



Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Facultad de Ingeniería de Sistemas e Informática

Escuela Profesional de Ingeniería de Software

Sistema para el diagnóstico de cáncer de cuello uterino

utilizando redes neuronales convolucionales con

imágenes de citología en base líquida de Papanicolaou

TESIS

Para optar el Título Profesional de Ingeniero de Software

AUTORES

Andrés Junior CCOPA MAMANI

Elmer Yuniors DIAZ QUIROZ

ASESOR

Dra. Lenis Rossi WONG PORTILLO

Lima, Perú

2022



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.

Referencia bibliográfica

Ccopa, A. & Diaz, E. (2022). *Sistema para el diagnóstico de cáncer de cuello uterino utilizando redes neuronales convolucionales con imágenes de citología en base líquida de Papanicolaou*. [Tesis de pregrado, Universidad Nacional Mayor de San Marcos, Facultad de Ingeniería de Sistemas e Informática, Escuela Profesional de Ingeniería de Software]. Repositorio institucional Cybertesis UNMSM.

Metadatos complementarios

Datos de autor 1	
Nombres y apellidos	Elmer Yuniors Diaz Quiroz
Tipo de documento de identidad	DNI
Número de documento de identidad	74024492
URL de ORCID	https://orcid.org/0000-0001-8239-1022
Datos de autor 2	
Nombres y apellidos	Andrés Junior Ccopa Mamani
Tipo de documento de identidad	DNI
Número de documento de identidad	77069106
URL de ORCID	https://orcid.org/0000-0001-7244-555X
Datos de asesor	
Nombres y apellidos	Lenis Rossi Wong Portillo
Tipo de documento de identidad	DNI
Número de documento de identidad	10438282
URL de ORCID	https://orcid.org/0000-0002-5032-3233
Datos del jurado	
Presidente del jurado	
Nombres y apellidos	Igor Jovino Aguilar Alonso
Tipo de documento	DNI
Número de documento de identidad	32931485
Miembro del jurado 1	
Nombres y apellidos	Fany Yexenia Sobero Rodriguez
Tipo de documento	DNI
Número de documento de identidad	20120467

Miembro del jurado 2	
Nombres y apellidos	Lenis Rossi Wong Portillo
Tipo de documento	DNI
Número de documento de identidad	10438282
Datos de investigación	
Línea de investigación	C.0.3.22. Ingeniería de software
Grupo de investigación	Inteligencia Artificial (INTGARTI)
Agencia de financiamiento	Perú. Universidad Nacional Mayor de San Marcos. Vicerrectorado de Investigación y Posgrado. Proyectos de Investigación con Financiamiento para Grupos de Investigación. PCONFIGI. Código: C21200191. Resolución: 005753-2021-R/UNMSM
Ubicación geográfica de la investigación	Universidad Nacional Mayor de San Marcos Edificio: Facultad de Ingeniería de Sistemas e Informática País: Perú Departamento: Lima Provincia: Lima Distrito: Cercado de Lima Calle: Av. Carlos Germán Amezaga 375 Latitud: -12.0533489 Longitud: -77.085658
Año o rango de años en que se realizó la investigación	2019 - 2022
URL de disciplinas OCDE	Sistemas de automatización, Sistemas de Control https://purl.org/pe-repo/ocde/ford#2.02.03



Universidad Nacional Mayor de San Marcos

Universidad del Perú, DECANA DE AMÉRICA

Facultad de Ingeniería de Sistemas e Informática

Escuela Profesional de Ingeniería de Software

Acta de Sustentación Virtual de Tesis

Siendo las dieciséis (16) horas del día 06 (seis) del mes de octubre de 2022, se reunieron en la sala virtual meet.google.com/sby-piic-zpa, presidido por el Dr. Igor Jovino Aguilar Alonso, la Mg. Fany Yexenia Sobero Rodriguez (Miembro) y la Dra. Lenis Rossi Wong Portillo (Miembro Asesor), para la sustentación virtual de la Tesis intitulada **“SISTEMA PARA EL DIAGNÓSTICO DE CÁNCER DE CUELLO UTERINO UTILIZANDO REDES NEURONALES CONVOLUCIONALES CON IMÁGENES DE CITOLOGÍA EN BASE LÍQUIDA DE PAPANICOLAOU”**, por el Bachiller **Andrés Junior Ccopa Mamani**, para optar el Título Profesional de Ingeniero de Software.

Acto seguido de la exposición de la Tesis, el presidente invitó al bachiller a dar respuesta a las preguntas establecidas por los miembros del jurado.

El bachiller en el curso de sus intervenciones demostró pleno dominio del tema, al responder con acierto y fluidez a las observaciones y preguntas formuladas por los señores miembros del jurado.

Finalmente, habiendo efectuado la calificación correspondiente por los miembros de jurado, el bachiller **Andrés Junior Ccopa Mamani** obtuvo la nota de 18 (Dieciocho).

A continuación, el presidente del jurado, Dr. Igor Jovino Aguilar Alonso, declara al bachiller **Ingeniero de Software**.

Siendo las 16:50 horas, se levantó la sesión.

Dr. Igor Jovino Aguilar Alonso
Presidente

Mg. Fany Yexenia Sobero Rodriguez
Miembro

Dra. Lenis Rossi Wong Portillo
Miembro Asesor



Universidad Nacional Mayor de San Marcos

Universidad del Perú, DECANA DE AMÉRICA

Facultad de Ingeniería de Sistemas e Informática

Escuela Profesional de Ingeniería de Software

Acta de Sustentación Virtual de Tesis

Siendo las dieciséis (16) horas del día 06 (seis) del mes de octubre de 2022, se reunieron en la sala virtual meet.google.com/sby-piic-zpa, presidido por el Dr. Igor Jovino Aguilar Alonso, la Mg. Fany Yexenia Sobero Rodriguez (Miembro) y la Dra. Lenis Rossi Wong Portillo (Miembro Asesor), para la sustentación virtual de la Tesis intitulada **“SISTEMA PARA EL DIAGNÓSTICO DE CÁNCER DE CUELLO UTERINO UTILIZANDO REDES NEURONALES CONVOLUCIONALES CON IMÁGENES DE CITOLOGÍA EN BASE LÍQUIDA DE PAPANICOLAOU”**, por el Bachiller **Elmer Yuniors Diaz Quiroz**, para optar el Título Profesional de Ingeniero de Software.

Acto seguido de la exposición de la Tesis, el presidente invitó al bachiller a dar respuesta a las preguntas establecidas por los miembros del jurado.

El bachiller en el curso de sus intervenciones demostró pleno dominio del tema, al responder con acierto y fluidez a las observaciones y preguntas formuladas por los señores miembros del jurado.

Finalmente, habiendo efectuado la calificación correspondiente por los miembros del jurado, el bachiller **Elmer Yuniors Diaz Quiroz** obtuvo la nota de 18 (dieciocho).

A continuación, el presidente del jurado, Dr. Igor Jovino Aguilar Alonso, declara al bachiller **Ingeniero de Software**.

Siendo las 16:50 horas, se levantó la sesión.

Dr. Igor Jovino Aguilar Alonso
Presidente

Mg. Fany Yexenia Sobero Rodriguez
Miembro

Dra. Lenis Rossi Wong Portillo
Miembro Asesor



Universidad Nacional Mayor de San Marcos
Universidad del Perú. Decana de América
Facultad de Ingeniería de Sistemas e Informática
Escuela Profesional de Ingeniería Software

INFORME DE EVALUACIÓN DE ORIGINALIDAD
N° 013-EPISW-FISI-2022

1. <i>Autoridad Académica que emite el Informe de Originalidad:</i>	<i>Directora de la Escuela Profesional de Ingeniería de Software</i>
2. <i>Apellidos y Nombres de la autoridad académica:</i>	<i>Dra. Nora Bertha La Serna Palomino</i>
3. <i>Operador del programa informático de similitudes:</i>	<i>Dra. Nora Bertha La Serna Palomino</i>
3. <i>Documento evaluado:</i>	<i>Tesis para Pregrado Título: “Sistema para el Diagnóstico de Cáncer de Cuello Uterino Utilizando Redes Neuronales Convolucionales con Imágenes de Citología en Base Líquida de Papanicolaou”</i>
5. <i>Autores del documento:</i>	<i>- Ccopa Mamani Andrés Junior - Diaz Quiroz Elmer Yuniors</i>
6. <i>Fecha de recepción de documento</i>	<i>Recepción: 13/07/2022</i>
7. <i>Fecha de aplicación del programa detector de similitudes:</i>	<i>Revisión: 13/07/2022</i>
8. <i>Software utilizado:</i>	<i>Turnitin</i>
9. <i>Configuración del programa detector de similitudes:</i>	<i>Excluye textos entrecomillados: Sí Excluye biografías: Sí Excluye cadenas menores a 40 palabras: Sí Otro criterio (especificar): No</i>
10. <i>Porcentaje de similitudes según programa detector de similitudes</i>	<i>Seis por ciento (6%)</i>
11. <i>Fuentes originales de las similitudes encontradas</i>	<i>Se adjuntan en 03 (tres) fojas al presente informe</i>
12. <i>Observaciones:</i>	<i>Ninguna</i>
13. <i>Calificación de originalidad</i> <i>i. Documento cumple criterios de originalidad, sin observaciones</i> <i>ii. Documento cumple criterios de originalidad, con observaciones</i> <i>iii. Documento no cumple criterios de originalidad.</i>	<i>Documento cumple criterio de originalidad, sin observación</i>
14. <i>Fecha del Informe:</i>	<i>09/11/2022</i>

Dra. Nora Bertha La Serna Palomino
Directora (e) de la EPISW

Este trabajo está dedicado a nuestras familias.

AGRADECIMIENTOS

A la Dra. Wong Portillo, Lenis Rossi por su orientación, dedicación, consejos y revisiones para que este trabajo cumpla con los objetivos trazados. A los profesores de la UNMSM por sus observaciones teóricas que sirvieron de mucho. A todas aquellas personas que indirectamente ayudaron para culminar este trabajo y que muchas veces constituyen un invaluable apoyo. Y por encima de todo damos gracias a Dios.

RESUMEN

El cáncer del cuello uterino es una alteración celular que se origina en el epitelio del cérvix y que se manifiesta inicialmente a través de lesiones precursoras de lenta y progresiva evolución, las cuales progresan a cáncer in situ. Acorde a la literatura revisada, varios autores coinciden que este tipo de cáncer resulta ser una de las causas más comunes de muertes en mujeres alrededor del mundo, especialmente en países en vías de desarrollo como América Latina. Con la detección del cáncer del cuello uterino en sus primeras etapas, apoyándose de las pruebas de Papanicolau, es posible realizar un diagnóstico y tratamiento adecuado para así evitar, en el peor de los casos, la muerte de la paciente. Acorde con lo anterior, en esta investigación se presenta un sistema inteligente apoyado de un modelo basado en el algoritmo k-means y redes neuronales convolucionales con el fin de realizar el diagnóstico de cáncer de cuello uterino por medio de la clasificación de imágenes de citología de base líquida de pruebas de Papanicolau. La metodología de investigación aplicada en este estudio consta de 4 fases: (i) Planteamiento de la pregunta de investigación; (ii) Diseño del modelo, donde construimos y realizamos el entrenamiento de dos arquitecturas de redes neuronales convolucionales pre-entrenadas, apoyados del 80% de un dataset con un total de 963 imágenes y con 4 clases de imágenes, las cuales son negativo para malignidad intraepitelial, lesión intraepitelial escamosa baja, lesión intraepitelial escamosa alta y carcinoma de células escamosas; (iii) Desarrollo del sistema, donde realizamos la construcción del sistema inteligente e integración del modelo entrenado; y (iv) Validación de la propuesta, donde se trabajó con el 20% restante del dataset,. Nuestros resultados determinan que la mejor clasificación la alcanzó la arquitectura ResNet50 una exactitud del 91%.

Palabras Claves: Cáncer de cuello uterino, Diagnóstico, Clasificación, Redes Neuronales Convolucionales.

ABSTRACT

Cervical cancer is a cellular alteration that originates in the epithelium of the cervix and initially manifests itself through precursor lesions of slow and progressive evolution, which progress to cancer in situ. According to the literature reviewed, several authors agree that this type of cancer is one of the most common causes of death in women around the world, especially in developing countries such as Latin America. With the detection of cervical cancer in its early stages, supported by Papanicolaou tests, it is possible to make an adequate diagnosis and treatment in order to avoid, in the worst case, the death of the patient. Accordingly, this research presents an intelligent system supported by a model based on the k-means algorithm and convolutional neural networks in order to make the diagnosis of cervical cancer through the classification of liquid based-cytology Pap smear images. The research methodology applied in this study consists of 4 phases: (i) Research question posing; (ii) Model design, where we built and performed the training of two pre-trained convolutional neural network architectures, supported by 80% of a dataset with a total of 963 images and with 4 classes of images, which are negative for intraepithelial malignancy, low squamous intraepithelial lesion, high squamous intraepithelial lesion and squamous cell carcinoma; (iii) System development, where we performed the construction of the intelligent system and integration of the trained model and, (iv) Validation of the proposal, where we worked with the remaining 20% of the dataset. Our results show that the best classification was achieved by the ResNet50 architecture with an accuracy of 91%.

Keywords: Cervical cancer, Diagnosis, Classification, Convolutional Neural Networks.

ÍNDICE

1. Capítulo I: Introducción	7
1.1. Formulación del problema	7
1.1.1. Problema general	7
1.1.2. Problemas específicos	7
1.2. Antecedentes del problema	7
1.3. Justificación	9
1.4. Objetivos	11
1.4.1. Objetivo general	11
1.4.2. Objetivos específicos	12
1.5. Organización	12
2. Capítulo II: Marco teórico	13
2.1. Sistema inteligente	13
2.2. Cáncer de cuello uterino	13
2.3. Redes neuronales convolucionales	14
2.3.1. ResNet 50	14
2.3.2. ResNet 101	14
3. Capítulo III: Estado del arte	15
3.1. Metodología de revisión de la literatura	15
3.2. Planificación de la revisión	15
3.3. Desarrollo de la revisión	16
3.4. Resultados de la revisión	17
3.4.1. Tendencias sobre las publicaciones	17
3.4.2. Marco propuesto para la revisión de la literatura	18
3.4.3. Factores de riesgo	20
3.4.4. Medidas de prevención	32
3.4.5. Técnicas de diagnóstico con IA	41
4. Capítulo IV: Metodología de la investigación	66
4.1. Planteamiento de la pregunta de investigación	66
4.2. Diseño del modelo CNN	66
4.3. Desarrollo del sistema inteligente	67
4.4. Validación de la propuesta	67
5. Capítulo V: Sistema de diagnóstico de cáncer de cuello uterino	68
5.1. Justificación del sistema	68

5.2.	Modelo	69
5.2.1.	Dataset.....	69
5.2.2.	Preprocesamiento de las imágenes.....	71
5.2.3.	Entrenamiento del modelo	71
5.3.	Desarrollo del sistema.....	79
5.3.1.	Diseño del sistema	79
5.3.2.	Implementación del modelo.....	81
5.3.3.	Uso del sistema	81
6.	Capítulo VI: Caso de estudio	86
6.1.	Población y muestra	86
6.2.	Validación del sistema	86
6.3.	Métricas.....	88
6.4.	Resultados	89
6.4.1.	Validación del modelo	89
6.4.2.	Validación del sistema	93
6.5.	Análisis de los resultados.....	105
7.	Capítulo VII: Conclusiones y trabajos futuros.....	107
7.1.	Conclusiones	107
7.1.1.	Conclusión general.....	107
7.1.2.	Conclusiones específicas	107
7.2.	Trabajos futuros	109
	Referencias.....	110
	Anexos	116
	Anexo A	117
	Anexo B	130
	Anexo C	139

ÍNDICE DE TABLAS

Tabla 1 Criterios de selección y exclusión.....	16
Tabla 2 Estudios potencialmente elegibles y estudios elegidos.....	18
Tabla 3 Clasificación de los estudios elegidos.....	19
Tabla 4 Taxonomía sobre “Factores de Riesgo” en CCU.....	20
Tabla 5 Datos de los factores de cáncer cervical (Zahras y Rustman, 2018).	30
Tabla 6 Taxonomía sobre “Medidas de prevención” contra el CCU.....	32
Tabla 7 Taxonomía sobre “Métodos de detección” en CCU.	41
Tabla 9 Parámetros de eficiencia de predicción para 3 funciones de núcleo diferentes (Nehra et al., 2018).	46
Tabla 10 Distribución de conjuntos de datos (Hyeon et al., 2017).	48
Tabla 11 Parámetros de eficiencia de predicción para 3 funciones de núcleo diferentes (Hyeon et al., 2017).	48
Tabla 12 Cantidad de imágenes	69
Tabla 13 División de las imágenes para el entrenamiento y validación	70
Tabla 14 Tabla de módulos con sus requerimientos	79
Tabla 15 Número de imágenes por tipo de clasificación	87
Tabla 17 Matriz de confusión del modelo ResNet50.....	89
Tabla 18 Resultados de la precisión del modelo ResNet 50	89
Tabla 19 Resultados de Recall del modelo ResNet 50	90
Tabla 20 Predicciones correctas e incorrectas del modelo ResNet 50.....	90
Tabla 21 Resultados de F1 Score del modelo ResNet 50	90
Tabla 22 Matriz de confusión del modelo ResNet 101.....	91
Tabla 23 Resultados de la precisión del modelo ResNet 101	91
Tabla 24 Resultados del Recall del modelo ResNet 101	92
Tabla 25 Resultados de las predicciones correctas e incorrectas del modelo ResNet 101	92
Tabla 26 Resultados de F1 Score del modelo ResNet 101	93
Tabla 27 Imágenes del INEN.....	93
Tabla 28 Exactitud de los modelos ResNet 50 y ResNet 101.....	105

