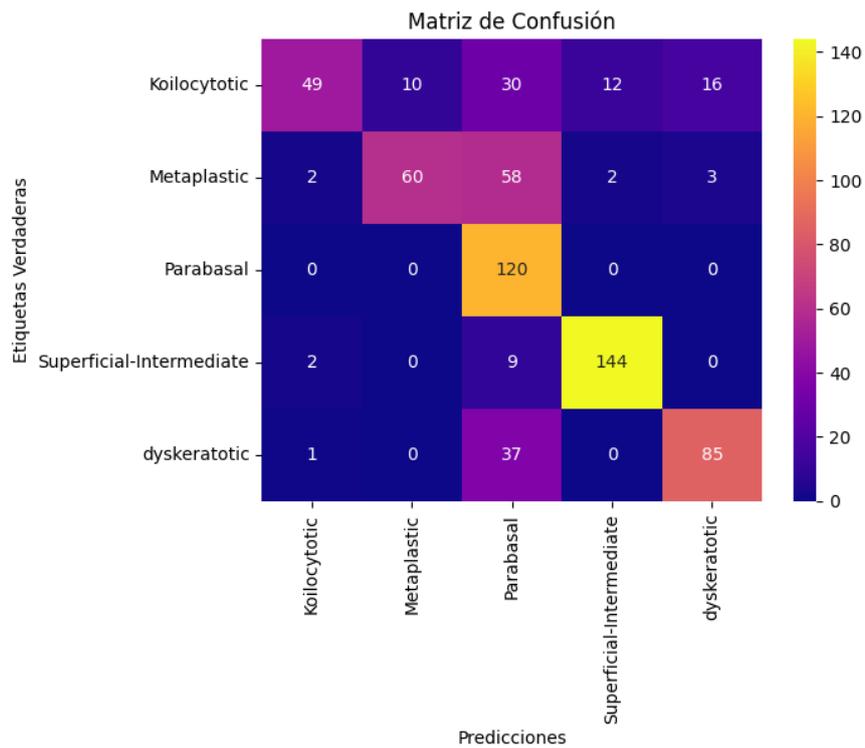
**Nota:** Los datos se analizaron de acuerdo con las características del computador especificado en la tabla 1. **Fuente:** Elaboración propia.



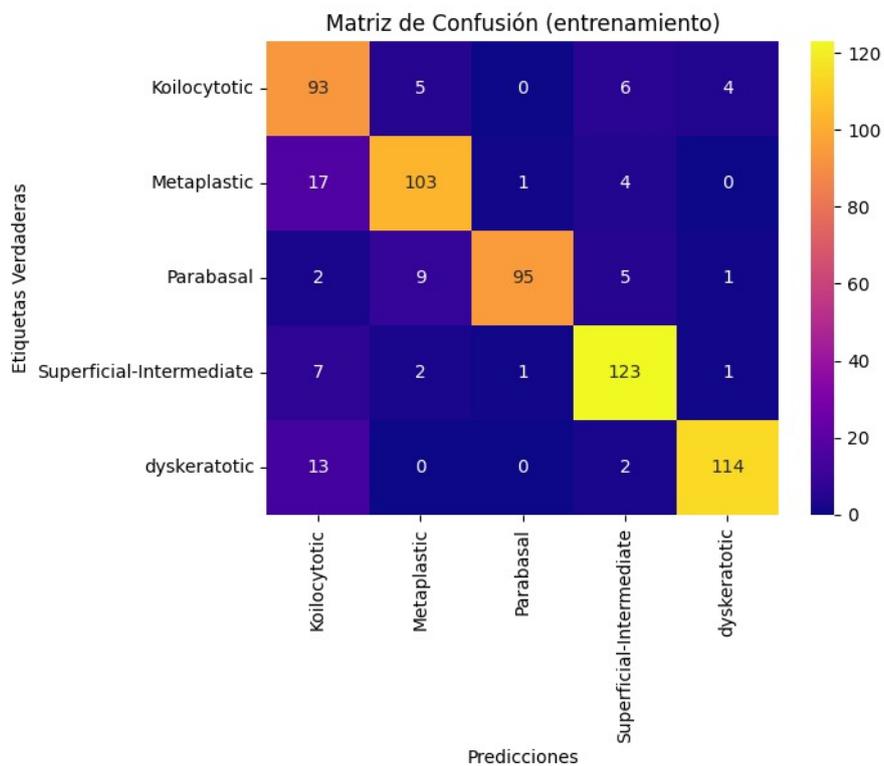
**Fig. 6** Medidas de consumo de recursos para cuatro clasificadores de aprendizaje automático  
**Fuente:** Elaboración propia.