ÍNDICE DE FIGURAS

Figura 1 Muertes por cánceres en mujeres de todas las edades a nivel mundial (IARC, 2020)..	10
Figura 2 Muertes por cánceres en mujeres de todas las edades en Perú (IARC, 2020).	10
Figura 3 Casos de cáncer de cuello uterino en Perú (MINSA, 2016).....	11
Figura 4 Proceso de revisión sistemático de la literatura.....	17
Figura 5 Estudios elegidos sobre el cáncer de cuello uterino por año 2017 - 2022.....	18
Figura 6 Marco propuesto para la revisión de la literatura.	19
Figura 7 Estadística descriptiva (Stewart et al., 2018).	22
Figura 8 Coeficientes, error estándar, estadística de valor t y probabilidad de las variables seleccionadas en el modelo final (Stewart et al., 2018).....	23
Figura 9 Diagrama de flujo (Fani et al., 2019).	24
Figura 10 Anticonceptivos hormonales (Xu et al., 2018).....	28
Figura 11 Antecedentes de tabaquismo (Xu et al., 2018).....	29
Figura 12 Características demográficas de los participantes del estudio (Okunade et al., 2018).33	
Figura 13 Pacientes con cáncer cervical y sus controles (Okunade et al., 2018).	34
Figura 14 Comparación entre los grupos de intervención y control (Firmino-Machado 2019)..	36
Figura 15 Conocimiento informado de los médicos (Almazrou et al., 2018).	40
Figura 16 Diagrama de flujo de la metodología (Nehra et al., 2018).....	45
Figura 17 Gráfico de eficiencia (Nehra et al., 2018).	46
Figura 18 Procedimiento para clasificar una imagen (Hyeon et al., 2017).	47
Figura 19 Gráfico de rendimiento (Hyeon et al., 2017).....	49
Figura 20 CNN propuesta por LeCun (Rohmatillah et al., 2018).....	50
Figura 21 Arquitectura del marco propuesto (Rohmatillah et al., 2018).....	51
Figura 22 Performance de los clasificadores (Rohmatillah et al., 2018).....	52
Figura 23 Diagrama de bloques de los cinco clasificadores combinados (Win et al., 2019).	53
Figura 24 Diagrama de la metodología propuesta (Bandyopadhyay & Nasipuri, 2020).	54
Figura 25 Diagrama de la metodología propuesta (Win et al., 2020).....	56
Figura 26 Diagrama de bloques de los clasificadores de conjunto (Win et al., 2020).	56
Figura 27 Diagrama de flujo del algoritmo propuesto (Sena et al., 2018).	57
Figura 28 Arquitectura CNN (Manasa Ungrapalli & Myna, 2019).....	61
Figura 29 Modelo Mask R-CNN (Sompawong et al., 2019).....	62

Figura 30	Diagrama de la red propuesta (Xia et al., 2020).....	64
Figura 31	Diagrama de la metodología de la investigación.....	66
Figura 32	Ejemplo de imágenes por tipo	70
Figura 33	Imagen original y segmentada de la prueba de Papanicolaou	71
Figura 34	Arquitectura ResNet50	72
Figura 35	Arquitectura del modelo utilizando ResNet50	73
Figura 36	Exactitud del entrenamiento y validación del modelo utilizando ResNet50.....	75
Figura 37	Pérdida del entrenamiento y validación del modelo utilizando ResNet50.....	76
Figura 38	Arquitectura ResNet101	77
Figura 39	Arquitectura del modelo utilizando ResNet101	77
Figura 40	Exactitud del entrenamiento y validación del modelo utilizando ResNet101.....	78
Figura 41	Pérdida del entrenamiento y validación del modelo utilizando ResNet101	79
Figura 42	Detalle de la arquitectura.....	80
Figura 43	Descripción del sistema.....	81
Figura 44	Login del sistema.....	82
Figura 45	Módulo diagnóstico.....	83
Figura 46	Historial de pacientes	83
Figura 47	Crear Paciente.....	84
Figura 48	Crear Usuario	84
Figura 49	Módulo reportes	85
Figura 50	Proceso de validación.....	87
Figura 51	Primera imagen de lesión leve de la Tabla 27	95
Figura 52	Segunda imagen de lesión leve de la Tabla 27.....	96
Figura 53	Primera imagen de lesión grave de la Tabla 27.....	96
Figura 54	Segunda imagen de lesión grave de la Tabla 27	97
Figura 55	Tercera imagen de lesión grave de la Tabla 27	98
Figura 56	Cuarta imagen de lesión grave de la Tabla 27.....	98
Figura 57	Quinta imagen de lesión grave de la Tabla 27	99
Figura 58	Sexta imagen de lesión grave de la Tabla 27	99
Figura 59	Primera imagen de lesión leve de la Tabla 27.....	100
Figura 60	Segunda imagen de lesión leve de la Tabla 27.....	101

Figura 61 Primera imagen de lesión grave de la Tabla 27.....	101
Figura 62 Segunda imagen de lesión grave de la Tabla 27	102
Figura 63 Tercera imagen de lesión grave de la Tabla 27	103
Figura 64 Cuarta imagen de lesión grave de la Tabla 27.....	103
Figura 65 Quinta imagen de lesión grave de la Tabla 27	104
Figura 66 Sexta imagen de lesión grave de la Tabla 27	104

Capítulo I: Introducción

1.1. Formulación del problema

1.1.1. Problema general

¿Es posible realizar un sistema inteligente que sirva de apoyo para el diagnóstico de cáncer de cuello uterino usando redes neuronales convolucionales, que ayude en la detección temprana del cáncer de cuello uterino?

1.1.2. Problemas específicos

PE1: ¿Es posible revisar y analizar diversos trabajos de investigación que están relacionados a los factores de riesgo, medidas de prevención y técnicas de diagnóstico con IA de cáncer de cuello uterino?

PE2: ¿Es posible diseñar un algoritmo basado de redes neuronales convolucionales para el diagnóstico de cáncer de cuello uterino?

PE3: ¿Es posible realizar un sistema inteligente que sirva de apoyo para el diagnóstico de cáncer de cuello uterino?

PE4: ¿Es posible definir un caso de estudio para corroborar la validez del sistema para el diagnóstico de cáncer de cuello uterino?

1.2. Antecedentes del problema

La primera referencia médica con respecto al cáncer de cuello uterino (CCU) data en el año 450 a.C. con Hipócrates, donde en esa época la "fumigación" local era el único calmante para esta enfermedad incurable. A pesar de los avances en el diagnóstico y el tratamiento en los siguientes 2000 años, el cáncer de cuello uterino sigue siendo una de las principales causas de muerte en las mujeres. Si bien la incidencia y la mortalidad de dicha enfermedad han disminuido mucho en las

naciones industrializadas, la prevalencia y la mortalidad siguen siendo epidémicas en los países en vías de desarrollo. Se tiene como dato que 350000 mujeres mueren anualmente a causa del cáncer de cuello uterino en todo el mundo. Debido a las infecciones por el virus del papiloma humano (VPH), investigadores informaron que se tengan nuevos aumentos en casos y muertes tanto en los países industrializados como en los países en vías de desarrollo (Orr, 1998).

Se tiene como dato que en el año 2000 se estimó que se tendrían 470606 casos nuevos y 233372 muertes por cáncer de cuello uterino anualmente entre mujeres de todo el mundo. Asimismo, más del 80% de esta carga la soportarían los países menos desarrollados donde el cáncer de cuello uterino es la principal neoplasia maligna entre las mujeres. Adicionalmente se indica que, para la Región de las Américas, se calcularon 92136 casos y 37640 muertes por cáncer de cuello uterino, en donde América Latina y el Caribe representan 83.9% y 81.2%, respectivamente, del total estimado de casos y muertes por cáncer de cuello uterino (Lewis, 2004).

En el 2012 se diagnosticaron en Estados Unidos 12200 nuevos casos de cáncer de cuello uterino y que 4200 personas murieron a causa de la enfermedad. Las tasas de cáncer de cuello uterino están disminuyendo entre las mujeres de Estados Unidos, pero la incidencia sigue siendo elevada entre las mujeres hispanas/latinas, negras y asiáticas. Expuesto lo anterior, el cáncer de cuello uterino es un importante problema de salud mundial para las mujeres. En 2008, la incidencia mundial anual del cáncer de cuello uterino fue de 529800, y la tasa de mortalidad anual fue de 275100. Fue el tercer cáncer más frecuente en las mujeres de todo el mundo y el 85% de los casos se producen en los países en vías de desarrollo, donde el cáncer cervical es la segunda causa más frecuente de muerte en las mujeres (Koh et al., 2013).

En la actualidad, el cáncer de cuello uterino es considerada la cuarta neoplasia maligna femenina más común a nivel global y representa un importante desafío de salud mundial. Aproximadamente

el 90% de las 270000 muertes por cáncer de cuello uterino en 2015 se dieron en países que se encuentran en vías de desarrollo donde la mortalidad es 18 veces mayor que la de los países desarrollados (Cohen et al., 2019).

1.3. Justificación

Acorde con (Bray et al., 2018), el cáncer de cuello uterino es el cuarto tipo de cáncer más frecuente en la mujer a nivel mundial. Durante el 2018, se calculó que hubo 570 000 nuevos casos, que representaron el 7.5% de la mortalidad femenina por cáncer. El mayor número de defunciones por cáncer de cuello uterino se presentan en los países menos desarrollados como América Latina, donde aproximadamente de 311 000 defunciones, más del 85% se da en estos países. La prevención del cáncer de cuello uterino comienza en programas de vacunación contra el VPH en niñas y campañas de detección periódica en mujeres; estos exámenes permiten que se detecte, en fases tempranas, las lesiones precancerosas y puedan ser tratadas fácilmente, antes que se llegue a desarrollar el cáncer de cuello uterino. Estas medidas de prevención se dan, en mayor medida en los países desarrollados, por el contrario, en los países en desarrollo, el acceso a estas medidas es limitado y, por ende, estas lesiones no se detectan hasta que están en fases más avanzadas, cuando se presentan los síntomas del CCU, es por esto que la tasa de mortalidad por CCU es alta.

Según (IARC, 2020), el número estimado de muertes por cáncer de cuello uterino a nivel mundial en el 2020 fueron de 341831, representando el 7.7% del total de muertes. En la Figura 1 se puede apreciar las muertes por cánceres en mujeres de todas las edades en el 2020 a nivel mundial.




Figura 1 Muertes por cánceres en mujeres de todas las edades a nivel mundial (IARC, 2020).

Según (IARC, 2020), en el Perú la tasa de mortalidad por cáncer de cuello uterino en el 2020 en mujeres representó el 12.3%. En la Figura 2 se puede apreciar las muertes por cánceres en mujeres de todas las edades en el 2020 en Perú.




Figura 2 Muertes por cánceres en mujeres de todas las edades en Perú (IARC, 2020).

En el Perú, el cáncer de cuello uterino es la tercera causa de mortalidad de cáncer en mujeres, específicamente, el CCU representa el 24.1% de cáncer en mujeres y, en la población general, el 14.9% de todos los cánceres (MINSA, 2016). En la Figura 3 se denota que para el período 2006-2011, en el Perú la vigilancia epidemiológica de cáncer notificó un total de 14115 casos de cáncer de cérvix a nivel nacional lo que representó el 14.6% de los cánceres notificados. El cáncer de cérvix fue el más frecuente de los cánceres notificados, presentándose con mayor frecuencia en mujeres entre los 40 y 59 años de edad (52.6%).




Figura 3 Casos de cáncer de cuello uterino en Perú (MINSA, 2016).

1.4. Objetivos

1.4.1. Objetivo general

El objetivo de la presente tesis es diseñar un sistema inteligente que sirva de apoyo para el diagnóstico de cáncer de cuello uterino utilizando redes neuronales convolucionales con la finalidad de que ayude a detectar el cáncer de cuello uterino en etapa temprana.

1.4.2. Objetivos específicos

OE1: Analizar diversos trabajos de investigación que están relacionados a los factores de riesgo, medidas de prevención y técnicas de diagnóstico con IA de cáncer de cuello uterino.

OE2: Diseñar el algoritmo basado en redes neuronales convolucionales para el diagnóstico de cáncer de cuello uterino.

OE3: Diseñar el sistema inteligente que sirva de apoyo para el diagnóstico de cáncer de cuello uterino.

OE4: Definir un caso de estudio para corroborar la validez del sistema para el diagnóstico de cáncer de cuello uterino.

1.5. Organización

El presente trabajo consta de 7 capítulos. El primer capítulo trata sobre el problema, en el cual se presenta el planteamiento, formulación, justificación, objetivos del problema en estudio. El segundo capítulo, presenta el marco teórico relacionada a la investigación. El tercer capítulo, trata sobre el estado del arte, que expone antecedentes de la investigación. En el cuarto capítulo, se explica la metodología de la investigación que se ha aplicado en el presente trabajo. El quinto capítulo, se detalla la construcción del modelo y el desarrollo del sistema inteligente. En el sexto capítulo, presentamos el caso de estudio. Finalmente, en el séptimo capítulo, se dan las conclusiones y trabajos futuros.

Capítulo II: Marco teórico

En el presente capítulo, se presenta el marco conceptual acorde a nuestro trabajo de investigación. En estos puntos se expondrán las definiciones de (i) Sistema de inteligente, (ii) Cáncer de cuello uterino y (iii) Redes neuronales convolucionales.

2.1. Sistema inteligente

Cuando se menciona lo referente a sistemas inteligentes, se deben de considerar dos aspectos importantes para su construcción: (i) la selección y utilización de distintos métodos de inteligencia artificial como por ejemplo redes neuronales convolucionales, aprendizaje con refuerzo profundo, entre otros; y (ii) la adquisición de conocimientos que utiliza dicho sistema en la realización de tareas deseadas, que podrían ser manuales o automáticas, como por ejemplo extracción de características, división de data, entre otros (Molina, 2022).

2.2. Cáncer de cuello uterino

El cáncer del cuello uterino (CCU) es una alteración celular que se origina en el epitelio del cérvix y se manifiesta inicialmente a través de lesiones precursoras de lenta y progresiva evolución, las cuales progresan a cáncer in situ (confinado a la superficie epitelial) o un cáncer invasor en donde las células con transformación maligna traspasan la membrana basal (MINSA, 2016).

La infección persistente por el virus del papiloma humano (VPH) es el factor más importante en el desarrollo del cáncer de cuello uterino. La incidencia del cáncer cervical parece estar relacionada con la prevalencia del VPH en la población. En los países con una alta incidencia de cáncer de cuello uterino, la prevalencia del VPH crónico es aproximadamente del 10% al 20%, mientras que la prevalencia en los países de baja incidencia es del 5% al 10% (Koh et al., 2013).

2.3. Redes neuronales convolucionales

Las redes neuronales convolucionales son un caso de algoritmos de Machine Learning, que su comportamiento para ejemplos de visualización se les puede asemejar a las neuronas humanas, por la capacidad de obtener resultados, a través de múltiples capas de procesamiento y niveles de abstracción para aprender representaciones de datos y obtener una salida esperada; para el aprendizaje esperado que es el caso que tratamos en este trabajo (Torres, n.d.).

2.3.1. ResNet 50

Es una red neuronal convolucional residual con 50 capas de profundidad, que puede cargar una versión preentrenada con más de un millón de imágenes de la base de datos de ImageNet, esta red puede clasificar imágenes en 1000 categorías, así como también se puede modificar para que realice la clasificación en las categorías que se desea (MathWorks, n.d.-b).

2.3.2. ResNet 101

Es una red neuronal convolucional residual con 101 capas de profundidad, que puede cargar una versión preentrenada con más de un millón de imágenes de la base de datos de ImageNet, esta red puede clasificar imágenes en 1000 categorías, así como también se puede modificar para que realice la clasificación en las categorías que se desea (MathWorks, n.d.-a).

Capítulo III: Estado del arte

En el presente capítulo, se presenta la revisión de la literatura aplicando una metodología de revisión de la literatura, la cual consta de tres fases: planificación de la revisión, desarrollo de la revisión y resultados de la revisión. Además, se muestra la taxonomía aplicada para analizar los resultados obtenidos.

3.1. Metodología de revisión de la literatura

Se desarrolla una metodología para realizar la revisión de la literatura, la cual consiste en realizar una planificación de la revisión, planteando preguntas de investigación, para luego proceder a desarrollar la revisión de los artículos y mostrar los resultados de los análisis de los artículos que se ha seleccionado.

Para la revisión de la literatura, se usó la metodología planteada por (Wong et al., 2017), en el cual se determinan 3 fases: (i) Planificación de la revisión, donde se debe elaborar las preguntas de investigación y definir el protocolo de revisión; (ii) Desarrollo de la revisión, en la que se seleccionan los estudios primarios, según los criterios de selección y exclusión; y (iii) Los resultados de la revisión, en la que se muestra el análisis y estadísticas de los estudios que fueron seleccionados antes, y se presenta el detalle del análisis.

3.2. Planificación de la revisión

Las siguientes preguntas de investigación han sido propuestas para lograr el propósito de la investigación: P1: ¿Cuáles son los factores de riesgo que provocan el cáncer de cuello uterino? P2: ¿Qué medidas de prevención existen para el cáncer de cuello uterino? P3: ¿Cuáles son las técnicas para detectar el cáncer de cuello uterino?

Las bases de datos que se utilizaron, principalmente, para definir el protocolo de búsqueda son las siguientes: SCIENCE DIRECT, IEEE Xplore Digital Library y Google Académico. La investigación cubre el periodo de enero de 2017 a setiembre de 2022.

Se utilizó la siguiente secuencia de búsqueda TITLE-ABS-KEY (“cervical cancer”) o TITLE-ABS-KEY (“cervical uterine cancer”) o TITLE-ABS-KEY (“cervical intraepithelial neoplasia”), que se han aplicado en el título, resumen y palabras clave. Después de eso, se aplicaron los criterios de selección y exclusión que se muestran en la Tabla 1.

Tabla 1 Criterios de selección y exclusión

Criterio de Selección	Criterio de Exclusión
Estudios relacionados con el cáncer de cuello uterino	Fuentes que son diferentes de Journals y Proceeding
Fuentes que describan factores de riesgo para el cáncer de cuello uterino	El idioma de estudio es diferente al inglés, español
Diferentes propuestas de IA de diagnóstico de cáncer de cuello uterino	Diagnóstico de cáncer diferente al cáncer de cuello uterino
	Radioterapia, quimioterapia y/u otros tratamientos, terapias

3.3. Desarrollo de la revisión

Los principales estudios identificados en el proceso de búsqueda fueron sometidos a un proceso de selección de acuerdo con los criterios establecidos en la Tabla 1. Para ello, fue necesario hacer una revisión previa, con el fin de determinar su relevancia; y finalmente, la mayoría de estos estudios fueron descartados porque estaban en otras áreas de medicina o ingeniería. El proceso desarrollado se encuentra en la Figura 4.




Figura 4 Proceso de revisión sistemático de la literatura

3.4. Resultados de la revisión

A continuación, se presenta los resultados de la investigación.

3.4.1. Tendencias sobre las publicaciones

El resultado del proceso de revisión proporcionó 36 010 estudios, de los cuales se seleccionaron 25, de acuerdo con los criterios de selección y exclusión. Estos estudios elegidos sobre propuestas fueron analizados para responder las preguntas de investigación. En la Tabla 2, es posible ver la cantidad de investigaciones seleccionadas por cada tipo de fuente.

Tabla 2 Estudios potencialmente elegibles y estudios elegidos

Fuente	Estudios potencialmente elegibles	Estudios elegidos
Google Académico	25012	4
ScienceDirect	6668	11
IEEE	4330	10
Total	36010	25

Además, en la Figura 5, se presenta el número de estudios relacionados con el cáncer de cuello uterino, entre los años 2017 - 2022. El total corresponde a diferentes aspectos sobre los factores de riesgo, medidas de prevención y técnicas de diagnóstico con IA de cáncer de cuello uterino.

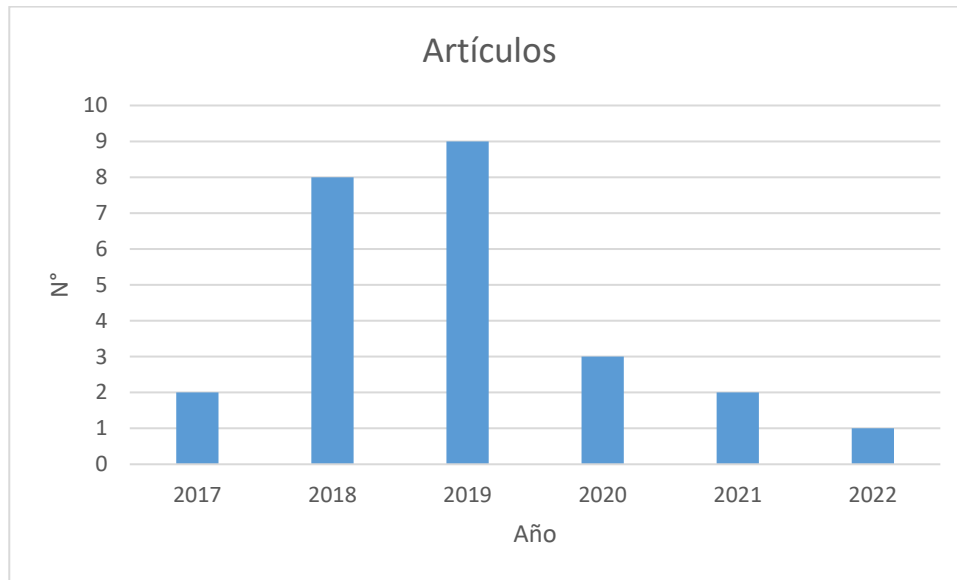


Figura 5 Estudios elegidos sobre el cáncer de cuello uterino por año 2017 - 2022

3.4.2. Marco propuesto para la revisión de la literatura

En esta sección, se presenta la revisión de la literatura de acuerdo con el Marco General propuesto, que se muestra en la Figura 6. Este marco consta de 3 categorías: “Factores de riesgo”, “Medidas de prevención” y “Técnicas de diagnóstico con IA”. Cada una de estas se relacionan a las preguntas de investigación planteadas anteriormente.




Figura 6 Marco propuesto para la revisión de la literatura

La clasificación “Factores de riesgo” permitirá saber, hasta ahora, cuáles son los factores que influyen en el cáncer de cuello uterino. Las “Medidas de prevención” nos facilitará el hecho de conocer precauciones que se toman para evitar el desarrollo del cáncer de cuello uterino. Finalmente, las “Técnicas de diagnóstico” nos posibilitará advertir cuáles son los diferentes procedimientos que son consideradas en diferentes estudios para el diagnóstico del cáncer de cuello uterino.

En la Tabla 3, se muestra las diferentes investigaciones encontradas en la revisión de la literatura, de acuerdo con la clasificación del marco propuesto.

Tabla 3 Clasificación de los estudios elegidos

Clasificación	Estudios	Total
Factores de riesgo	(Stewart et al., 2018), (P. Sharma & Pattanshetty, 2017), (Xu et al., 2018), (Fani et al., 2019), (Zahras & Rustam, 2018)	5
Medidas de prevención	(Almazrou et al., 2019), (Firmino-Machado et al., 2019), (Smith et al., 2018), (Okunade et al., 2018), (Shrivastav et al., 2021)	5
Técnicas de detección con IA	(Kuko & Pourhomayoun, 2019), (Bhuvaneshwari & Poornima, 2019), (Shalini et al., 2018), (Hyeon et al., 2017), (Rohmatillah et al., 2018), (Win et al., 2019), (Bandyopadhyay & Nasipuri, 2020), (D. Sharma et al., 2018), (Ghoneim et al., 2019), (Manasa Ungrapalli & Myna, 2019),	15

3.4.3. Factores de riesgo

Esta clasificación mostrará cuáles son los factores de riesgo que han considerado las diferentes propuestas en el cáncer de cuello uterino y también está relacionada con la primera pregunta de investigación (P1). La taxonomía está basada en los diferentes tipos de factores que se encuentran en la literatura, como el factor infección por VPH, conducta sexual, psicosocial, económico y cultural, salud y reproducción, y calidad de atención (ver Tabla 4).

Tabla 4 Taxonomía sobre “Factores de Riesgo” en CCU

Factores de riesgo	Estudios
Infección por VPH	(Stewart et al., 2018), (Fani et al., 2019)
Conducta sexual	(Stewart et al., 2018), (P. Sharma & Pattanshetty, 2017)
Psicosocial, económico y cultural	(Stewart et al., 2018), (P. Sharma & Pattanshetty, 2017)
Salud y reproducción	(Stewart et al., 2018), (Xu et al., 2018)
Calidad de atención	(Stewart et al., 2018), (Zahras & Rustam, 2018)

- **Infección por el virus del papiloma humano (VPH)**

Se menciona en la investigación de (Stewart et al., 2018) que existen diferentes factores de riesgo relacionados con el cáncer de cuello uterino en África Subsahariana (SSA) (Oriental, Central, Meridional y Occidental). De los que conforman el SSA, África Oriental tiene el mayor número de incidencias de este tipo de cáncer en todo el mundo, lo cual es contradictorio con el hecho de que este es uno de los cánceres más prevenibles, mediante la vacunación, la detección y el tratamiento. Los autores recalcan que la alta incidencia de cáncer de cuello uterino en la SSA se da porque en la mayoría de estos países no se cuenta con la infraestructura, recursos o experiencia en salud adecuada, es por eso que la detección y/o prevención no se efectúa de manera correcta. A partir de esto, las mujeres solo buscan ayuda de los médicos cuando experimentan los síntomas, pero esto solo significa que ya se está desarrollando el CCU. Para el desarrollo de su investigación,

realizaron una revisión de los diferentes factores de riesgo que son los más relevantes en el SSA. Asimismo, hicieron uso de una Relación de Incidencia de Mortalidad (IMR), el cual le proporciona un medio para determinar los factores de riesgos más relevantes que contribuyen al desarrollo del CCU en el SSA. Para obtener los datos de IMR, utilizaron la base de datos proporcionada por GLOBOCAN 2012 de IARC. También, emplearon diferentes variables para detectar los factores de riesgo relevantes, y, para aquellos factores de riesgo con múltiples variables, solo seleccionaron las variables con los datos más completos que se obtuvieron del Banco de Datos Mundial (datos demográficos, VIH femenino, tabaquismo, desnutrición y paridad), del Instituto de Estadística de la UNESCO (educación) y del Programa Encuestas Demográficas y Salud de la USAID (comportamientos sexuales, estado civil, uso de anticonceptivos, ITS y datos educativos). Luego, procedieron a evaluar la distribución del IMR, y corrigieron la asimetría detectada a través de una transformación \log_{10} . Además, hallaron los coeficientes de correlación de Pearson para las variables de distribución normal, los coeficientes de correlación de Spearman para las variables no paramétricas, y los valores de probabilidad (p) los generaron y utilizaron para probar la correlación de los factores de riesgo y el LogIMR. Los resultados que obtuvieron se muestran en la Figura 7, y los factores que presentaron una correlación significativa los utilizaron para realizar la regresión lineal multivariada.

Variable	Number of countries (n)	Median	IQR	Range	Pearson (C)	Spearman (S)	p-value
HIV prevalence 15-49yr, %	45	2.7	5	0.2-26.5		0.375	0.011*
Comprehensive HIV knowledge, %	34	28.75	20.38	13.9-67.8		0.201	0.254
Economic status, GDP per capita USD	46	1811.96	2100.27	547.32-36754.81		0.753	0.000*
Health expenditure, per capita USD	44	124.15	146.62	23.65-1170.09		0.743	0.000*
Hospital beds, per 1000 population	44	1.1	1.35	0.1-3.3		0.581	0.000*
Rural population, % total	46	60.97	22.57	13.54-88.79	-0.523		0.000*
Undernourishment, % total	39	20.2	20.4	3.6-48.1	-0.182		0.2666
Single, % women	36	27.9	8.48	7.9-59.5		0.468	0.004*
Married, % women	36	54.75	22.45	10.7-88.4	-0.696		0.000*
Common-law spouse, % women	36	9.5	14.85	0.2-34.2		0.336	0.049*
Divorced, % women	36	7.4	5.15	1.0-14.1	0.403		0.015*
Widowed, % women	36	2.5	1.75	0.6-7.5		-0.037	0.831
Median age of sexual debut	35	17.4	1.45	15.9-21.0		0.24	0.166
Median age at first marriage	40	18.85	2.2	15.5-29.1		0.622	0.000*
Median age at first birth	36	19.95	1.6	18.3-23.0	0.148		0.39
Average no. sexual partners	28	2.25	0.93	1.2-5.1		0.493	0.008*
No condom use with non-regular partner	34	64.8	21.03	34.5-95.0	-0.525		0.001*
1 or more co-wife, % women	33	18.3	21.2	1.5-343.8		-0.377	0.030*
Oral contraception, % women	36	4.1	4.45	0.7-62.2		0.297	0.078
Contraceptive knowledge, % women	35	96.4	4.65	67.3-99.7		0.468	0.005*
STI, % women	34	10.4	11.68	0.2-50.2		-0.064	0.718
Parity (average)	45	4.94	1.23	1.45-7.58	-0.601		0.000*
Smoking, % women	33	2.8	4	0.2-21.2		-0.108	0.549
Illiteracy, female 15 + yr	44	38.35	36.93	6.87-88.96		-0.708	0.000*
Transition Prim to Sec, % women	37	78.67	24.76	53.36-98.56		0.285	0.087
Cumulative primary dropout, % women	38	35.62	27.73	1.13-75.49	-0.494		0.002*
Mean years of education	33	4.4	3.99	0.99-9.02		0.792	0.000*
Education: none (%)	37	20	34.3	2.3-80.0		-0.742	0.000*
Education: primary (%)	37	33.6	30.7	9.3-68.3	0.189		0.261
Education: secondary (%)	37	27	23.5	6.5-65.2		0.568	0.000*
Education: post-secondary (%)	32	3.6	3.63	0.5-22.0		0.484	0.005*

Figura 7 Estadística descriptiva (Stewart et al., 2018)

Para los factores de riesgo relevantes, los evaluaron mediante una matriz de diagrama de dispersión. También, agregaron dos variables categóricas al conjunto de datos: Región (“Sur”, “Este”, “Central” y “Oeste”) y Cribado (“Basado en la población”, “Oportunista”, “Sin programa” y “Sin datos”), y con este conjunto de datos completo los sometieron a una regresión lineal múltiple por pasos para seleccionar la combinación de variables para la detección del CCU en etapa tardía para SSA. Además, se realizó una regresión gradual, finalmente, el diagnóstico de regresión del modelo se realizó utilizando pruebas de suma de cuadrados ANOVA Tipo II que evalúan cualquier interacción entre variables. Para el análisis de los datos, utilizaron R versión 3.4.1 (2017-06-07) para Mac iOS con los siguientes paquetes: PASTECS, MASS, psych, CAR, GVLMA, RVAidememoire, RCOMPANION, RColor-Brewer, RWORLDMAP, RWORLDXTRA y Hmisc. En la Figura 8, se muestran los factores que seleccionaron para el modelo final. Los autores presentan un análisis de IMR por regiones de SSA, e indican los factores más significativos relacionados con el CCU. Unos de los factores más relevantes es la alta prevalencia de VIH en las

poblaciones, y esto influye en un mayor riesgo de contraer el VPH, que es uno de los factores de mayor importancia para desarrollar el CCU.

Coefficients:	Estimate	Std. Error	t value	p value
(Intercept)	4.426×10^{-01}	4.908×10^{-02}	9.018	4.39×10^{-11} ***
HIV	-1.936×10^{-03}	1.130×10^{-03}	-1.713	0.095 .
GDP	2.189×10^{-06}	1.147×10^{-06}	1.909	0.065 .
Rural	-6.078×10^{-04}	4.328×10^{-04}	-1.404	0.168
No condom use	-1.347×10^{-03}	5.194×10^{-04}	-2.594	0.013 *
Parity	-1.744×10^{-02}	6.220×10^{-03}	-2.804	0.008 **
No education	-1.311×10^{-03}	3.039×10^{-04}	-4.315	0.0001 ***

Significance codes: **** < 0.001; *** < 0.01; ** < 0.05; * < 0.1; . < 1

Figura 8 Coeficientes, error estándar, estadística de valor t y probabilidad de las variables seleccionadas en el modelo final (Stewart et al., 2018)

Acorde con (Fani et al., 2019), el VPH infecta los epitelios cutáneos y mucosos, y también causa la progresión de la neoplasia cervical a cáncer cervical (CC) invasivo, lo que la lleva a ser una de las neoplasias malignas más comunes en las mujeres. Además, mencionan que varios estudios han demostrado que el VPH 16 y el VPH 18 son más prevalentes en CC y en adenocarcinoma, respectivamente. Los autores toman el caso de Irán, que tiene una población de 30.13 millones de mujeres mayores de 15 años que están en riesgo de desarrollar CC. Teniendo en cuenta la importancia del VPH, el objetivo de su revisión es informar sobre la prevalencia del VPH-RH (tipos 16 y 18) en mujeres iraníes con CC e investigar los métodos actuales para la detección del VPH. Los autores inician el desarrollo de su artículo incorporando bases de datos nacionales e internacionales, incluyendo SID, Iranmedex, Pubmed, Google Scholar, Scopus y Science Direct. Limitaron la investigación a los artículos originales publicados en inglés y persa, presentando la incidencia o prevalencia de VPH en Irán. Utilizaron ciertas palabras claves en la búsqueda de información. Lograron identificar 92 estudios primarios a través de búsquedas en bases de datos nacionales e internacionales; entre ellos, 43 artículos duplicados y 30 artículos fueron excluidos después de la búsqueda avanzada. Finalmente, utilizaron diecinueve artículos

para este estudio. Todos los análisis estadísticos fueron realizados a través del software STATA SE Versión 11, aplicando un modelo de efectos aleatorios para la heterogeneidad. La Figura 9 detalla el diagrama de flujo. Los autores concluyen mencionando que, según los resultados, la prevalencia de infección por VPH entre las mujeres iraníes con CC fue menor que la reportada entre las mujeres africanas y latinoamericanas, casi similar a la prevalencia reportada en Rumania y más alta que la reportada para Turquía. Menciona que estas diferencias podrían deberse a varios factores, como la selección de métodos de detección, la cantidad de muestras recolectadas, la edad a la que comienzan los encuentros sexuales y la cantidad de parejas sexuales. Además, hacen notar que HPV16 fue el tipo principal en los casos de CC iraníes. Con respecto a la fracción positiva de HPV16 / 18 en mujeres con CC, ellos sugieren la vacunación de los grupos de alto riesgo, y también buscar una solución para la prevención y el control de la infección por VPH a través de instalaciones de técnicas de diagnóstico avanzadas.

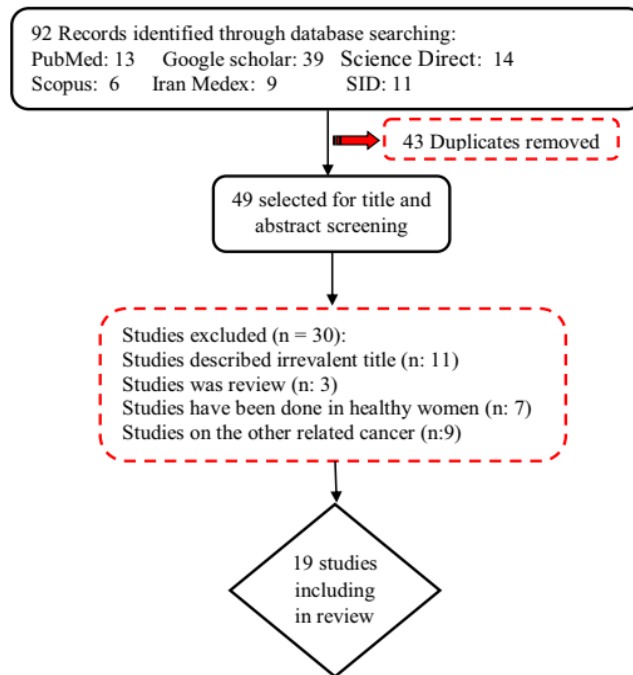


Figura 9 Diagrama de flujo (Fani et al. 2019)

- **Conducta sexual**

(P. Sharma & Pattanshetty, 2017), mencionan que el porcentaje de ocurrencia de cáncer varía en diferentes partes del mundo. De estos, los países en vías de desarrollo llevan la mayor carga. Estiman que hay entre 2 y 2,5 millones de casos de cáncer en la India en un momento dado y una cuarta parte de la carga mundial de cáncer de cuello uterino es asumida solo por la India. El cáncer de cuello uterino puede ocurrir por cada 1/53 mujeres en los países desarrollados. Caso contrario se hace notar en los países subdesarrollados, donde se tiene una relación de 1/100 mujeres. En un estudio realizado en 1967, los factores de riesgo de cáncer de cuello uterino, como el matrimonio precoz y el parto, el número de parejas y partos se identificaron como factores de mayor riesgo de cáncer de cuello uterino. Sin embargo, no se han realizado análisis de factores de riesgo para el cáncer de cuello uterino en el sur de la India, principalmente, en el distrito de Udupi. Con lo mencionado anteriormente, los autores justifican su investigación tomando como lugar de estudio el hospital Shirdi Sai Baba Cancer, Manipal- en el distrito de Udupi. Para iniciar con la investigación, se tuvo el consentimiento de las personas. Todos los casos histológicamente confirmados de cáncer de cuello uterino entre el grupo de edad de 20-80 años fueron incluidos en el estudio. Los casos que no estaban dispuestos a participar en el estudio o aquellos casos que estaban gravemente enfermos fueron excluidos del estudio. Los casos fueron entrevistados utilizando un cuestionario semiestructurado. El análisis de datos se realizó utilizando un paquete estadístico para el software de ciencias sociales (SPSS versión 15). Los datos se resumen en forma de tablas. Se utilizó un análisis de regresión logística univariante para evaluar los factores significativamente asociados con el cáncer cervical. Se utilizó la regresión logística múltiple para calcular la razón de probabilidades ajustada con un intervalo de confianza (IC) del 95%. Como conclusiones, con base en los resultados, señalan que el estado civil casado, edad de la menarquia

de 13-14 años, antecedentes de prurito vaginal, edad del primer coito de <18 años, al menos un aborto, la paridad de > 3 son importantes factores de riesgo de cáncer de cuello uterino. Añaden que la educación sanitaria puede administrarse junto con exámenes regulares de cáncer cervical a las mujeres, especialmente, las mujeres posmenopáusicas, además de la revisión periódica de las mujeres en edad reproductiva, ya que ayudará en el diagnóstico precoz y el tratamiento oportuno. También, señalan que la introducción de la vacunación contra el VPH, a partir de la edad del joven adolescente, debe orientarse en las instalaciones públicas, ya que la edad al coito <18 años es un factor de riesgo. Por ello, se deben iniciar programas de salud enfocados en crear conciencia para aumentar el comportamiento informado de búsqueda de salud en el grupo de alto riesgo.