En la fig. 7 se puede observar un gráfico de barras donde se comparan las métricas obtenidas de cada algoritmo, destacando el algoritmo Dropout en exactitud, precisión y F1 - Score y en cuanto a recall, CNN superó al resto.

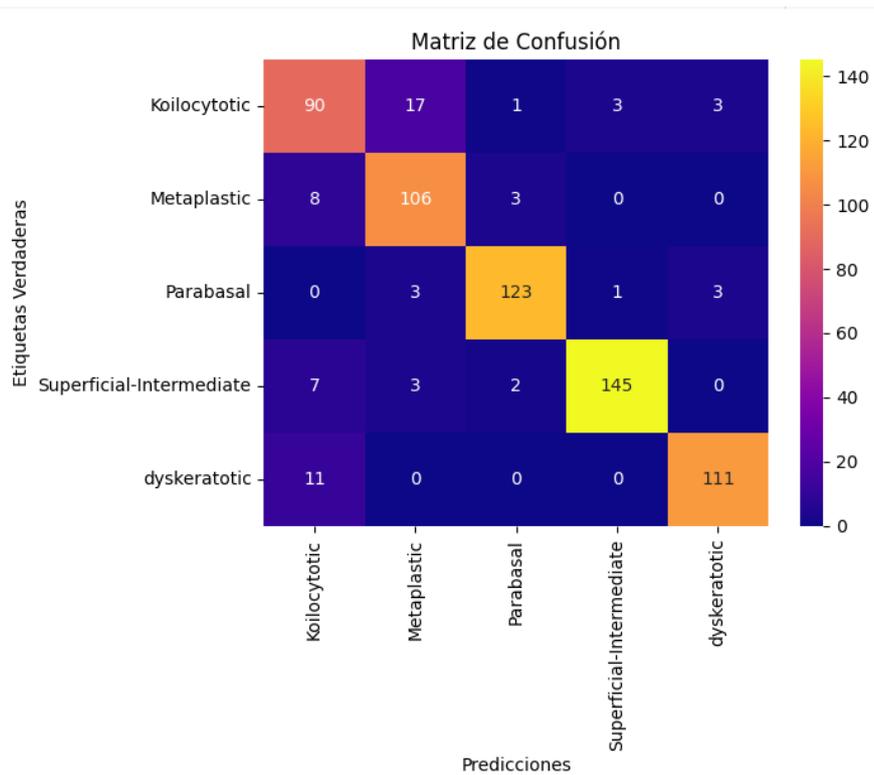
Ahora bien, se presentan las matrices de confusión (fig. 8, fig. 9, fig. 10, fig. 11) para cada uno de los algoritmos detallándose la cantidad de imágenes con sus etiquetas verdaderas y sus respectivas predicciones, considerando que las etiquetas de células Coilocitóticas y Diskeratóticas son diagnosticadas como células con cáncer, y el resto, es decir, las Metaplásicas, Parabasales y Superficiales Intermedias corresponden a células no cancerígenas.



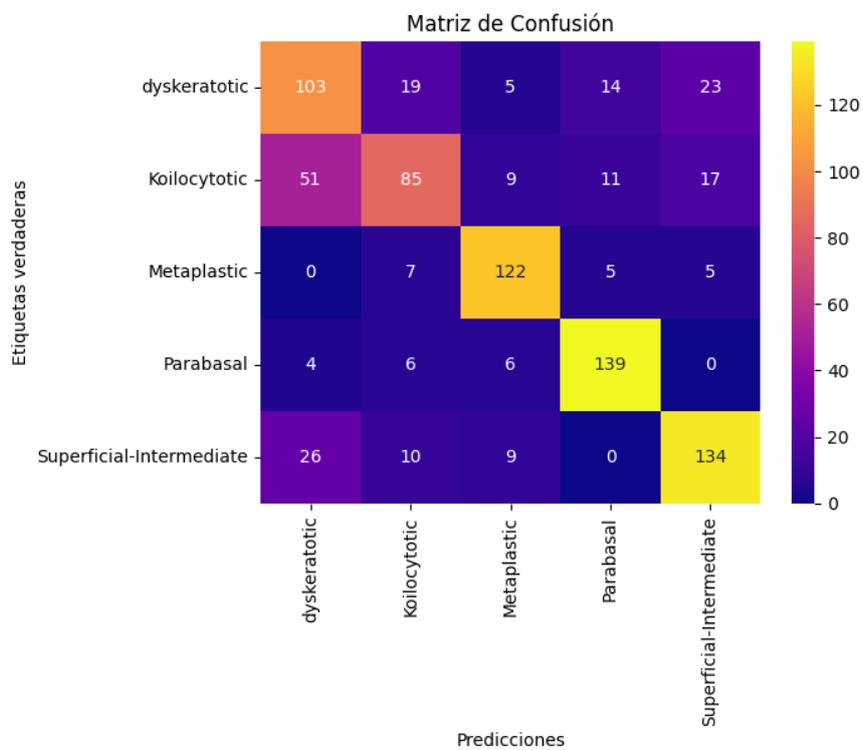
**Fig. 7** Matriz de confusión del algoritmo DenseNet121.