(Stewart et al., 2018), como se explicó anteriormente, lo autores también mencionan otro factor significativo que tiene relación con la falta de uso del condón con una pareja no regular, esta alta incidencia de sexo inseguro es debido a una falta de educación sanitaria y programas insuficientes de sensibilización e intervención del gobierno, ya sea por recursos económicos, el conflicto interno, la corrupción, las sequías y hambrunas, también, debido a un desempoderamiento de la mujer, que no les permite negociar el uso de condón con su pareja.

- **Factores psicosociales, económicos y culturales**

(Stewart et al., 2018), señala otro factor influyente son las poblaciones rurales, ya que son estos los que tienen menor acceso a la atención médica, una peor alfabetización en salud y conciencia sobre el cáncer, por ende, los pacientes solo se presentan en un centro médico cuando los síntomas son considerables. Además, en SSA la población rural es una gran fuerza laboral y lo cual facilita la propagación del VPH, cuando los trabajadores regresan a sus hogares.

(P. Sharma & Pattanshetty, 2017), agregan que la educación es un factor importante en relación con el cáncer de cuello uterino. En sus estudios estadísticos, se presenta una relación inversamente proporcional entre el nivel de estudio (alfabetización) y el cáncer de cuello uterino.

- **Salud y reproducción**

(Stewart et al., 2018), también, menciona que el factor de alta paridad está relacionado con una mayor frecuencia de relaciones sexuales sin protección que resulta en una mayor exposición al VPH y un mayor riesgo de desarrollar el CCU. Además, está relacionado a la falta de conocimiento sobre salud o acceso a los anticonceptivos, debido a un sistema de salud ineficiente. La alta paridad, incluso, puede reflejar una desigualdad de género en el acceso a la educación.

Acorde con (Xu et al., 2018), la Agencia Internacional para la Investigación del Cáncer (IARC) ha clasificado el tabaquismo y los anticonceptivos orales combinados como cancerígenos para los humanos y su evaluación de la evidencia ha demostrado una asociación causal entre estos agentes y el cáncer de cuello uterino. Sin embargo, debido a los cambios temporales en la formulación de anticonceptivos orales en términos de dosis de estrógeno y tipo de progestágeno, justifican investigar la asociación entre el pre-cáncer y el uso de anticonceptivos orales en una cohorte más reciente. Para su investigación, requirió de datos y muestras, las cuales fueron obtenidas del Cervical Health Study, un gran estudio de casos y controles, realizado en New South Wales, Australia. El reclutamiento fue realizado entre diciembre de 2006 y julio de 2011, en mujeres de 20 a 64 años. Para el análisis, se seleccionaron casos y controles de edades 30-44 años. Los controles y los casos fueron emparejados por banda de 5 años (30-34, 35-39, 40-44). Para el recojo de datos y mediciones, utilizaron cuestionarios y formularios de consentimiento.




Figura 10 Anticonceptivos hormonales (Xu et al., 2018)

En cuanto a los análisis estadísticos, todos ellos se realizaron con el software Stata 11.0 (StataCorp). Los odds ratios (OR) y los intervalos de confianza del 95% (IC) se estimaron mediante análisis de regresión logística condicional. Se incluyeron en el estudio actual un total de 886 casos y 3636 controles. El 93% de los controles eran usuarias actuales (55%) o exusuarias (38%) de anticonceptivos hormonales (ver Figura 10). Para el historial de tabaquismo, el uso amplio, el tiempo desde que dejó de fumar, la duración del uso y el número de cigarrillos / día se asociaron con NIC 2/3 ($p = 0,008$, $p = 0,003$, $p = 0,033$ y $p < 0,001$ respectivamente) (ver Figura 11).




Figura 11 Antecedentes de tabaquismo (Xu et al., 2018)

Sus conclusiones indican que, entre las mujeres australianas de 30 a 44 años de edad, las usuarias actuales de anticonceptivos hormonales y las fumadoras actuales tenían un mayor riesgo de desarrollar CIN 2/3, además, una mayor duración de uso e intensidad de exposición, respectivamente, conducen a un mayor aumento en el riesgo.

- **Calidad de atención**

(Stewart et al., 2018), sostuvo, además, que la falta de calidad de atención tiene relación con que los gobiernos no proporcionan a sus poblaciones una calidad en educación y en salud, que repercute en la falta de pruebas de detección y programas de prevención.

(Zahras & Rustam, 2018), los autores recalcan que las tasas de incidencia de cáncer de cuello uterino van en aumento y esto es una preocupación constante, es por esto para su estudio hacen uso de las redes neuronales, la cual es una rama de la inteligencia artificial. Utilizan las redes neuronales para evaluar un conjunto de datos de factores de riesgo de cáncer de cuello uterino, los

cuales los evalúan por medio de cuatro variables y quieren saber cuál de los métodos tiene la mayor precisión. El conjunto de datos los recopiló en el “Hospital Universitario de Caracas”, en Caracas, Venezuela. Este conjunto de datos que recopilaron comprende información demográfica, hábitos y registros médicos históricos, pero varios pacientes decidieron no responder algunas de las preguntas debido a problemas de privacidad lo que les produjo tener datos faltantes. En un principio, el conjunto de datos que utilizarían iba a estar comprendido de 32 factores de riesgo y cuatro variables objetivo: Hinselmann, Schiller, citología y biopsia; pero, debido a que tuvieron datos faltantes, eliminaron los factores de riesgo 27 y 28, por ende, utilizaron solo 30 factores de riesgo, donde los datos fueron de 699 personas. A continuación, se muestra la Tabla 5 con los factores de riesgo que usaron para su estudio.

Tabla 5 Datos de los factores de cáncer cervical (Zahras y Rustman, 2018)

Número de factor	Nombre de los factores
1	Edad
2	Número de parejas sexuales
3	Primer encuentro sexual (edad)
4	Número de embarazos
5	Fuma
6	Fuma (años)
7	Fuma (paquetes/año)
8	Anticonceptivos hormonales
9	Anticonceptivos hormonales (años)
10	IUD
11	IUD (años)
12	STD's
13	STD's (número)
14	STD's: Condilomatosis
15	STD's: Condilomatosis cervical
16	STD's: Condilomatosis vaginal
17	STD's: Condilomatosis vulvo perineal
18	STD's: Sífilis
19	STD's: Enfermedad inflamatoria pélvica
20	STD's: Herpes genético
21	STD's: Molluscum Contagiosum
22	STD's: SIDA

23	STD's: VIH
24	STD's: Hepatitis B
25	STD's: PVH
26	STD's: Número de diagnósticos
27	STD's: Tiempo del primer diagnóstico
28	STD's: Tiempo del último diagnóstico
29	Dx: Cáncer
30	Dx: CIN
31	Dx: VPH
32	Dx

En su estudio, evaluaron los datos por medio de redes neuronales, clasificaron los datos en cuatro variables objetivo y midieron la precisión para cada objetivo. Obtuvieron los siguientes resultados: para la variable objetivo Hinselmann, obtuvieron una precisión de 95.99%, cuando usaron el 50% de datos de entrenamiento de datos con un tiempo de 12.75 segundos, pero, cuando usaron el 90% de datos de entrenamiento, obtuvieron la precisión más baja 90.78% y el menor tiempo que fue de 3.38 segundos; para la variable objetivo Schiller lograron obtener una precisión de 95.71% utilizando el 10% de datos de entrenamiento, pero con el mayor tiempo de 23.47 segundos y con el tiempo de ejecución más rápido de 3.73 segundo utilizando el 90% de los datos de entrenamiento alcanzaron el 90.46% de precisión, en cuanto el tercer objetivo, citología, lograron alcanzar una precisión de 97.41%, cuando usaron el 10% de datos de entrenamiento y con un tiempo de 25.52 segundos, el mayor tiempo; y finalmente, para el cuarto objetivo que es biopsia obtuvieron la mayor precisión de 92.69% con el 90% de datos de entrenamiento y con el menor tiempo de 4.57 segundos. Finalmente, concluyen que las redes neuronales pueden llegar a ser buenos clasificadores de datos riesgo de cáncer de cuello uterino, y rescatan que pudieron obtener en los cuatro objetivos una precisión mayor del 90% en poco tiempo, además de que puede ayudar al personal médico a clasificar fácilmente algunos datos de riesgo de cáncer de cuello uterino, y esto llevaría a una mejor calidad de atención.

3.4.4. Medidas de prevención

Esta clasificación nos mostrará cuáles son las medidas de prevención que se han considerado en las diferentes propuestas sobre el cáncer de cuello uterino y también está relacionada con la segunda pregunta de investigación (P2). La taxonomía está basada en las diferentes medidas de prevención que se encuentran en la literatura, como la salud, la vacuna y la detección temprana (ver Tabla 6).

Tabla 6 Taxonomía sobre “Medidas de prevención” contra el CCU

Medidas de prevención	Estudios
Salud	(Okunade et al., 2018)
Detección temprana	(Firmino-Machado et al., 2019), (Shrivastav et al., 2021)
Vacuna	(Smith et al., 2018), (Almazrou et al., 2019), (Shrivastav et al., 2021)

- **Salud**

(Okunade et al., 2018), mencionan en su investigación que los oligoelementos realizan una función vital en muchas reacciones enzimáticas bioquímicas, y que han sido examinados rigurosamente como un factor clave en diversas enfermedades humanas, incluidos los cánceres. También, se sabe que los oligoelementos participan fundamentalmente en el proceso de desarrollo normal de diferentes tejidos en humanos y animales. Es por esto por lo que pueden jugar un papel clave en la prevención del CCU. Entre los oligoelementos con mayores estudios, están el zinc, el selenio y el cobre. Estudios han demostrado que el zinc desempeña un papel vital como regulador en el inicio de la inmunidad celular, por otro lado, la concentración de cobre en suero es considerado un marcador inespecífico para controlar la progresión de enfermedades malignas, y respecto al oligoelemento esencial, el selenio, los oncólogos siguen investigando acerca de sus funciones como radioprotector en tejidos normales, radiosensibilizador en tumores malignos y sus efectos en la prevención primaria y secundaria del cáncer. Existen diferentes investigaciones sobre

el nivel de zinc, cobre y selenio en pacientes con CCU, tanto dentro como fuera de Nigeria, pero aún hay datos limitados respecto a la asociación entre los oligoelementos y el CCU en mujeres nigerianas. Por lo tanto, el estudio que realizaron fue en el Hospital de Enseñanza de la Universidad de Lagos (LUTH), Lagos, Nigeria, en el cual escogieron 50 pacientes recientemente diagnosticados con carcinoma de células escamosas del cuello uterino y 100 sujetos de control que no tenían malignidad. Realizaron un cuestionario estructurado, en el cual se recopilaron datos relevantes, y después se obtuvo un volumen de 5ml de muestra de sangre. Para determinar las concentraciones de zinc y cobre, utilizaron un espectrofotómetro de absorción atómica directa, y, para medir la concentración de selenio, utilizaron el método de generación de hidruro. Luego de la generación de hidruro, utilizaron un método de borohidruro de sodio para determinar la concentración de selenio (AAS Modelo ECI 4141). Ingresaron todos los datos en la computadora y los analizaron utilizando el paquete estadístico SPSS versión 22.0, calcularon las estadísticas descriptivas para todos los datos continuos y los expresaron como media y desviación estándar. Las asociaciones entre dos grupos de variables continuas se probaron utilizando la prueba t de muestra independiente. La significación estadística se definió como $P < 0.05$.

Demographic characteristics	Patients (n=50)	Controls (n=150)	P-value
	Mean \pm SD	Mean \pm SD	
Age (years)	43.1 \pm 7.5	40.9 \pm 11.8	0.177
BMI (kg/m ²)	23.6 \pm 3.1	22.7 \pm 6.3	0.093
Haemoglobin level (g/dL)	8.4 \pm 2.6	12.7 \pm 1.4	0.042
Total albumin (g/dL)	5.1 \pm 1.3	4.9 \pm 2.2	0.134
*BMI – Body Mass Index; SD – Standard Deviation			

Figura 12 Características demográficas de los participantes del estudio (Okunade et al., 2018)

Los resultados que obtuvieron reflejaron que los niveles de zinc y selenio eran bajos en los pacientes con CCU, en comparación con los pacientes de control, además, el zinc desempeña una función anticancerígena por medio de la estabilización estructural del ácido desoxirribonucleico

(ADN), ácido ribonucleico (ARN) y ribosoma. También, el estudio que realizaron coincidió con otros estudios en que el selenio a un nivel bajo aumenta el riesgo en el CCU. Sin embargo, los valores de nivel de cobre, si bien en los pacientes con CCU fue mayor, no se encontró ninguna asociación estadísticamente significativa. Finalmente, los autores concluyen que su estudio no puede ser generalizado porque solo está basado en un hospital. Además, sugieren que los suplementos de zinc y selenio pueden prevenir la aparición de CCU.




Figura 13 Pacientes con cáncer cervical y sus controles (Okunade et al., 2018)

- **Detección temprana**

(Firmino-Machado et al., 2019) plantean que requieren estrategias fáciles de implementar para aumentar el nivel de participación de la población en la detección de cáncer de cuello uterino, una de las estrategias que se utilizan, y que es de bajo costo, es mediante invitaciones que se envían mediante mensajes de texto automáticos o llamadas telefónicas, las cuales pueden aumentar la adherencia en un 15%. Por lo tanto, el objetivo de los autores fue evaluar la efectividad de esta estrategia, con un aumento gradual de la complejidad y el costo (mensajes de texto/llamadas telefónicas automáticas, llamadas telefónicas manuales y entrevistas cara a cara), para mejorar la adherencia de las mujeres en la detección del cáncer de cuello uterino. La estrategia que utilizaron

se implementó gradualmente para aumentar la adherencia en el cribado del cáncer de cuello uterino en un ensayo aleatorizado, multicéntrico, paralelo, basado en la población (estrategia escalonada para mejorar la adherencia del cribado de cáncer de cuello uterino -SCAN-Cervical Cancer). La invitación la realizaron en tres pasos: en el primer paso, la invitación fue por medio de mensajes de texto automáticos y personalizados, las participantes que no se adhirieron en el paso 1 pasaron al paso 2, en el cual los secretarios clínicos realizaron la invitación a través de llamadas telefónicas, por último, en el paso 3, la invitación la realizaron por medio de llamadas telefónicas y citas cara a cara, para las participantes que no se adhirieron con el paso 1+2. Para el grupo de control, la invitación la realizaron por medio de una carta escrita personalizada. El estudio lo realizaron en Portugal, donde el Sistema Nacional de Salud proporciona acceso universal y esencialmente gratuito al tratamiento, pero también servicios preventivos como la detección, es por eso que se utilizaron dos áreas de atención primaria de salud: Porto occidental (área urbana), con una adherencia al cribado del cáncer de cuello uterino del 30% y Marão e Douro Norte (área suburbana y rural), con una adherencia al cribado del cáncer de cuello uterino estimada en un 60%, de las cuales 13 unidades de atención primaria de salud acordaron participar, todas implementaron los pasos 1 y 2, pero solo 10 implementaron el paso 3. Para analizar los datos se basaron en la Intención de Tratar (ITT), también, realizaron Análisis por Protocolo (PP) para estimar la eficacia de las intervenciones del paso 1, paso 2, paso 3, paso 1+2 y paso 1+2+3. Además, evaluaron las diferencias de las características de las mujeres y las proporciones de adherencias entre los grupos de intervención y de control con la prueba chi-square, el valor de significancia que utilizaron de p con un valor de 0.05.

	Intervention		Control		% Difference (95% CI)	p-Value ^a	Crude OR (95% CI)	p-Value	Adjusted ^b OR (95% CI)	p-Value
	n	n _{screened} (% screened)	n	n _{screened} (% screened)						
Intention-to-treat analysis										
Step 1	605	236 (39.9)	615	158 (25.7)	13.3 (8.1 to 18.5)	< 0.001	1.85 (1.45 to 2.36)	< 0.001	1.87 (1.46 to 2.39)	< 0.001
Step 1 + 2	605	294 (48.6)	615	189 (30.7)	17.9 (12.4 to 23.2)	< 0.001	2.13 (1.69 to 2.69)	< 0.001	2.16 (1.71 to 2.74)	< 0.001
Step 1 + 2 + 3	605	310 (51.2)	615	209 (34.0)	17.3 (11.7 to 22.6)	< 0.001	2.04 (1.62 to 2.57)	< 0.001	2.07 (1.64 to 2.63)	< 0.001
Per-protocol analysis ^c										
Step 1	517	222 (42.9)	609	158 (25.9)	17.0 (11.5 to 22.4)	< 0.001	2.14 (1.67 to 2.76)	< 0.001	2.14 (1.66 to 2.77)	< 0.001
Step 2	247	57 (23.1)	441	31 (7.0)	16.1 (10.5 to 20.1)	< 0.001	3.97 (2.48 to 6.35)	< 0.001	4.11 (2.56 to 6.62)	< 0.001
Step 3 ^d	119	11 (9.2)	265	7 (2.6)	6.6 (1.8 to 13.3)	0.005	3.75 (1.42 to 9.94)	0.008	3.71 (1.38 to 10.0)	0.009
Step 1 + 2	434	276 (63.6)	593	188 (31.7)	31.9 (25.9 to 37.6)	< 0.001	3.76 (2.89 to 4.89)	< 0.001	3.86 (2.96 to 5.04)	< 0.001
Steps 1 + 2 + 3 ^d	273	179 (65.6)	365	121 (33.2)	32.4 (24.8 to 39.5)	< 0.001	3.84 (2.76 to 5.35)	< 0.001	4.13 (2.92 to 5.84)	< 0.001

CI - confidence interval.

^a Comparison between intervention and control.

^b Adjusted for age (continuous), education (< 9, 9–12, 12, > 12 years), household size (≤2 vs. > 2 people), employment status (student/employed vs. un-employed/retired), occupation (white collar vs. blue collar), Health Care Area (Porto Ocidental vs. Marão e Douro Norte), deprivation index (continuous variable) and previous participation in organized screening (never attended, attended irregularly, attended regularly).

^c These analyses exclude women who were classified as non-eligible after randomization, those who have an invalid phone number (intervention group) and those with invalid address (control group).

^d This analysis excludes all the women defined in ^c and those registered at primary care units that did not implement the step 3 intervention.

Figura 14 Comparación entre los grupos de intervención y control (Firmino-Machado 2019)

Tuvieron una población de 1220 mujeres, 605 para la intervención y 615 para el control. Para el paso 1, tuvieron a 517 mujeres para la intervención y 609 para el control, de las cuales la adherencia para la detección de cáncer de cuello uterino fue mayor en las mujeres de intervención que de control, específicamente, 39.0% vs. 25.7%, con $p < 0.001$. En el paso 2, analizaron a 369 mujeres para la intervención y 457 para el control, de las cuales la adherencia fue mayor para el grupo de intervención, teniendo un 15.7% vs. 6.8%, con $p < 0.001$; y, en el paso 1+2, también, el grupo de intervención tuvo una mayor adherencia a las del grupo de control, con 48.6% vs. 30.7%, con $p < 0.001$. Finalmente, para el paso 3, contaron con 311 mujeres para el grupo de intervención y 426 para el grupo de control, la adherencia no tuvo mayor diferencia, 5.1% vs. 4.7%, $p = 0.780$; y, en el acumulativo de 1+2+3, la adherencia fue mayor el grupo de intervención, 51.2% vs 34.0%, $p < 0.001$. Con este estudio, los autores demostraron que una invitación gradual para realizar detecciones tempranas es más efectiva que una atención estándar, además, esperan que la adherencia al cribado de cáncer cervical aumente en al menos un 17%, y se utilicen diferentes estrategias gradualmente.

(Shrivastav et al., 2021) comenta que el cáncer de cuello uterino es y seguirá siendo uno de los mayores problemas de salud en aquellos países donde se tienen bajos y medios ingresos. Sin embargo, si este problema es detectado a tiempo, puede prevenirse e inclusive curarse. Por ende, en su trabajo realizado se enfocó en determinar el perfil sociodemográfico y clínico de las pacientes con cáncer de cuello uterino que acuden a un centro oncológico de tercer nivel. Para lograr ello, realizó un estudio retrospectivo en el Instituto Estatal del Cáncer de Delhi, Nueva Delhi. Un total de 136 mujeres a las que se les diagnosticó cáncer de cuello uterino fueron incluidas en su población de estudio. Además, utilizó una hoja de extracción de datos previamente probada como herramienta de estudio para recopilar información de los registros de los pacientes ingresados. Adicionalmente, realizó un análisis descriptivo y una prueba de chi-cuadrado, y el nivel de significación se fijó en $p < 0,05$. Con base en los resultados que obtuvo, estudió retrospectivamente a los 136 pacientes con cáncer de cuello uterino con una edad media de $46 \pm 9,85$ y un IMC medio de $23,78 \pm 5,03$. Alrededor del 36,8% de las pacientes tenían entre 40 y 49 años y el 57,4% eran analfabetas. Mientras que el 40,4% de las pacientes pertenecían al estadio II de FIGO, el 27,2% tenían un cáncer en estadio III de FIGO. La mayoría (63,2%) de los pacientes fueron diagnosticados de carcinoma de células escamosas (CCE), mientras que el resto eran adenocarcinomas (25%) y adenoescamosos (11,8%). El estadio clínico del cáncer se asoció significativamente con el nivel educativo ($p=0,03$) y las prácticas alimentarias ($p=0,007$). Como conclusiones comenta que se encontró un mayor porcentaje de mujeres con lesiones cervicales en estadio II y III, y reafirma la importancia de la educación y la dieta saludable en la detección temprana y la prevención del cáncer cervical.

- **Vacuna**

(Smith et al., 2018) menciona que con la implementación del Programa Nacional de Detección Cervical (NCSP) de Nueva Zelanda se ha logrado disminuir la tasa de incidencia de cáncer de cuello uterino en las mujeres maoríes y no maoríes (europeas/otras), pero aún ha seguido habiendo diferencia de las tasas de incidencia entre estas mujeres, ya que esta tasa en las mujeres maoríes es dos veces más alta que en las mujeres no maoríes. Es por lo que la Unidad Nacional de Detección de Nueva Zelanda les encargó este estudio para determinar si los cambios que se estaban proponiendo para la detección y prevención de cáncer de cuello uterino benefician en la misma medida a mujeres maoríes y otras mujeres en Nueva Zelanda. Por ende, tuvieron como objetivo evaluar el impacto de la vacunación contra el VPH y la transición propuesta al cribado primario del VPH cada 5 años en las mujeres maoríes y en otras mujeres de Nueva Zelanda, a los niveles de participación actuales; y además investigar qué mejoras en la participación de las mujeres maoríes (en la vacunación, el cribado o la vigilancia de las mujeres de mayor riesgo definidas por el cribado) tendrían el mayor impacto en la incidencia/mortalidad del cáncer cervical. Para lograr ello, Smith adaptó un modelo integral Policy1-Cervix de vacunación contra el VPH y de cribado cervical en Nueva Zelanda para ajustarlo a los datos observados específicos de cada etnia. Utilizó modelos específicos para cada etnia para estimar el impacto a largo plazo de la vacunación y el cribado (cobertura de la vacunación: 63% frente a 47%; cobertura del cribado a cinco años: 68% frente a 81%, en las mujeres maoríes, frente a las europeas/otras, respectivamente). En cuanto a los resultados, prevé que el cambio de la citología al cribado basado en el VPH reducirá la incidencia del cáncer de cuello de útero en un 17% (14%) en las mujeres maoríes (europeas/otras), respectivamente. Las reducciones correspondientes debidas a la vacunación y al cribado basado en el VPH combinados fueron del 58% (44%), pero en los niveles actuales de participación la

incidencia a largo plazo seguiría siendo casi el doble en las mujeres maoríes (6,1/100.000 frente a 3,1/100.00 en las europeas/otras). Entre lo examinado, el mayor impacto viene de la alta cobertura de la vacuna y de lograr una mayor asistencia de las mujeres maoríes a la vigilancia de las anomalías detectadas en el cribado. El autor concluye señalando que las reducciones relativas del cáncer de cuello uterino debidas a la vacunación y al cribado basado en el VPH son mayores en las mujeres maoríes que en las europeas/de otro origen. Aunque estas intervenciones tienen el potencial de reducir sustancialmente las diferencias entre grupos, la incidencia del cáncer cervical seguiría siendo mayor en las mujeres maoríes. Esto resulta la importancia de los enfoques múltiples y la posible influencia de factores que van más allá de la prevención del VPH.

(Almazrou et al., 2019) mencionan que, si bien la vacuna contra el VPH es una de las principales medidas de prevención contra el cáncer de cuello uterino, también, está asociada a reducir las enfermedades relacionadas con el VPH. Sin embargo, existen diferentes factores que influyen en el conocimiento deficiente sobre el VPH y la relación que tiene con el cáncer de cuello uterino, estos factores son la falta de conocimiento sobre la vacuna del VPH, prácticas culturales, creencias y factores sociales, los cuales son determinantes para la aceptación y absorción de la vacuna en el Reino de Arabia Saudita (KSA). Realizaron un estudio para evaluar el nivel de conocimiento, las actitudes y las prácticas de los médicos y pediatras, ya que estos son la principal fuente de información para los padres respecto a la importancia de la vacuna contra el VPH. Este estudio lo realizaron en la Ciudad Médica Rey Abdul-Aziz, Región Central, Arabia Saudita; entre septiembre de 2017 y enero de 2018, donde se encuentra el hospital gubernamental KAMC, en el cual evaluaron a los médicos que tenían trabajando más de 6 meses, en total evaluaron 248 médicos. Recopilaron los datos por medio de un cuestionario que se difundió por Google por un enlace al correo electrónico de los médicos y pediatras, dividieron el cuestionario en cuatro

dominios principales: datos demográficos, conocimiento general sobre las vacunas contra el cáncer cervical y el VPH, práctica/comportamiento respecto a la vacuna contra el VPH y la actitud hacia la vacuna contra el VPH. Para analizar los datos, utilizaron STATA13 (College Station, TX), realizaron análisis descriptivos para frecuencias y porcentajes, también, obtuvieron valores medios para los datos continuos y realizaron un análisis de regresión con respecto al conocimiento y la actitud de los médicos hacia la provisión de la vacuna contra el VPH. Utilizaron la prueba chi-square para comparar variables categóricas en el cuestionario (género, años de práctica y especialidad), y la significancia que aceptaron fue cuando $p < 0.05$.

Variable	N (%)	
Knowledge of the existence of cervical cancer		
Yes	169	(97.69)
No	4	(2.32)
Cervical cancer can be fatal		
Yes	65	(37.57)
No	84	(48.55)
Do not know	24	(13.87)
Cervical cancer is normally caused by an infectious agent		
Yes	166	(95.95)
No	0	
Do not know	7	(4.05)
There is an effective method of reducing the risk of cervical cancer		
Yes	163	(94.22)
No	10	(5.78)
Cervical cancer is a common type of cancer in Saudi Arabia		
Yes	51	(29.48)
No	65	(37.57)
Do not know	57	(32.95)
Knowledge of the existence of HPV		
Yes	168	(97.11)
No	5	(2.89)
HPV can cause cervical cancer		
Yes	162	(93.64)
No	3	(1.73)
Do not know	8	(4.62)
HPV subtypes 6 and 11 are associated with cervical cancer		
Yes	77	(44.51)
No	52	(30.06)
Do not know	44	(25.43)
HPV subtypes 16 and 18 are associated with cervical cancer		
Yes	99	(57.23)
No	26	(15.03)
Do not know	48	(27.75)
There is a vaccine against cervical cancer		
Yes	146	(84.39)
No	20	(11.56)
Do not know	7	(4.05)
The HPV vaccine can guarantee 100% protection from cervical cancer		
Yes	33	(19.08)
No	82	(47.40)
Do not know	58	(33.53)
Pap smear testing is not required following HPV vaccination		
Yes	15	(8.67)
No	102	(58.96)
Do not know	56	(32.37)
Overall knowledge score for cervical cancer	N (%)	Mean (SD)
Good knowledge	106 (61.27)	3.74(0.87)
Poor Knowledge	67 (38.73)	
Overall knowledge score for HPV	N (%)	Mean (SD)
Good knowledge	101 (58.38)	4.69(1.38)
Poor Knowledge	72 (41.62)	

Figura 15 Conocimiento informado de los médicos (Almazrou et al., 2018)

Los resultados que obtuvieron son que, de todos los participantes, el 98% conocía el cáncer cervical, pero casi la mitad (49%) no consideraba al cáncer cervical como fatal, respecto al conocimiento de los subtipos del VPH, el 45% reconoció que los tipos 6 y 11 son oncogénicos, mientras que el 30% no lo hizo, y para los subtipos 16 y 18, el 57% informó saber que estaban asociados con el cáncer cervical. Respecto al conocimiento de la vacuna contra el VPH, el 84% la conocía, el 80% de los participantes consideró que es importante que las mujeres reciban la vacuna contra el VPH, y el 82% afirmó que permitiría que sus hijas lo reciban. En general, el 61% de los médicos mostró un buen conocimiento del cáncer cervical y la mayoría de los médicos recomendaron que las vacunas para las mujeres se administren en edades entre 16 y 26 años.

(Shrivastav et al., 2021) enfatiza en su trabajo de investigación realizado en el Instituto Estatal del Cáncer de Delhi, Nueva Delhi, que es obligatorio acelerar la concienciación de la población y el cribado, incorporando innovaciones digitales que incluyan programas de vacunación.

3.4.5. Técnicas de diagnóstico con IA

Esta clasificación mostrará cuales son los métodos de detección que se han considerado en las diferentes propuestas sobre el cáncer de cuello uterino y, también, está relacionada con la tercera pregunta de investigación (P3). La taxonomía está basada en los diferentes tipos de factores que se encuentran en la literatura, como Papanicolau Test, Colposcopia (ver Tabla 7).

Tabla 7 Taxonomía sobre “Métodos de detección” en CCU

Técnicas de diagnóstico con IA	Estudios
Algoritmos de clustering	(Kuko & Pourhomayoun, 2019), (Bhuvaneshwari & Poornima, 2019)
Algoritmos de clasificación	(Kuko & Pourhomayoun, 2019), (Bhuvaneshwari & Poornima, 2019), (Shalini et al., 2018), (Hyeon et al., 2017), (Rohmatillah et al., 2018), (Win et al., 2019), (Bandyopadhyay & Nasipuri, 2020), (Win et al., 2020)

Aprendizaje profundo	(Hyeon et al., 2017), (Rohmatillah et al., 2018), (D. Sharma et al., 2018), (Ghoneim et al., 2019), (Manasa Ungrapalli & Myna, 2019), (Sompawong et al., 2019), (Xia et al., 2020), (Basak et al., 2021), (Yaman & Tuncer, 2022)
----------------------	--

- **Algoritmos de clustering**

(Kuko & Pourhomayoun, 2019) proponen utilizar técnicas para extraer, segmentar y clasificar anomalías en las células cervicales, por medio de imágenes que obtuvieron de pruebas de Papanicolaou, para esto construyeron un sistema de extremo a extremo que identifica las células en las muestras aplicando visión artificial, la extracción de características lo realizan con algoritmos de aprendizaje no supervisado y luego clasifican la anomalía de las células y los grupos de células basándose en el Sistema Bethesda para obtener una clasificación aplicando un conjunto de técnicas de aprendizaje automático.

Para lograr su objetivo, obtuvieron su conjunto de datos del Centro Médico de la Universidad del Sur de California, de este modo, lograron recolectar 104 muestras, pero de un solo paciente, los datos fueron brindados por un patólogo quien les informó que estas muestras contenían células anormales, posiblemente, cancerosas y células normales. Además, sus colegas patólogos clasificaron las etiquetas en 13 677 células y grupos de células para que utilicen un conjunto para que puedan realizar el entrenamiento basándose en el sistema Bethesda, en donde realizaron una distribución justa de las imágenes y obtuvieron 2 298 células anormales y 2 298 células normales. Luego, procedieron a realizar la extracción y segmentación de las células, para la extracción de características, aplicaron un proceso centrado en la visión artificial basado en el algoritmo de procesamiento de imágenes Watershed, en el cual se coloca un cuadro delimitador alrededor de cualquier objeto de interés en la imagen, pero antes pasaron la imagen a una escala de grises, y luego, volvieron las imágenes a su color original. Para la segmentación de las imágenes comenzaron reduciendo las imágenes de la célula en 128x128 píxeles, luego procedieron a

transformar las imágenes en un vector de 16 384 píxeles, para implementar el algoritmo K-means de Mini-batch sin supervisión en donde crearon 4 grupos de píxeles, y procedieron a segmentar adecuadamente las muestras de células, los cuales consistieron en el segmento del núcleo, membrana celular, el citoplasma y el fondo. También, aplicaron la técnica de aumento de datos, para lo cual obtuvieron 8 imágenes por cada imagen, lo que les resultó en 36 768 muestras de imágenes.

(Bhuvaneshwari & Poornima, 2019) proponen el uso de técnicas de preprocesamiento de imágenes, para la detección de células normales y anormales en pruebas de Papanicolaou, por lo cual han utilizado la técnica basada en Fuzzy y el algoritmo de KNN para la clasificación. Además, recalcan que una detección temprana de células precancerosas llega a ser importante en el tratamiento del cáncer. Para lograr su objetivo, utilizaron imágenes que obtuvieron del Hospital Universitario Herlev, el cual desarrolló dos conjuntos de datos relacionados con las células cervicales. La metodología que utilizaron partió de un preprocesamiento de la imagen, en el cual, primero, redimensionaron la imagen a un tamaño de 256x256px, luego, para el cambio del tamaño de la imagen, aplicaron el filtro gaussiano, para reducir la intensidad del píxel y el ruido de la imagen. Para la segmentación utilizaron el algoritmo Fuzzy-C Mean, el cual es un algoritmo de repetición donde se obtiene un c óptimo. En la extracción de características utilizaron Gray Level Co-event Matrix (GLCM), el cual les sirvió para calcular la dependencia extraordinaria de las dimensiones tenues de una imagen, además, para la extracción de característicos de la forma que calcularon, usaron circularidad, perímetro y área.

- **Algoritmos de clasificación**

(Kuko & Pourhomayoun, 2019), para el proceso de entrenamiento, utilizaron el modelo de bosques aleatorios, en el cual configuraron 100 estimadores y entrenaron con el 80% de los datos

y en la prueba utilizaron el 20% de los datos. Este conjunto lo repitieron para una validación cruzada 5 veces. Obtuvieron una exactitud del 90.37% con una sensibilidad y especificidad del 96.33% y 83.59%, respectivamente, en la clasificación de las células en anormal y normal. Además, proponen que se puede realizar un sistema automatizado de detección de Papanicolaou de extremo a extremo, junto con patólogos y expertos capacitados para salvar la vida de los pacientes.

(Bhuvaneshwari & Poornima, 2019), en la parte de clasificación, utilizaron el algoritmo k-Nearest Neighbours. Para la técnica que propusieron, utilizaron MATLAB 2017. Finalmente, en su entrenamiento y prueba, obtuvieron una precisión del 95%, y concluyen que esta detección es útil para que el patólogo pueda dar de manera efectiva un diagnóstico y tratamiento.