**Fig. 8** Matriz de confusión del algoritmo CNN



**Fig. 9** Matriz de confusión del algoritmo Dropout



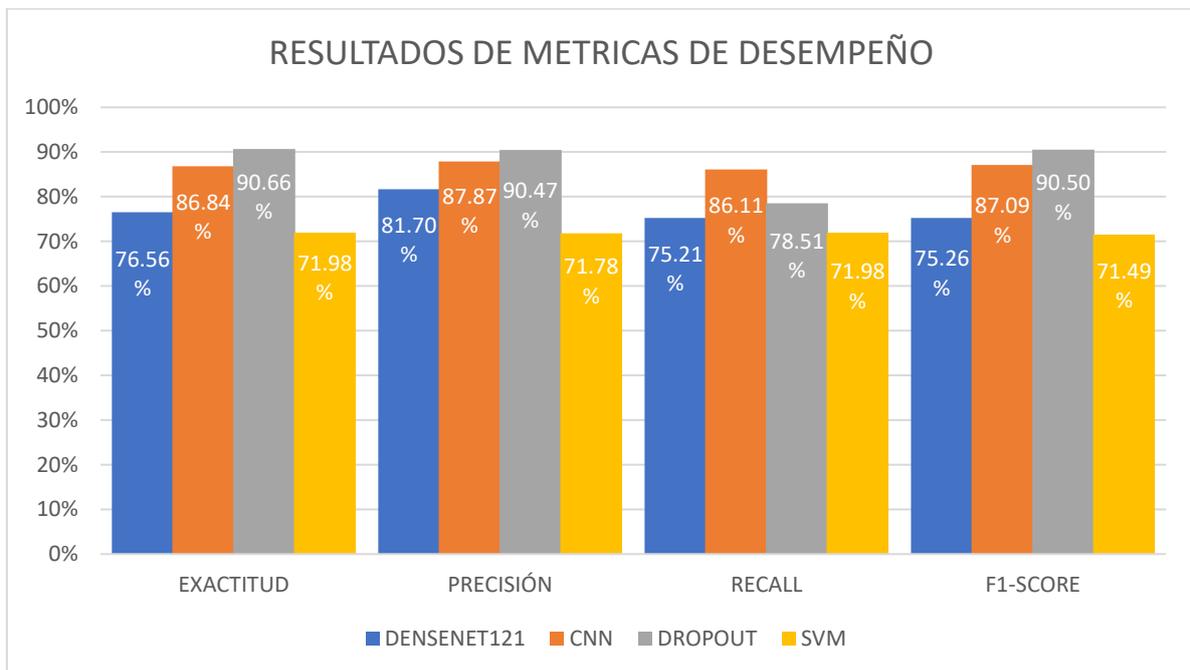
**Fig. 10** Matriz de confusión del algoritmo SVM

Los resultados obtenidos ofrecen una evaluación exhaustiva del desempeño de cada algoritmo en la tarea de detección de cáncer cervical. Estos detalles abarcan tanto el porcentaje de imágenes correctamente clasificadas como aquellas que fueron categorizadas de manera incorrecta. Para una visualización clara y concisa de estos resultados, se presenta la información de manera estructurada en la Tabla 6.

**TABLA VI: MÉTRICAS DE EXACTITU, PRECISIÓN, RECALL Y F1-SCORE**

Modelo	Exactitud	Precisión	Recall	F1-score
DenseNet121	76.56%	81.70%	75.21%	75.26%
CNN	86.84%	87.87%	86.11%	87.09%
Dropout	90.66%	90.47%	78.51%	90.50%
SVM	71.98%	71.78%	71.98%	71.49%

**Nota:** Fuente Propia



**Fig. 11** Resultados de las métricas de desempeño de los cuatro algoritmos de aprendizaje automático

## 1. Resultados DenseNet121

El algoritmo DenseNet121 demostró una tasa de exactitud del 76.56%, indicando que, de las 4049 imágenes evaluadas, logró clasificar correctamente 3100. Además, la precisión del modelo fue del 81.70%, evidenciando que acertó en la clasificación de 3308 imágenes y cometió errores en 741 casos. La especificidad o recall alcanzó el 75.21%, lo que implica que, de las 4049 imágenes, el modelo identificó correctamente 3045. El puntaje F1 del modelo fue del 75.26%, señalando que, en promedio, entre la precisión y el recall, clasificó correctamente 3047 imágenes de las 4049.

## **2. Resultados CNN**

El algoritmo CNN logró una exactitud del 86.84%, clasificando correctamente 3516 de las 4049 imágenes. Asimismo, alcanzó una precisión del 87.87%, indicando que, de las 4049 imágenes, el modelo acertó en la clasificación de 3558 imágenes. La especificidad obtenida fue del 86.11%, denotando que, de las 4049 imágenes, el modelo clasificó correctamente 3487 imágenes. El F1 score del modelo fue del 87.09%, evidenciando que, en promedio entre la precisión y el recall, clasificó correctamente 3526 imágenes de 4049.

## **3. Resultados CNN con capas de Dropout**

El algoritmo CNN combinado con capas de Dropout alcanzó una impresionante exactitud del 90.66%, clasificando correctamente 3671 de las 4049 imágenes. La precisión del modelo fue del 90.47%, indicando que de las 4049 imágenes, el modelo acertó en la clasificación de 3663 imágenes y cometió errores en 386 casos. La especificidad obtenida fue del 78.51%, sugiriendo que, de las 4049 imágenes, el modelo clasificó correctamente 3179 imágenes. El F1 score del modelo fue del 90.50%, evidenciando que, en promedio entre la precisión y el recall, clasificó correctamente 3664 imágenes de 4049.

## **4. Resultados SVM**

El algoritmo SVM aplicado luego de la extracción de características GLCM, LBP y DWT obtuvo una exactitud del 71.98%, logrando clasificar correctamente 2642 de las 4049 imágenes. La precisión fue del 71.78%, indicando que de las 4049 imágenes, el modelo acertó en la clasificación de 2906 imágenes y cometió errores en 1143 casos. La especificidad

obtenida fue del 71.98%, denotando que, de las 4049 imágenes, el modelo clasificó correctamente 2642 imágenes. El F1 score del modelo fue del 71.49%, evidenciando que, en promedio entre la precisión y el recall, clasificó correctamente 2895 imágenes de 4049.

La hipótesis inicial de que el algoritmo Support Vector Machines (SVM) es el mejor en detectar el cáncer cervical utilizando imágenes de Papanicolaou no se sostiene según los resultados obtenidos en la implementación. Después de llevar a cabo el estudio y la evaluación, se observó que el algoritmo que presentó un rendimiento superior fue la red neuronal convolucional (CNN) con una capa de dropout.

Este hallazgo contradice la hipótesis original y destaca la importancia de realizar evaluaciones empíricas y específicas para el dataset y el problema en cuestión. La elección del algoritmo óptimo puede depender de diversos factores, como la complejidad de los datos, la naturaleza del problema y las características particulares de las imágenes de Papanicolaou.

La preferencia por la CNN con capa de dropout puede atribuirse a su capacidad para aprender características complejas y patrones de manera automática, lo que resulta beneficioso en tareas de clasificación de imágenes. Es relevante destacar que la efectividad de los algoritmos puede variar según las condiciones específicas del dataset y los requerimientos del problema, y en este caso, la CNN ha demostrado ser más adecuada para la detección de cáncer cervical en imágenes de Papanicolaou.

## **2.1. Discusión**

Los resultados obtenidos en nuestra investigación sobre la detección de cáncer cervical utilizando algoritmos de aprendizaje automático es fundamental para comprender el impacto y la relevancia de nuestro trabajo, dejando un avance en el diagnóstico clínico. Al comparar los resultados, se observa que nuestra investigación logra una precisión y sensibilidad comparables, lo que valida la efectividad de los algoritmos implementados.

La evaluación de los algoritmos DenseNet121, CNN, CNN combinado con capas de Dropout y SVM combinado con la extracción de características, proporciona información valiosa sobre su rendimiento en la tarea de detección de cáncer cervical.

El algoritmo DenseNet121 logró una tasa de exactitud del 76.56%, con una precisión

del 81.70% y una especificidad del 75.21%. El puntaje F1 fue del 75.26%. Estos resultados sugieren un rendimiento decente en la clasificación de las imágenes del dataset. Sin embargo, es importante señalar que la tasa de exactitud podría estar influenciada por el desbalanceo de clases, y se debe considerar el contexto clínico específico.