(Shalini et al., 2018) menciona que cada vez existe un mayor número de personas con acceso a una mejor atención médica y más avanzada sometándose a una prueba de Papanicolaou. Para estas pruebas, existe una escasez de patólogos capacitados y experimentados. Por otro lado, revisar las láminas de la prueba de Papanicolaou se ha convertido en un consumo de tiempo considerable, lo que, en última instancia, conduce a un aumento de la carga de trabajo de los patólogos, pudiendo llegar también a la fatiga. Esta puede ser una causa potencial de inexactitudes en el diagnóstico. Para solucionar aquel problema, proponen un sistema de detección automatizado de cáncer de cuello uterino. La Figura 16 muestra el flujo del algoritmo del método de detección del cáncer de cuello uterino empleado. Este flujo contiene siete pasos. La metodología presentada de clasificación automatizada de imágenes de colposcopia del cuello uterino comienza con la recopilación de imágenes de colposcopia obtenidas a partir de imágenes disponibles gratuitamente en la imagen que se construyó. Una vez que los GLCM (Gray Level Coexistence Matrix) estuvieron disponibles, extrajeron las 13 características de Haralick para cada GLCM. Luego, el

clasificador de SVM se entrenó utilizando las 13 características extraídas para cada imagen en el conjunto de datos de entrenamiento. Después de entrenar el modelo SVM, las imágenes presentes en el conjunto de datos de prueba se clasificaron utilizando el modelo SVM mencionado anteriormente. Después de predecir las clases en el conjunto de datos de prueba, se realizó un análisis de rendimiento. El conjunto de datos así obtenido se dividió en 2 partes: 70% del dataset para el entrenamiento y 30% del dataset para las pruebas.




Figura 16 Diagrama de flujo de la metodología (Shalini et al., 2018)

Extrajeron las características de Haralick del GLCM calculado para cada imagen. Descubrieron que los valores de todas las características de Haralick difieren significativamente para imágenes cancerosas y no cancerosas y, debido a esta razón, la clasificación de imágenes entre cancerosas y no cancerosas se hizo posible. Posteriormente, calcularon la exactitud, especificidad, precisión y sensibilidad para el clasificador SVM con 3 funciones de kernel diferentes. Los datos obtenidos se tabulan en la Tabla 8.

Tabla 8 Parámetros de eficiencia de predicción para 3 funciones de núcleo diferentes (Shalini et al., 2018)

	Sensitivity	Precision	Specificity	Accuracy
Precision	78.43%	100%	100%	87.78%
RBF	85.11%	100%	100%	92.22%
Linear	100%	94.34%	92.5%	96.67%

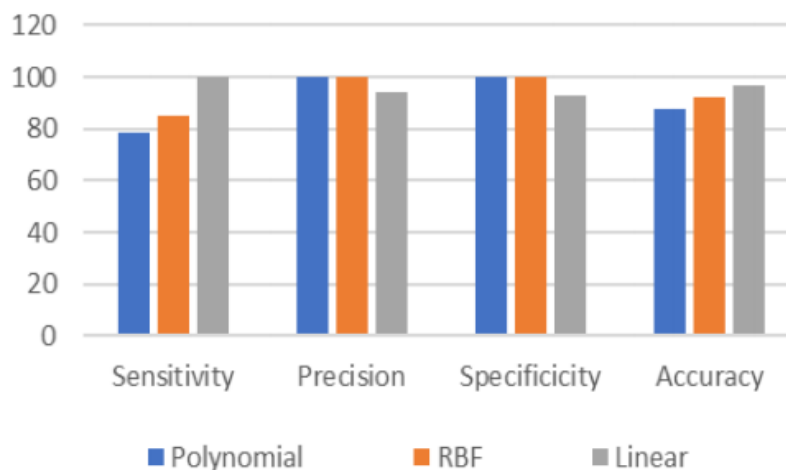


Figura 17 Gráfico de eficiencia (Shalini et al. 2018)

Con base en la Figura 17, los autores optaron por SVM sobre otros algoritmos de aprendizaje automático, porque SVM es menos sensible al ruido en la entrada, mientras que una pequeña cantidad de perturbaciones en la entrada puede causar una gran disminución en la precisión en el caso de las redes neuronales. Finalmente, concluyen que el análisis mostró que la función del núcleo polinomial dio una precisión del 87,78%, la función del núcleo RBF dio una precisión del 92,22%, mientras que la función del núcleo lineal dio la precisión más alta del 96,67%.

(Hyeon et al., 2017) menciona que la prueba de Papanicolaou tiene dificultades para construir sistemas automatizados porque necesita analizar la imagen del microscopio. Tienen en mente construir un sistema de este tipo utilizando Deep Neural Networks, ya que muestran una mejora notable en el análisis de imágenes en los últimos años. Por tanto, utilizaron Deep Neural

Networks para analizar la imagen de las células cervicales y desarrollar un sistema que pueda ayudar al citopatólogo. Su estudio tiene como objetivo clasificar el estado normal/anormal de las imágenes microscópicas en la prueba de Papanicolaou. Para llegar a ello, extraen vectores de características de las imágenes microscópicas utilizando un modelo de red neuronal convolucional (CNN) previamente entrenado y se clasifican los vectores extraídos a través de varios clasificadores. El procedimiento general se resume en la Figura 18.




Figura 18 Procedimiento para clasificar una imagen (Hyeon et al., 2017)

Recolectaron 71,344 imágenes microscópicas de frotis de Papanicolaou y sus interpretaciones de la Seegene Medical Foundation. Debido a que la distribución del conjunto de datos está muy desequilibrada, es difícil entrenar clasificadores de aprendizaje automático sin ninguna mitigación. Para mitigar la distribución desequilibrada, se fusionan las clases ASCUS, LSIL, ASC-H, HSIL y Cáncer como una clase anormal. Además, para equilibrar la distribución de las clases Normal y Anormal, se reduce la muestra de las instancias de la clase Normal por el número de datos de la clase Anormal fusionada. Como resultado, la distribución del conjunto de datos se cambia, tal como se muestra en la siguiente Tabla 9.

Tabla 9 Distribución de conjuntos de datos (Hyeon et al., 2017)

Class	Number of Instances
Normal	8373
Abnormal	8373

Antes de realizar un experimento, dividieron el conjunto de datos fusionados y son reducidos en un conjunto de entrenamiento del 80% y un conjunto de prueba del 20%. Además, se entrena a todos los clasificadores usando solo el conjunto de entrenamiento y lo probaron empleando solo el conjunto de prueba. Como resultado, se puede calcular el rendimiento de clasificación, tal como se muestra en la Tabla 10 y la Figura 19. El mejor rendimiento se logra mediante la máquina de vectores de soporte.

Tabla 10 Parámetros de eficiencia de predicción para 3 funciones de núcleo diferentes (Hyeon et al., 2017)

	Logistic Regression	Random Forest	Ada Boost	SVM
Precision	0.7456	0.7318	0.7276	0.7817
Recall	0.7456	0.7317	0.7275	0.7817
F1	0.7456	0.7317	0.7274	0.7817

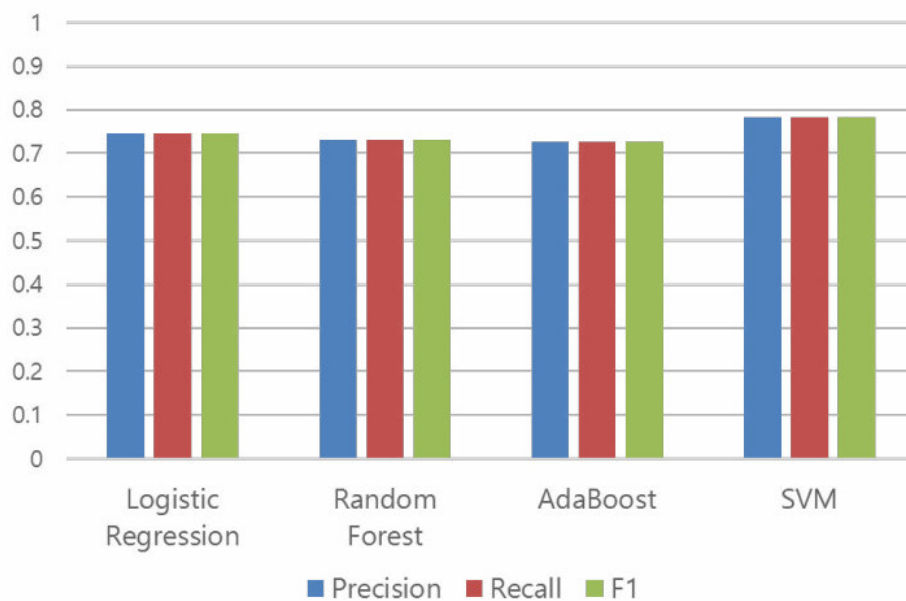


Figura 19 Gráfico de rendimiento (Hyeon et al., 2017)

Como conclusión, presentan un método para desarrollar un clasificador que determina el estado normal o anormal de las células del cuello uterino en una imagen microscópica. El VGGNet-16, que es un modelo de red neuronal convolucional (CNN) previamente entrenado en el desafío de reconocimiento visual a gran escala de ImageNet, se utiliza como un extractor de vectores de características para imágenes microscópicas. Luego, se podría entrenar una máquina de vectores de soporte con un rendimiento del 78% utilizando estos con vectores de características extraídas. En este momento, para extraer el vector de características que representa la imagen microscópica, se usa el método de dividir la imagen en varias partes, extrayendo los vectores de características de cada pieza y calculando el promedio de ellas.

Acorde a (Rohmatillah et al., 2018), el cáncer del cuello uterino es una de las enfermedades más mortales en mujeres en el mundo. Para superar ello, se han venido desarrollando varias investigaciones, con respecto a métodos de detección, para ayudar a los médicos a tomar mejores decisiones en el diagnóstico y prevenir afecciones más graves. Su investigación propone un método para producir un buen resultado en la clasificación de las células cervicales. Además, dicho método puede clasificar las celdas de entrada en siete clases diferentes. Este método propuesto consta de tres pasos principales, extracción de características, reducción de características y clasificación. El algoritmo de CNN se implementó en la etapa de extracción de características, ya que es una técnica poderosa en el dominio de la imagen que incluye la segmentación, clasificación y detección de objetos de la imagen. La Figura 20 muestra una arquitectura propuesta por LeCun para el reconocimiento de dígitos.




Figura 20 CNN propuesta por LeCun (Rohmatillah et al. 2018).

Para su investigación, utilizaron Herlev Pap Smear Database. Las bases de datos de frotis de Papanicolaou de Herlev son un conjunto de datos de frotis de Papanicolaou adquirido a partir de imágenes de frotis sanos y cancerosos recopilados por el Hospital Universitario de Herlev (Dinamarca). Este conjunto de datos contiene cientos de imágenes de células cervicales distribuidas en siete clases diferentes. La Figura 21 muestra la arquitectura del marco propuesto. Como CNN necesita muchas imágenes para obtener una buena precisión, las imágenes del conjunto de datos primero deben aumentarse girándose en 90 grados, 180 grados, 270 grados y, finalmente, voltearlas horizontalmente. Como las imágenes de las clases completas no se distribuyen de manera uniforme, algunas imágenes deben eliminarse aleatoriamente en las clases que tienen más imágenes. Esos procedimientos dieron como resultado 3780 imágenes que luego se dividieron en imágenes de entrenamiento y de prueba con una proporción del 75% (2835 imágenes) y el 25% (945 imágenes), respectivamente. Las imágenes de entrenamiento se redimensionaron a 64x64 píxeles antes de enviarlas a la arquitectura CNN, para extraer sus características.




Figura 21 Arquitectura del marco propuesto (Rohmatillah et al., 2018)

Esta investigación implementó una arquitectura basada en VGG (Visual Geometry Group) 16 (con pesos previamente entrenados en ImageNet) que consistió en varias capas convolucionales 2D y capas de agrupación máxima que tienen un tamaño de 3x3 y 2x2, respectivamente, y se realizó la activación de ReLU (Unidad lineal rectificada) como activación de capa. Después de obtener las características de las imágenes de entrada, esas características se redujeron mediante el uso de Linear Análisis discriminante (LDA) seguido de análisis de componentes principales (PCA). Finalmente, como clasificador, se realizó Support Vector Machine y Artificial Neural Network con softmax como función de activación de salida. Los resultados de este experimento se evaluaron mediante tres medidas, precisión, sensibilidad y especificidad. La Figura 22 muestra la comparación entre SVM y softmax como clasificadores.




Figura 22 Performance de los clasificadores (Rohmatillah et al., 2018)

El artículo muestra que el mejor método para clasificar las células cervicales es el uso de SVM. Además, los resultados obtenidos son mejores en comparación con la investigación anterior con 95,8%, 99,3% y 99,1% en precisión, sensibilidad y especificidad, respectivamente. El método propuesto logró un resultado prometedor en la clasificación del cáncer de células de cuello uterino. Por lo tanto, es potencialmente posible implementarlo en otros campos con diferentes conjuntos de datos.

(Win et al., 2019) justifica su trabajo mencionando que en los EE. UU. la tasa de mortalidad de los pacientes con cáncer de cuello uterino se redujo en un 2% gracias a la detección temprana y acertada en las pruebas de Papanicolaou. Sin embargo, el análisis manual es un proceso que requiere mucho trabajo y tiempo, y depende de un citólogo experto. Por lo tanto, es necesario desarrollar un sistema de diagnóstico apoyado por ordenador para que la prueba de Papanicolaou sea más precisa y fiable. En su estudio, propone un marco para la detección y clasificación del cáncer cervical a partir de imágenes de Papanicolaou. El objetivo de su trabajo fue presentar una idea innovadora de aplicar el algoritmo de bosque aleatorio (RF) como método de selección de características utilizando el clasificador ensemble propuesto para mejorar el rendimiento

predictivo. Utilizó los cuatro pasos básicos del sistema de detección y clasificación del cáncer de cuello uterino: mejora de la imagen, segmentación, extracción de características y clasificación. La agrupación de K-means, combinada con operaciones de morfología, obtuvo una buena segmentación para los núcleos celulares y el citoplasma. Las características más importantes, la forma, el color y la textura de los núcleos y el citoplasma, se aplicaron para detectar el cáncer cervical. Para mejorar la precisión de los resultados de predicción, utilizó el algoritmo de bosque aleatorio (RF) como método de selección de características. En la etapa de clasificación, aplicó un clasificador de conjunto de bolsas que agregaba los resultados de cinco clasificadores, discriminante lineal (LD), máquina de vectores de apoyo (SVM), vecino más cercano k ponderado (KNN), árboles potenciados y árboles de bolsas, tal como se muestra en la Figura 23. Para probar la eficacia del método propuesto, utilizó el conjunto de datos de Herlev. Según los resultados experimentales, obtuvo una alta precisión de clasificación con las características top10 utilizando el clasificador combinado propuesto. La precisión fue del 97,83% en problemas de dos clases y del 81,54% en problemas de siete clases. Cuando los resultados se compararon con cinco clasificadores, el método propuesto fue significativamente mejor en los problemas de dos clases y de siete clases.

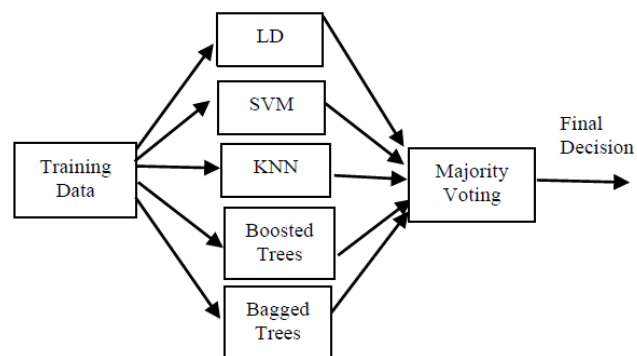


Figura 23 Diagrama de bloques de los cinco clasificadores combinados (Win et al., 2019).

(Bandyopadhyay & Nasipuri, 2020) comentan que el cáncer de cuello uterino es el segundo tipo de cáncer más frecuente en mujeres alrededor del mundo. En algunos países de África subsahariana, América Latina y Asia, la tasa de mortalidad es aún más elevada. Por otro lado, el cáncer cervical es fácilmente tratable siempre y cuando sea detectado en sus etapas iniciales. La prueba de Papanicolau ayuda en este proceso de despistaje, pero el problema reside en que este proceso se hace de manera manual, requiriendo de mucho tiempo, alta experticia, es costoso y tedioso. Dado lo anterior, este proceso debe de ser automatizado apoyándose del procesamiento y detección de imágenes de células obtenidas de las pruebas de Papanicolau. La metodología propuesta aquí se basó en la agrupación K-means para la segmentación de imágenes preprocesadas y se lleva a cabo en el conjunto de datos Herlev, tal como se observa en la Figura 24. Se comprobaron los valores de IoU de los resultados de la segmentación con la verdad del terreno y se extrajeron varias características de forma del núcleo segmentado. La clasificación de los núcleos sobre la base de las características de forma se realizó con la ayuda del clasificador Random Forest y se comparó con otros clasificadores y sus resultados en el conjunto de datos. Los resultados finales que se obtuvieron con Random Forest tienen un valor en el accuracy de 94.52 en el training y de 92.15 en el testing.




Figura 24 Diagrama de la metodología propuesta (Bandyopadhyay & Nasipuri, 2020).

(Win et al., 2020) menciona que, aproximadamente, el 90% de las muertes por cáncer de cuello uterino ocurren en los países de bajos y medios ingresos. El cáncer de cuello uterino puede

prevenirse mediante revisiones periódicas para detectar cualquier precáncer y tratarlo. La prueba de Papanicolaou busca cualquier cambio anormal o precanceroso en las células del cuello uterino. Sin embargo, el cribado manual de la citología en el microscopio es subjetivo y con criterios poco reproducibles. Dado lo anterior, el autor planteó su objetivo de su estudio en desarrollar un sistema de cribado asistido por ordenador para el cáncer de cuello de útero utilizando el procesamiento digital de imágenes de frotis de Papanicolaou. En la Figura 25, se presenta el diagrama de flujo del sistema de cribado asistido por ordenador propuesto por el autor para la citología cervical. El sistema propuesto consta de seis etapas: adquisición de imágenes, mejora de imágenes, segmentación de células, extracción de características, selección de características y clasificación. En la etapa de adquisición de imágenes, se utilizó el conjunto de datos SIPaKMeD para las células múltiples, y el conjunto de datos Herlev para una sola célula. Las imágenes de frotis de Papanicolaou de entrada fueron mejoradas y denotadas para mejorar la calidad de la imagen como un paso de mejora de la imagen. El siguiente paso fue la segmentación celular. Este paso dividió las imágenes de entrada en las regiones interesantes: núcleo y citoplasma. Tras la segmentación, el siguiente paso fue la extracción de características. En la extracción de rasgos, se extrajeron los puntos o rasgos distintivos de interés. En la etapa de selección de características, se utilizó el algoritmo de bosque aleatorio como método de selección. El último paso fue la clasificación. En esta etapa se aplicó el clasificador de conjunto de bolsas, tal como se observa en la Figura 26, que combinaba los resultados de cinco clasificadores: C1: LD (discriminante lineal), C2: SVM (máquina de vectores de apoyo), C3: KNN (vecino más cercano), C4: árboles reforzados y C5: árboles embolsados. Según los resultados experimentales, se obtuvo un 98,27% de precisión en la clasificación de dos clases y un 94,09% en la de cinco clases utilizando el conjunto de datos

SIPaKMeD. Cuando los resultados se compararon con los de cinco clasificadores, el método propuesto fue significativamente mejor en los problemas de dos clases y de cinco clases.