El algoritmo CNN exhibió un rendimiento superior con una exactitud del 86.84%, una precisión del 87.87%, y una especificidad o recall del 86.11%. El puntaje F1 fue del 87.09%. Estos resultados indican una mejora significativa en comparación con DenseNet121.

Este rendimiento contrasta con los hallazgos de Sanyal et. al [19], quien en su estudio destacó la eficacia de las arquitecturas CNN en la clasificación de imágenes médicas. La precisión y recall mejorados del modelo CNN sugieren que la capacidad de extracción de características y aprendizaje de representaciones puede haber contribuido al bajo rendimiento del modelo que se obtuvo, ya que este en sus resultados del autor en mención, demuestran una precisión de 95.46% y una especificidad 96,01%.

El modelo CNN combinado con capas de Dropout demostró un rendimiento aún mejor, alcanzando una exactitud del 90.66%, una precisión del 90.47%, y una especificidad o recall del 78.51%. El puntaje F1 fue del 90.50%. La inclusión de capas de Dropout parece haber contribuido a la robustez y generalización del modelo.

Es importante destacar que el desempeño de los modelos puede variar según las características específicas del dataset y la calidad de las imágenes. Además, el tamaño del dataset de entrenamiento y la ausencia de aprendizaje por transferencia pueden afectar la capacidad de generalización de los modelos.

Se puede inferir con lo anteriormente expuesto que, mientras que DenseNet121 proporciona un rendimiento sólido, los modelos CNN, especialmente cuando se combinan con Dropout, superan en términos de exactitud y precisión. Estos resultados sugieren que la elección de la arquitectura y la incorporación de técnicas como Dropout pueden ser críticas para mejorar el rendimiento en la detección de cáncer cervical.

## IV. CONCLUSIONES Y RECOMENDACIONES

### 3.1. Conclusiones

Se logró de manera exitosa determinar un Dataset de imágenes de Papanicolaou. La elección de la dataset SIPaKMeD proveniente de Kaggle cumplió con los criterios establecidos, proporcionando un conjunto representativo de imágenes cervicales para llevar a cabo el análisis de detección de cáncer. Es crucial tener en cuenta que la ausencia de aprendizaje por transferencia y el tamaño del dataset de entrenamiento pueden afectar la capacidad de generalización de los modelos. Futuras investigaciones podrían explorar la aplicabilidad de estos modelos en conjuntos de datos más amplios y diversificados.

Los algoritmos seleccionados, en particular las redes neuronales convolucionales (CNN), CNN con el algoritmo DenseNet121, CNN con dropout y SVM combinado con extracción de características se realizaron de manera efectiva, considerando criterios clave como consumo de memoria, tiempo de respuesta y consumo de CPU. Estos algoritmos fueron elegidos por su idoneidad para la detección de cáncer cervical en imágenes de Papanicolaou.

La implementación de los algoritmos se llevó a cabo de manera satisfactoria utilizando Google Colab. La elección de este entorno demostró ser acertada, ya que proporcionó una plataforma en la nube con recursos computacionales adecuados, herramientas y librerías preinstaladas, lo que simplificó el proceso de implementación y permitió un fácil acceso y colaboración en el desarrollo del código. La utilización de Google Colab facilitó la ejecución eficiente de los algoritmos seleccionados, contribuyendo significativamente al éxito de la implementación y la consecución de los objetivos establecidos en el estudio de detección de cáncer cervical mediante aprendizaje automático en imágenes de Papanicolaou.

Los resultados obtenidos fueron analizados de manera exhaustiva en donde las pruebas y el análisis realizadas confirmaron el buen funcionamiento del código implementado, validando la eficacia y precisión de los algoritmos seleccionados. La inclusión de capas de Dropout en el modelo CNN mejoró aún más su rendimiento, alcanzando una exactitud del 90.66%, una precisión del 90.47%, y una especificidad del 78.51%. Estos resultados respaldan la utilidad de técnicas de regularización como Dropout para mejorar la

generalización del modelo, especialmente en conjuntos de datos limitados.

### **3.2. Recomendaciones**

Considerar la exploración de otras arquitecturas de redes neuronales para evaluar su impacto en la precisión de la detección. La investigación continua de arquitecturas emergentes puede mejorar aún más los resultados.

Realizar una optimización exhaustiva de los hiperparámetros para cada modelo puede proporcionar una comprensión más profunda de cómo ajustar los modelos para obtener el mejor rendimiento posible.

Extender las pruebas y validaciones a conjuntos de datos externos y más amplios puede verificar la generalización y la aplicabilidad de los modelos en entornos más diversos.

Integrar información clínica adicional, como datos demográficos o historiales médicos, en el modelo podría mejorar la capacidad de personalizar las predicciones y hacerlas más relevantes desde una perspectiva clínica.

Considerar el desarrollo de una herramienta de asistencia clínica basada en los modelos implementados. La creación de una interfaz de usuario amigable podría facilitar su integración en entornos clínicos para apoyar a los profesionales de la salud en la detección temprana del cáncer cervical.

## V. REFERENCIAS

- [1] O. R. para las A. de la O. M. de la Salud, "Día Mundial contra el Cáncer 2023: Por unos cuidados más justos." [Online]. Available: <https://www.paho.org/es/campanas/dia-mundial-contra-cancer-2023-por-unos-cuidados-mas-justos>
- [2] D. O. del B. El Peruano, "65% de pacientes con cáncer de mama o cuello uterino retrasa o suspende su tratamiento." [Online]. Available: <https://www.elperuano.pe/noticia/207149-65-de-pacientes-con-cancer-de-mama-o-cuello-uterino-retrasa-o-suspende-su-tratamiento#:~:text=06%2F03%2F2023> Los resultados, una cita médica (42 %25)
- [3] M. de Salud, "¿Qué es el cáncer de cuello uterino?" [Online]. Available: <https://www.gob.pe/21445-que-es-el-cancer-de-cuello-uterino>
- [4] D. Jia, C. Zhang, N. Wu, Z. Guo, and H. Ge, "Multi-layer segmentation framework for cell nuclei using improved GVF Snake model, Watershed, and ellipse fitting," *Biomed Signal Process Control*, vol. 67, p. 102516, May 2021, doi: 10.1016/j.bspc.2021.102516.
- [5] L. Yan *et al.*, "Multi-state colposcopy image fusion for cervical precancerous lesion diagnosis using BF-CNN," *Biomed Signal Process Control*, vol. 68, p. 102700, Jul. 2021, doi: 10.1016/j.bspc.2021.102700.
- [6] M. Akazawa and K. Hashimoto, "Artificial intelligence in gynecologic cancers: Current status and future challenges – A systematic review," *Artificial Intelligence in Medicine*, vol. 120. Elsevier B.V., Oct. 01, 2021. doi: 10.1016/j.artmed.2021.102164.
- [7] R. Cuba, "El cáncer de cuello uterino es la segunda causa de mortalidad en el Perú." [Online]. Available: <https://andina.pe/agencia/noticia-el-cancer-cuello-uterino-es-segunda-causa-mortalidad-el-peru-934175.aspx>
- [8] E. de redactores y equipo de editores médicos de la S. Americana and Cáncer, "Estadísticas importantes sobre el cáncer de cuello uterino." [Online]. Available: <https://www.cancer.org/es/cancer/tipos/cancer-de-cuello-uterino/acerca/estadisticas-clave.html#:~:text=La Sociedad Americana Contra El,del cáncer de cuello uterino>

- [9] E. de redactores y equipo de editores médicos de la A. C. Society, "Pruebas de detección para el cáncer de cuello uterino." [Online]. Available: <https://www.cancer.org/es/cancer/tipos/cancer-de-cuello-uterino/deteccion-diagnostico-clasificacion-por-etapas/pruebas-de-deteccion.html>
- [10] M. sin Fronteras, "Qué es el cáncer de cuello uterino: cuáles son sus síntomas, las causas y su tratamiento." [Online]. Available: <https://www.msf.org.ar/actualidad/que-cancer-cuello-uterino-cuales-son-sus-sintomas-las-causas-y-su-tratamiento>
- [11] O. Yaman and T. Tuncer, "Exemplar pyramid deep feature extraction based cervical cancer image classification model using pap-smear images," *Biomed Signal Process Control*, vol. 73, Mar. 2022, doi: 10.1016/j.bspc.2021.103428.
- [12] A. Newaz, S. Muhtadi, and F. S. Haq, "An intelligent decision support system for the accurate diagnosis of cervical cancer," *Knowl Based Syst*, vol. 245, Jun. 2022, doi: 10.1016/j.knosys.2022.108634.
- [13] E. Hussain, L. B. Mahanta, C. R. Das, and R. K. Talukdar, "A comprehensive study on the multi-class cervical cancer diagnostic prediction on pap smear images using a fusion-based decision from ensemble deep convolutional neural network," *Tissue Cell*, vol. 65, p. 101347, Aug. 2020, doi: 10.1016/j.tice.2020.101347.
- [14] M. M. Ali *et al.*, "Machine learning-based statistical analysis for early stage detection of cervical cancer," *Comput Biol Med*, vol. 139, Dec. 2021, doi: 10.1016/j.compbimed.2021.104985.
- [15] S. K and G. C, "A hybrid model for efficient cervical cell classification," *Biomed Signal Process Control*, vol. 72, Feb. 2022, doi: 10.1016/j.bspc.2021.103288.
- [16] S. Devi, S. R. Gaikwad, and R. Harikrishnan, "Prediction and Detection of Cervical Malignancy Using Machine Learning Models," *Asian Pacific Journal of Cancer Prevention*, vol. 24, no. 4, pp. 1419–1433, 2023, doi: 10.31557/APJCP.2023.24.4.1419.
- [17] R. Surendiran, M. Thangamani, S. Monisha, and P. Rajesh, "Exploring the Cervical Cancer Prediction by Machine Learning and Deep Learning with Artificial Intelligence Approaches," *International Journal of Engineering Trends and Technology*, vol. 70, no.