Figura 25 Diagrama de la metodología propuesta (Win et al., 2020).




Figura 26 Diagrama de bloques de los clasificadores de conjunto (Win et al., 2020).

- **Aprendizaje profundo**

(Hyeon et al., 2017), mencionados anteriormente, clasifican automáticamente los estados normales y anormales de las células del cuello uterino utilizando VGGNet-16, que es un modelo

de red neuronal convolucional (CNN) previamente entrenado en el ImageNet Large Scale Visual Recognition Challenge, y varios clasificadores de aprendizaje automático.

(Rohmatillah et al., 2018), anteriormente mencionado, analiza un segundo clasificador basado en una DNN, para este caso, obtiene una precisión, sensibilidad y especificidad de 94,8%, 97,53% y 99,38%, respectivamente.

(D. Sharma et al., 2018) centra el trabajo propuesto en la detección del cáncer que se desarrolla en la parte más baja del útero, llamada cérvix. Este es uno de los tipos más comunes de cáncer que afecta a las mujeres y es causado principalmente por el virus del papiloma humano (VPH). La arquitectura propuesta del cribado automático de la citología vaginal comienza con la recopilación de imágenes de una base de datos pública estándar seguida de la metodología propuesta en la Figura 27.

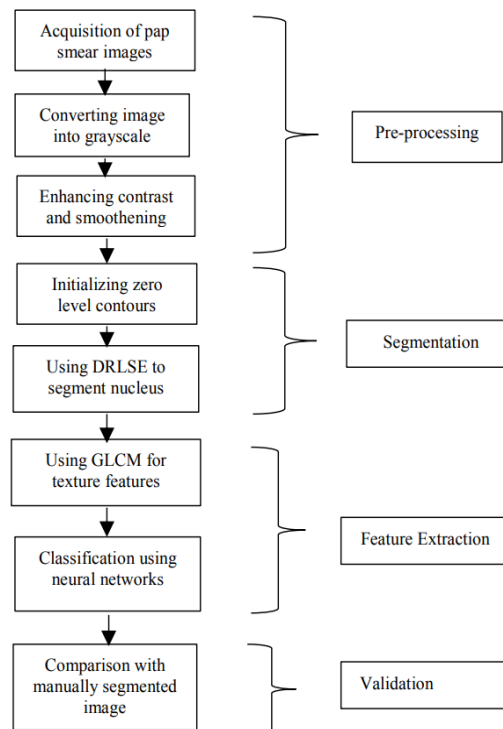


Figura 27 Diagrama de flujo del algoritmo propuesto (Sena et al. 2018).

El procesamiento se realiza en una matriz bidimensional, por lo que las imágenes RGB de entrada se convierten, en primer lugar, en imágenes en escala de grises. En la segmentación, para evitar esta inestabilidad y reducir los errores numéricos, se utiliza un nuevo tipo de evolución de conjuntos de niveles denominada evolución de conjuntos de niveles regularizados por distancia (DRLSE). En el trabajo propuesto, se evalúan 22 características basadas en texturas utilizando la matriz de co-ocurrencia de nivel de gris (GLCM) para cada imagen y se forma una matriz de características con características de todas las imágenes. Las características basadas en texturas se consideran, ya que se observa que estas son más eficientes para diferenciar las imágenes en la base de datos utilizada para este trabajo. La red neuronal diseñada consta de 2 capas ocultas con 22 neuronas en cada capa. Estas neuronas actúan como unidades computacionales, en virtud de la función de activación. La función sigmoidea se ha utilizado como función de activación, que optimiza el rendimiento del algoritmo minimizando la función de coste. El algoritmo de retropropagación se ha utilizado para implementar la red neuronal. En este algoritmo, los pesos de las neuronas se calculan inicialmente utilizando el algoritmo feedforward. Estos pesos se optimizan luego calculando los gradientes utilizando el algoritmo de retropropagación. En la metodología propuesta, el número de neuronas en la capa de salida es 7.

Para los resultados experimentales, el contorno segmentado con el método propuesto se compara con la imagen segmentada manualmente. Los resultados son los siguientes: Training Accuracy 85.185, Testing Accuracy 84.615.

(Ghoneim et al., 2019) los autores proponen la aplicación de redes neuronales convolucionales como una ayuda para el diagnóstico de cáncer de cuello uterino, por medio de imágenes de exámenes de Papanicolaou que obtuvieron de la base de datos Herlev que fue desarrollada en el Hospital Universitario Herlev (Dinamarca), el cual contiene 917 imágenes de

siete clases, tres de estas clases pertenecen a células normales y cuatro de estas clases a anormales, por consiguiente, se tienen 242 imágenes normal y 675 imágenes anormal. Pero recalcan que la implementación de este método de diagnóstico no es para reemplazar la evaluación subjetiva de un experto, sino para que les ofrezca una ayuda, ya que, normalmente, el diagnóstico se realiza mediante un proceso de detección y una biopsia. En su investigación, propusieron un sistema basado en el aprendizaje profundo para la detección y clasificación de las células cancerosas cervicales, particularmente, aplicaron redes neuronales convolucionales (CNN, por sus siglas en inglés) seguidas por un clasificador basado en máquina de aprendizaje extremo (ELM, por sus siglas en inglés). Además, introdujeron CNN en la detección y clasificación de células de cuello uterino, también, insertaron un clasificador basado en ELM, y, por último, introdujeron un clasificador basado en autoencoder (AE). Los autores especifican que, por lo investigado, son los primeros en aplicar ELM y AE después de la CNN en el sistema de detección de cáncer cervical. Para la investigación, aplicaron tres modelos de CNN, el primero tiene una arquitectura poco profunda y los otros dos tienen una arquitectura profunda, ya que utilizaron los modelos VGG16 Net y CaffeNet. La primera arquitectura la construyeron con 2 capas convolucionales, 2 capas completamente conectadas seguidas de una capa softmax (salida), y utilizaron el algoritmo minibatch Stochastic Gradient Descent (SGD) para la optimización de los parámetros del modelo, para el entrenamiento. Luego, para el sistema que propusieron, utilizaron el clasificador basado en ELM, el cual es una red poco profunda, pero tiene muchas ventajas, como aprendizaje rápido, fácil convergencia y menos aleatorizado. La red ELM la construyeron con dos capas, y procedieron a eliminar la capa softmax del modelo CNN, y utilizaron el algoritmo SGD, también, como alternativa, investigaron el clasificador basado en AE, el cual elimina el ruido y es bueno para extraer características genéricas de una clase. Para el entrenamiento, utilizaron el 80% de las

imágenes y el 20% para la validación. Los mejores resultados los obtuvieron con el clasificador ELM, ya que les ofreció una exactitud del 99.7% para la clasificación de 2 clases y una exactitud del 97.2% para la clasificación de 7 clases.

(Manasa Ungrapalli & Myna, 2019) mencionan, en su trabajo, que el procesamiento y análisis de imágenes sumado al aprendizaje profundo suponen un gran progreso para la ciencia médica dado que se ha logrado usar estas técnicas de inteligencia artificial para la detección de cáncer. Esto conlleva un gran desafío, dado que es muy importante lograr obtener buenos resultados de clasificación en etapas tempranas. Los autores proponen una arquitectura CNN para la clasificación de 7 tipos de imágenes de Papanicolaou. Para lograrlo, crearon su arquitectura CNN, tal como se observa en la Figura 28. La clasificación de imágenes de frotis de Papanicolaou para el cáncer de cuello uterino constó de dos tipos: células cancerosas normales y anormales. El conjunto de datos incluyó 7 conjuntos de clases de imágenes cancerosas que tenían 3 conjuntos de imágenes cancerosas normales y 4 conjuntos de imágenes cancerosas anormales. Su trabajo constó de dos etapas de clasificación: La etapa (i) del trabajo consistió en clasificar los datos como células cancerosas normales o anormales. La etapa (ii) del trabajo clasificó la clase del cáncer como normal columnar, normal intermedio, normal superficial, displasia ligera, displasia moderada, displasia severa y carcinoma-in-situ. Finalizan indicando que su trabajo realizado da buenos resultados en la clasificación de imágenes para 3 conjuntos de clases y 4 conjuntos de clases para células normales, además, es capaz de clasificar y detectar tanto las células normales y anormales con precisión.

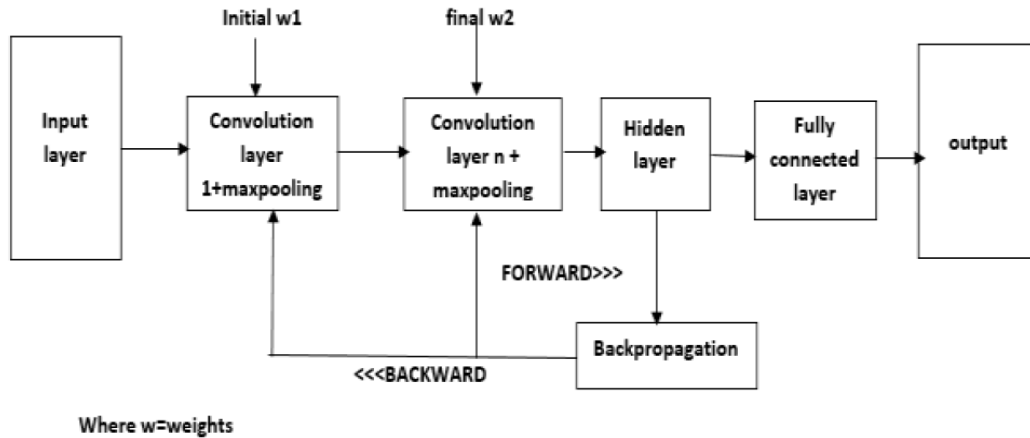


Figura 28 Arquitectura CNN (Manasa Ungrapalli & Myna, 2019)

(Sompawong et al., 2019) sostiene que el cáncer de cuello uterino es el segundo tipo de cáncer más común en las mujeres tailandesas. La alta tasa de mortalidad de esta neoplasia se debe, principalmente a que no existe el equipo suficiente y médicos necesarios para realizar una apropiada prueba de Papanicolaou y darle seguimiento. Por ende, el objetivo de su estudio fue aplicar la Red Neural Convolutiva Regional de Máscara (Mask R-CNN) al cribado del cáncer de cuello de útero mediante el uso de porta objetos histológicos de citología. Basándose en la revisión de la literatura, este fue el primer intento de utilizar Mask R-CNN para detectar y analizar el núcleo de la célula cervical, buscando características nucleares normales y anormales. El modelo utilizado en este trabajo, el cual se puede observar en la Figura 29, consistió en lo siguiente: en la fase de entrenamiento, la entrada fue una imagen de frotis de papanicolaou y la máscara de verdad del núcleo con la etiqueta de clase fue preprocesada y se entrenó en la Mask R-CNN, en la fase de prueba, se preprocesó la imagen del portaobjetos de Papanicolaou, para ello, fue utilizado la Mask R-CNN para especificar el cuadro delimitador, la máscara del núcleo y la clase de cada célula. El conjunto de datos mencionados anteriormente fueron portaobjetos histológicos de base líquida obtenidos del Hospital de la Universidad de Thammasat (TU). Los portaobjetos contenían tanto células cervicales como diversos artefactos, como glóbulos blancos, imitando los portaobjetos

obtenidos en entornos clínicos reales. El algoritmo propuesto alcanzó una precisión media (mAP) del 57,8%, una exactitud del 91,7%, una sensibilidad del 91,7% y una especificidad del 91,7% por imagen. Dado que necesitaban evaluar la eficiencia del algoritmo en comparación con el algoritmo de clasificación de células individuales (Zhang et al., IEEE JBHI, vol. 21, n.º 6, pp. 1633, 2017), modificaron el método para clasificar también las células individuales en la prueba del conjunto de datos TU utilizando la segmentación Mask R-CNN. Los resultados obtenidos tuvieron una precisión del 89,8%, una sensibilidad del 72,5% y una especificidad del 94,3%.




Figura 29 Modelo Mask R-CNN (Sompawong et al., 2019)

(Xia et al., 2020) menciona que el cáncer de cuello uterino, que es el segundo tipo de cáncer más común en el mundo, tiene por víctimas más de 200 000 mujeres cada año y, aproximadamente, el 90% de las muertes ocurren en países en vías de desarrollo. La biopsia cervical se considera el estándar para el cribado del cáncer de cuello de uterino, que puede reducir significativamente la mortalidad. Sin embargo, las principales técnicas de cribado de frotis disponibles son de lectura manual y dado que una imagen patológica contiene miles de células, la interpretación visual de

estas imágenes requiere mucho tiempo. Pocos estudios enfocados en la clasificación y segmentación de células de cáncer de cuello uterino se han apoyado principalmente de técnicas como el Aprendizaje Automático (ML). En recientes años, nuevas técnicas de Aprendizaje Profundo (DL) basadas en redes neuronales convolucionales (CNN) han venido mejorando satisfactoriamente los diagnósticos y detecciones de cáncer. En este trabajo, el autor propone una nueva estructura de red para la detección de células cancerosas cervicales, denominada red de fusión serie-paralelo (SPFNet), la cual se encuentra graficada en la Figura 30. En comparación con las estructuras tradicionales que utilizan redes de clasificación como principal eje para la extracción de características de la imagen, aquí se utilizó diferentes estrategias de combinación en el módulo de series y se diseñó cinco componentes de cabeza diferentes para encontrar la estructura de red más adecuada para la tarea de detección. Además, se llevó a cabo un preprocesamiento de los datos, como el recorte de la ventana deslizable RoI, para las imágenes citológicas thinprep del cáncer de cuello de útero. Con el fin de comparar el marco propuesto con el estado de la técnica de detección, se probaron estos algoritmos de detección de objetos en el mismo conjunto de datos de cáncer cervical. Los resultados experimentales muestran que el marco de detección genera los rendimientos óptimos mejor que cualquier otro con una precisión promedio de 78.4%.

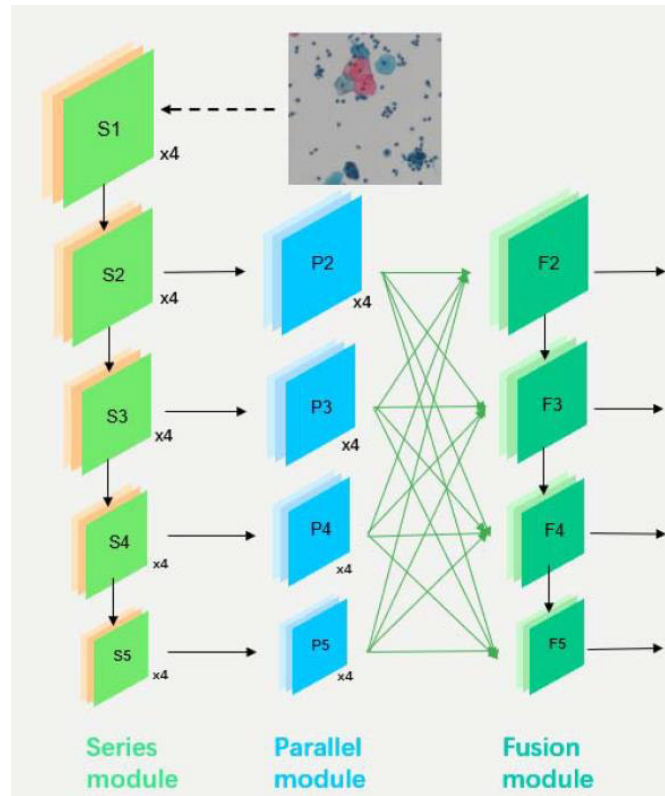


Figura 30 Diagrama de la red propuesta (Xia et al., 2020)

(Basak et al., 2021) propone en su artículo clasificar las células cervicales en imágenes de papanicolaou para la detección del cáncer. El dataset que utilizaron son de citología de base líquida de SIPaKMed y Mendeley, donde desarrollaron el generador ejemplar de características profundas piramidales. En su propuesta, consideran las siguientes fases del modelo basado en la estructura piramidal: (i) transfieren la extracción de funciones basada en el aprendizaje utilizando las redes DarkNet19 o DarkNet53 en una estructura piramidal ejemplar y el generador de funciones que propusieron crea 21 000 funciones, (ii) implementaron el análisis de componentes de vecindad para obtener 10 000 características más informativas de las 21 000 características que se generaron, (iii) la clasificación la realizaron con el algoritmo Support Vector Machine con las 10 000 características que extrajeron con los componentes de vecindad. Utilizaron como técnicas de validación la cruzada de 5 veces y la de retención (80:20). Las mejores precisiones que obtuvieron

para el conjunto de datos SIPaKMeD y Mendeley LBC se calcularon como 98,26 % y 99,47 %, respectivamente. Los resultados que obtuvieron ilustran que el modelo piramidal ejemplar propuesto es exitoso para diagnosticar el cáncer de cuello uterino utilizando imágenes de papanicolau.