- 7, pp. 94–107, Jul. 2022, doi: 10.14445/22315381/IJETT-V70I7P211.
- [18] Y. Jiménez Gaona *et al.*, “Radiomics Diagnostic Tool Based on Deep Learning for Colposcopy Image Classification,” *Diagnostics*, vol. 12, no. 7, p. 1694, Jul. 2022, doi: 10.3390/diagnostics12071694.
- [19] P. Sanyal, P. Ganguli, and S. Barui, “Performance characteristics of an artificial intelligence based on convolutional neural network for screening conventional Papanicolaou-stained cervical smears,” *Med J Armed Forces India*, vol. 76, no. 4, pp. 418–424, Oct. 2020, doi: 10.1016/j.mjafi.2019.08.001.
- [20] A. Sarwar, V. Sharma, and R. Gupta, “Hybrid ensemble learning technique for screening of cervical cancer using Papanicolaou smear image analysis,” *Personalized Medicine Universe*, vol. 4, pp. 54–62, Jul. 2015, doi: 10.1016/j.pmu.2014.10.001.
- [21] W. William, A. Ware, A. H. Basaza-Ejiri, and J. Obungoloch, “A review of image analysis and machine learning techniques for automated cervical cancer screening from pap-smear images,” *Comput Methods Programs Biomed*, vol. 164, pp. 15–22, Oct. 2018, doi: 10.1016/j.cmpb.2018.05.034.
- [22] M. M. Ali *et al.*, “Machine learning-based statistical analysis for early stage detection of cervical cancer,” *Comput Biol Med*, vol. 139, Dec. 2021, doi: 10.1016/j.combiomed.2021.104985.
- [23] M. Akazawa and K. Hashimoto, “Artificial intelligence in gynecologic cancers: Current status and future challenges – A systematic review,” *Artif Intell Med*, vol. 120, p. 102164, Oct. 2021, doi: 10.1016/j.artmed.2021.102164.
- [24] S. Haridas and T. Jayamalar, “A Versatile Detection of Cervical Cancer with i-WFCM and Deep Learning based RBM Classification,” *Journal of Machine and Computing*, vol. 3, no. 3, pp. 238–250, Jul. 2023, doi: 10.53759/7669/jmc202303022.
- [25] M. Alsalatie, H. Alquran, W. A. Mustafa, Y. Mohd Yacob, and A. Ali Alayed, “Analysis of Cytology Pap Smear Images Based on Ensemble Deep Learning Approach,” *Diagnostics*, vol. 12, no. 11, p. 2756, Nov. 2022, doi: 10.3390/diagnostics12112756.
- [26] M. J. Del Moral-Argumedo, C. A. Ochoa-Zezzati, R. Posada-Gómez, and A. A. Aguilar-

Lasserre, "A Deep Learning approach for automated Cytoplasm and Nuclei cervical segmentation," *Biomed Signal Process Control*, vol. 81, Mar. 2023, doi: 10.1016/j.bspc.2022.104483.

**ANEXOS:**



**ANEXO 11: TABLA DE OPERACIONALIZACIÓN DE VARIABLES**

<b>Variable de estudio</b>	<b>Definición conceptual</b>	<b>Definición operacional</b>	<b>Indicadores</b>	<b>ITEM</b>	<b>Instrumento</b>	<b>Valores finales</b>	<b>Tipo de variable</b>	<b>Escala de medición</b>
Algoritmos de aprendizaje automático	Permiten aprender a las maquinas a partir de datos, realizando tareas sin necesidad de que estos sean programados de manera específica.	Se realizará una implementación en un entorno de trabajo de cada uno de los algoritmos, luego se someterá a Entrenamiento, pruebas y mediciones.	<ul style="list-style-type: none"> <li>- Consumo de Memoria</li> <li>- Tiempo de respuesta</li> <li>- Consumo de CPU</li> </ul>		Ficha electrónica automatizada de observación	<ul style="list-style-type: none"> <li>- Megabytes (MB) o gigabytes (GB)</li> <li>- Segundos (s)</li> <li>- Porcentaje</li> </ul>	Independiente	El algoritmo de SVM tuvo un rendimiento de memoria en Megabytes, Tiempo de respuesta en segundos y Consumo de CPU en porcentaje
Detección de cáncer de cuello uterino	Área de la medicina que utiliza técnica como el aprendizaje automático de los algoritmos, para un diagnóstico preciso y eficiente.	Se realizará una implementación en un entorno de trabajo en donde se buscará las datas set, luego se realizará la selección de las imágenes de papanicolaou	<ul style="list-style-type: none"> <li>- Precisión</li> <li>- Recall</li> <li>- F-score</li> <li>- AUC</li> </ul>		Ficha electrónica automatizada de observación	Se expresan en porcentajes	Dependiente	Escala Nominal

### ANEXO 12: TABLA DE MATRIZ DE CONSISTENCIA LÓGICA

Problema	Hipótesis	Objetivo General	Objetivo Específico	Tipo de Investigación	Diseño de Investigación
¿Qué algoritmo de aprendizaje automático será el que presenta mejores resultados para la detección del cáncer de cuello uterino utilizando imágenes de papanicolaou?	El algoritmo Support Vector Machines (SVM) es el mejor en detectar el cáncer de cuello uterino utilizando imágenes de papanicolaou.	Analizar los algoritmos de aprendizaje automático para la detección de cáncer de cuello uterino usando imágenes de papanicolaou.	los 1. Determinar una Data set de imágenes de papanicolaou. 2. Seleccionar los algoritmos más adecuados para la detección de cáncer de cuello uterino. 3. Implementar los algoritmos para la detección del cáncer del cuello uterino. 4. Analizar los resultados obtenidos.	Tecnología Aplicada Cuantitativa.	Cuasi-experimental



### ANEXO 13: TABLA DE ALGORITMOS

N°	Paper	Algoritmo	Precisión	Sensibilidad	Especificidad	Exactitud
1	Radiomics Diagnostic Tool Based on Deep Learning for Colposcopy Image Classification	SVM	-	70%	48.8%	58%
2	Radiomics Diagnostic Tool Based on Deep Learning for Colposcopy Image Classification	CNN	73.08%	-	-	-
3	Performance characteristics of an artificial intelligence based on convolutional neural network for screening conventional Papanicolaou-stained cervical smears	CNN	95.46%	94,28%	96,01%	-
4	Hybrid ensemble learning technique for screening of cervical cancer using Papanicolaou smear image análisis	Regresión logística	99.00%	95.96%	98.42%	98.57%
5	Machine learning-based statistical analysis for early stage detection of cervical cancer	Random Forest	99.16%	99.21%	98.91%	-
6	A review of image analysis and machine learning techniques for automated cervical cancer screening from pap-smear images	CNN	98.86%	-	-	-
7	A review of image analysis and machine learning techniques for automated cervical cancer screening from pap-smear images	K-Nearest Neighbors (KNN)	92%	81%	94%	-
8	Analysis of Cytology Pap Smear Images Based on Ensemble Deep Learning Approach	CYENET (Cervical Net)	99.6%	98.1%	-	-
9	Analysis of Cytology Pap Smear Images Based on Ensemble Deep Learning Approach	EfficientNet Feature Pyramid Network	88%	-	88%	-
10	A Deep Learning approach for automated Cytoplasm and Nuclei cervical segmentation	ResNet-34 y Vgg-19	99.71%	-	-	-
11	A Deep Learning approach for automated Cytoplasm and Nuclei cervical segmentation	Extreme Learning Machine (ELM)	79.15%	73.44%	81.25%	82.65%
12	Un modelo mejorado de aprendizaje profundo difuso (IFDL) para gestionar la incertidumbre en la clasificación de imágenes celulares de frotis de Papanicolaou	Aprendizaje profundo difuso mejorado (IFDL)	99,20%	-	-	-
13	DeepCervix: Un marco basado en el aprendizaje profundo para la clasificación de células cervicales	DeepCervix	98,32%	-	-	-

	mediante técnicas híbridas de fusión de características profundas					
<b>14</b>	Detección asistida del cáncer de cuello uterino a través de imágenes de células DIC	SVM	93.5%	-	-	-
<b>15</b>	Marco automático de diagnóstico de imágenes patológicas de portaobjetos completos a través de la selección estocástica unitaria y la fusión de la atención	CNN	80%	-	-	-