(Yaman & Tuncer, 2022) proponen un marco completamente automatizado donde utilizan el aprendizaje profundo y la selección de características mediante la optimización evolutiva para la clasificación de las imágenes de citología. En el marco que proponen, extraen características profundas de varios modelos de redes neuronales de convolución (CNN) y utilizan un enfoque de reducción de características de dos pasos para garantizar la reducción del costo de cómputo y una convergencia más rápida. Los modelos CNN que utilizaron extrajeron un gran espacio de características cuya dimensionalidad se redujeron mediante el análisis de componentes principales y se conserva el 99 % de la varianza. Seleccionaron un subconjunto de características óptimo no redundante de este espacio de características donde utilizaron un algoritmo de optimización evolutiva, el optimizador grey wolf, mejorando así el rendimiento de la clasificación. Finalmente, el subconjunto de características que seleccionaron lo usaron para entrenar un clasificador de máquina de vectores de soporte donde generaron las predicciones finales. El marco propuesto lo evaluaron en tres conjuntos de datos de referencia disponibles públicamente: conjunto de datos de citología basada en líquidos de Mendeley (4 clases), conjunto de datos de prueba de Papanicolaou Herlev (7 clases) y conjunto de datos de prueba de Papanicolaou SIPaKMeD (5 clases) donde lograron una precisión de clasificación de 99,47, 98,32 y 97,87%, respectivamente, lo que justifica la fiabilidad de su enfoque.

Capítulo IV: Metodología de la investigación

En el presente capítulo, se realiza la descripción de la metodología de investigación aplicada al estudio, el cual consta de 4 fases: (i) Planteamiento de la pregunta de investigación, (ii) Diseño del modelo CNN, (iii) Construcción del sistema inteligente y (iv) Validación de la propuesta, tal como se muestra en la Figura 31.

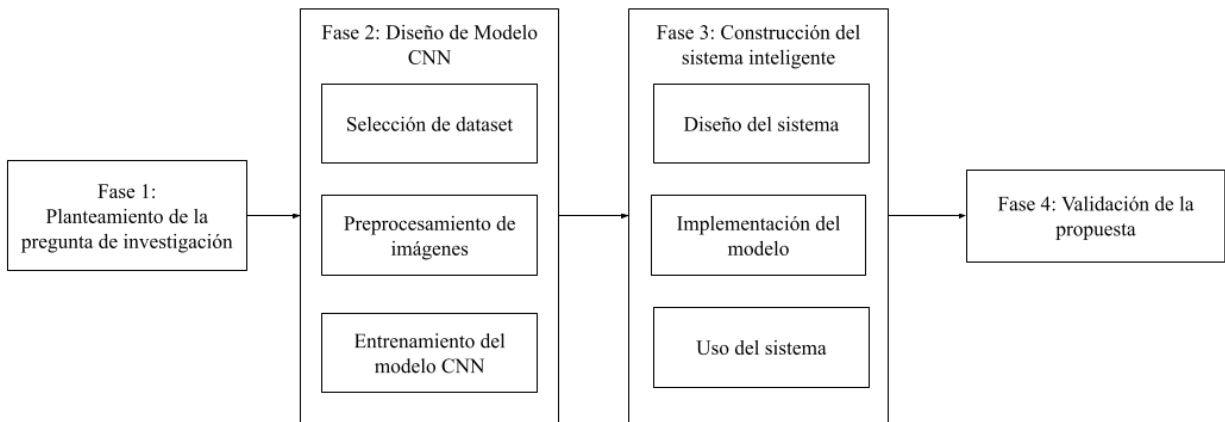


Figura 31 Diagrama de la metodología de la investigación

4.1. Planteamiento de la pregunta de investigación

Se presenta la fase número 1 donde se plantea la siguiente pregunta de investigación “¿Es posible realizar un sistema para el diagnóstico de cáncer de cuello uterino usando redes neuronales convolucionales para ayudar en la detección temprana del cáncer de cuello uterino?”, que está relacionada al objetivo general de la investigación.

4.2. Diseño del modelo CNN

El diseño del Modelo consta de las siguientes actividades: (i) Selección de dataset. En el cual se analiza y describe el conjunto de datos utilizados en el entrenamiento del modelo, (ii) Preprocesamiento de imágenes. En el cual se ha definido el algoritmo de segmentación de las

imágenes que se utilizarán como entrada para el entrenamiento del modelo, (iii) Entrenamiento del modelo CNN. Se entrenará 2 arquitecturas tomando ResNet50 y Resnet101, donde se construirá un modelo aplicando redes neuronales convolucionales con la librería Tensorflow utilizando GoogleColab, una plataforma de Google, para el respectivo entrenamiento y apoyándonos del 80% del dataset.

4.3. Desarrollo del sistema inteligente

El desarrollo del sistema consta de 3 partes: (i) Diseño del sistema, donde se define los módulos que posee el sistema, los cuales son: módulo gestión, módulo diagnóstico y módulo reporte, (ii) Implementación del modelo, donde se da la integración del modelo aplicado con redes neuronales convolucionales en nuestro sistema, (iii) Uso del sistema, donde se explica el funcionamiento del sistema con sus principales módulos que se han desarrollado.

4.4. Validación de la propuesta

Proceso de validación: el cual consiste en dos casos de estudio: (1) Validación del sistema con el 20% del dataset restante, (2) Validación del sistema con imágenes brindadas por el Instituto Nacional de Enfermedades Neoplásicas (INEN).

Capítulo V: Sistema de diagnóstico de cáncer de cuello uterino

En el presente capítulo, se realiza la descripción del aporte, el cual consiste en desarrollar una herramienta para el Diagnóstico de Cáncer de Cuello Uterino haciendo uso de Redes Neuronales Convolucionales (RNC); la justificación del uso de Redes Neuronales Convolucionales, el mapa del modelo planteado, así como la descripción general y especificación de cada uno de sus componentes son también parte del presente capítulo.

5.1. Justificación del sistema

La herramienta planteada se sustenta fundamentalmente en los siguientes puntos:

En estudios realizados por (Fani et al., 2019; P. Sharma & Pattanshetty, 2017; Stewart et al., 2018; Xu et al., 2018) se analiza diferentes factores de riesgos que influyen en el desarrollo de cáncer de cuello uterino, pero sin el uso necesario de las tecnologías. Dado lo anterior, el estudio de (Zahras & Rustam, 2018) diseña y utiliza una red neuronal convolucional para analizar estos factores de riesgo para determinar qué tipo de prueba realizar a un determinado paciente y poder ser de ayuda al personal médico.

En trabajos como los de (Bandyopadhyay & Nasipuri, 2020; Sompawong et al., 2019; Win et al., 2020; Xia et al., 2020) resaltan que el cáncer de cuello uterino es fácil de tratar si se es detectado en sus etapas iniciales. Para lograr ello, es necesario contar con un proceso automatizado apoyado de inteligencia artificial que logre analizar las imágenes de pruebas de Papanicolau, ya que actualmente dicho proceso es se realiza de manera manual, requiere de tiempo, experticia, alto costo y es resulta tedioso. Por consiguiente, ellos presentan distintas herramientas basadas en aprendizaje profundo y redes neuronales que sirvan de apoyo para los patólogos en el diagnóstico

de cáncer de cuello uterino. Estudios como los de (Bhuvaneshwari & Poornima, 2019; Kuko & Pourhomayoun, 2019) donde utilizan algoritmos de clustering para la segmentación de imágenes y extracción de características, son de ayuda en la etapa del procesamiento para las distintas herramientas tecnológicas revisadas en esta investigación.

Mencionado todo lo anterior, en este trabajo proponemos realizar la segmentación de las imágenes y luego realizar el diagnóstico aplicando redes neuronales convolucionales.

5.2. Modelo


Este apartado corresponde a la Fase de Modelo de la metodología de la investigación mencionada en el capítulo anterior. Esta fase comprende los puntos del dataset, preprocesamiento de las imágenes y entrenamiento del modelo.

5.2.1. Dataset


El conjunto de datos utilizados para el entrenamiento del modelo fueron imágenes de citología en base líquida de Papanicolau provenientes de un estudio realizado en 460 pacientes (Hussain, 2019). Este dataset cuenta con 963 imágenes divididas en 4 tipos de carcinoma que son detallados en la Tabla 11, además en la Figura 32 se muestran los 4 tipos: Normal (Fig. 32a), Lesión leve (Fig. 32b), Lesión grave (Fig. 32c) y Carcinoma (Fig. 32d).

Tabla 11 Cantidad de imágenes


Tipo de imagen	Total
Normal	613
Lesión leve	163
Lesión grave	113
Cáncer	74
Total	963




(a) Normal



(b) Lesión Leve



(c) Lesión Grave



(d) Cáncer

Figura 32 Ejemplo de imágenes por tipo

Para dividir el conjunto de imágenes que serán utilizados en el entrenamiento y posteriormente en la validación se hizo uso del Principio de Pareto (Fernández, n.d.), 80% de las imágenes serán utilizadas para el entrenamiento y 20% de las imágenes restante serán utilizados para la validación, tal como se aprecia en la Tabla 12.

Adicionalmente, de la cantidad de imágenes de entrenamiento, se volvió a usar el principio de Pareto: 80% de las imágenes serán utilizadas para el entrenamiento; y 20% restante, para el test.

Tabla 12 División de las imágenes para el entrenamiento y validación


Tipo de imagen	Entrenamiento	Test	Validación	Total
Normal	392	98	123	613
Lesión Leve	105	23	35	163
Lesión Grave	73	18	22	113

Cáncer	48	12	14	74
Total	618	151	194	963


5.2.2. Preprocesamiento de las imágenes

Para el preprocesamiento de las imágenes se utilizó el algoritmo de k-means, el cual es un algoritmo no supervisado, que es utilizado para la segmentación de imágenes basándose en los centroides, este algoritmo es proporcionado por la librería Sklearn, la cual es una librería de aprendizaje automático para el lenguaje de programación Python.

En la Figura 33, se puede observar la imagen Original (Fig. 33a) y la imagen Segmentada (Fig. 33b) por el algoritmo a la derecha. Para este caso de estudio el algoritmo K-means se utilizó con el valor de 3.



(a) Original



(b) Segmentada

Figura 33 Imagen original y segmentada de la prueba de Papanicolaou

5.2.3. Entrenamiento del modelo

En el entrenamiento de modelo, se decidió entrenar dos modelos de redes neuronales convolucionales, para verificar cuál tenía mejores resultados, y, a partir de esto, poder escoger el mejor para exportarlo e implementarlo al sistema, lo cual se verifica en la fase de validación.

Los modelos de CNN usados en clasificación de imágenes, tales como el VGG o LeNet, obtienen una alta precisión en sus predicciones debido a su profundidad (alta cantidad de capas). Por su contraparte, al mayor número de capas se produce el fenómeno llamado desvanecimiento de gradiente (Elgendy, 2020). Por esta razón, se decidió utilizar en este trabajo las dos arquitecturas de CNN residuales más usadas en la literatura: Resnet50 y Resnet101. Y estas tienen la particularidad de que no necesariamente todas las capas están conectadas de manera secuencial, algunas capas están asociadas a otras, saltando capas intermedias apoyándose de una función residual.

- **Modelo ResNet 50**

En el modelo se ha utilizado la arquitectura del modelo Resnet50 que ofrece la librería de tensorflow, en el cual se carga con pesos ya entrenados que ofrece Imagenet, para este caso se deshabilitó las capas totalmente conectadas que son propias del ResNet50 para la clasificación, tal como se muestra en la Figura 34, y se agregó capas adicionales para la clasificación de las imágenes, así como se puede observar en la Figura 35.




Figura 34 Arquitectura ResNet50

La Figura 35 muestra la estructura de la arquitectura elaborada para el modelo ResNet 50, modelo que consiste en las capas anteriormente mencionadas, propias del ResNet 50, y que,

adicionalmente, se añadirán las propias para mejorar los resultados del entrenamiento. En primer lugar, se ha agregado una capa Flatten, la cual ayudará a redimensionar las capas llevándolas a una sola (aplanar). Posteriormente se agregarán 3 capas Dense con función de activación “ReLU” y 3 capas Gaussian Noise que serán utilizadas para mitigar el sobreajuste (una forma de aumento de datos aleatorios). Finalmente, se añadirá una capa Dense con función de activación “softmax” para la clasificación de imágenes.

La primera capa dense recibe como entrada un espacio con dimensionalidad 163840 y como salida da un espacio con dimensionalidad 2048, la segunda capa dense da como salida una dimensionalidad 512, la tercera capa dense con una salida de dimensionalidad 128, y la última capa dense una salida con dimensionalidad 4, ya que se tienen 4 clases de imágenes.

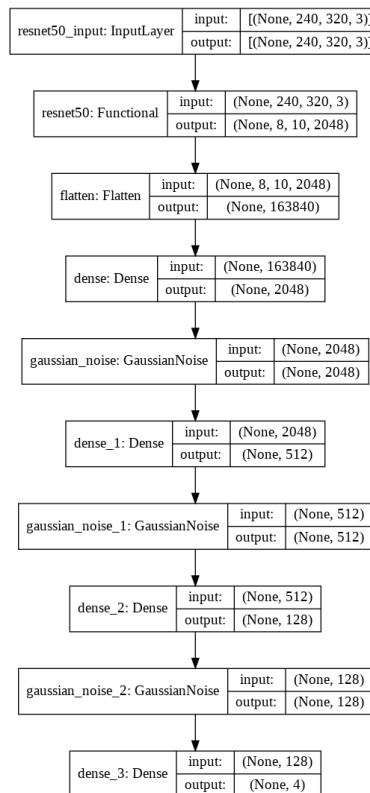


Figura 35 Arquitectura del modelo utilizando ResNet50

En cuanto a la compilación del modelo, se utilizaron argumentos que serán mencionados a continuación. En primer lugar, el Optimizador, configurado con un “RMSprop (learning_rate=1e-4)”. Adicionalmente, la Función de pérdida, configurada con “categorical_crossentropy”. Finalmente, la Métrica dada como “accuracy”.

En la Tabla 13, se prosigue a explicar el código que se ha utilizado para ambos modelos, solo se realiza la modificación en la línea con respecto al modelo que se utiliza.

En la línea 0, se obtiene la data con base en una función propia encargada de procesar las imágenes de papanicolau. Esta data será usada, posteriormente, en el entrenamiento (línea 14). En la línea 1 se procede a instanciar la variable resnet con el Modelo pre entrenado ResNet50, con los pesos de imagenet, se desactivó las capas totalmente conectadas. A partir de la línea 2 hasta la 12, se construye el modelo donde se le añade la arquitectura ResNet50, y capas adicionales para la clasificación de las imágenes. En la línea 13, se realiza la compilación del modelo, con los siguientes parámetros el optimizador, configurado con un “RMSprop (learning_rate=1e-4)”, la función de pérdida, configurada con “categorical_crossentropy” y la métrica con “accuracy”. Por último, en la línea 14, se realiza el entrenamiento, con los parámetros que es el tamaño del Batch, definido con una cantidad de 32 y el número de Épocas dado como 100.

Tabla 13 División de las imágenes para el entrenamiento y validación

Línea	Código
0	x_train, y_train = get_data(train_dir)
1	resnet = ResNet50(weights='imagenet',include_top=False, input_shape=(240,320,3))
2	model = Sequential()
3	model.add(resnet)
4	model.add(layers.Flatten())
5	model.add(layers.Dense(2048, activation='relu'))
6	model.add(layers.GaussianNoise(0.2))
7	model.add(layers.Dense(512, activation='relu'))
8	model.add(layers.GaussianNoise(0.2))

```

9     model.add(layers.Dense(128, activation='relu' ))
10    model.add(layers.GaussianNoise(0.2))
11    model.add(layers.Dense(4, activation='softmax'))
12    model.summary()
13    model.compile(optimizer=RMSprop(learning_rate=1e-4), loss='categorical_crossentropy',
14                  metrics=['accuracy'])
14    history = model.fit(x_train, y_train, batch_size = 32, validation_data = (x_val, y_val), epochs =
15                      100, verbose = 1)

```

En la Figura 36, se puede visualizar los resultados de la exactitud que se obtuvo luego del entrenamiento del modelo, y su respectiva prueba. Se obtuvo una exactitud promedio del 100% de exactitud en el entrenamiento, pero en el caso de la validación se obtuvo la mayor exactitud de 91%, lo cual es inferior, pero es buen resultado, además, se puede observar, en la Figura 36, que a partir de la época 71 se tiene una uniformidad en el entrenamiento.




Figura 36 Exactitud del entrenamiento y validación del modelo utilizando ResNet50

En la Figura 37, se observa la pérdida que se obtuvo durante el entrenamiento y la prueba del modelo. En la Figura 37, la pérdida en el entrenamiento fue descendiendo durante el avance de las épocas, se tiene una pérdida de 0, y, en el caso de la validación, la pérdida también tuvo picos

altos, pero, a partir de época 30, fue descendiendo considerablemente, y así se mantuvo hasta la época 100, la cual varía entre 1.5 a 2.




Figura 37 Pérdida del entrenamiento y validación del modelo utilizando ResNet50

- **Modelo ResNet 101**

En el modelo se ha utilizado la arquitectura del modelo ResNet 101 que ofrece la librería de tensorflow, en el cual se carga con pesos ya entrenados que ofrece, pero, en esta arquitectura, solo se habilitó para el entrenamiento la capa 10. Además de que se deshabilitaron las capas totalmente conectadas que son propias del Resnet 101 para la clasificación, tal como se muestra en la Figura 38, es por lo que se agregó capas adicionales para la clasificación de las imágenes, así como se puede visualizar en la Figura 39.




Figura 38 Arquitectura ResNet101

La Figura 39 muestra la estructura de la arquitectura elaborada para el modelo ResNet 101, modelo que consiste en las capas anteriormente mencionadas, propias del ResNet 101, y que adicionalmente se añadirán las nuestras propias para mejorar los resultados del entrenamiento. En primer lugar, se ha agregado una capa Flatten, la cual ayudará a redimensionar las capas llevándolas a una sola (aplanar). Posteriormente se agregarán 3 capas Dense con función de activación “ReLU” y 3 capas Gaussian Noise que serán utilizadas para mitigar el sobreajuste (una forma de aumento de datos aleatorios). Finalmente se añadirá una capa Dense con función de activación “softmax” para la clasificación de imágenes.




Figura 39 Arquitectura del modelo utilizando ResNet101

En cuanto a la compilación del modelo, se utilizaron argumentos que serán mencionados a continuación. En primer lugar, el Optimizador, configurado con un “RMSprop (learning_rate=1e-4)”. Adicionalmente, la Función de pérdida, configurada con “categorical_crossentropy”. Finalmente, la Métrica dada como “accuracy”.

Para el entrenamiento, también se utilizaron algunos argumentos adicionales, tales como el tamaño del Batch, definido con una cantidad de 32. El número de Épocas dado como 100.

En la Figura 40, se puede visualizar los resultados de la exactitud que se obtuvo luego del entrenamiento del modelo, y su respectiva prueba. Se obtuvo una exactitud del 100% de exactitud en el entrenamiento, pero, en el caso de la prueba, la mayor exactitud obtenida fue de 89.93%.

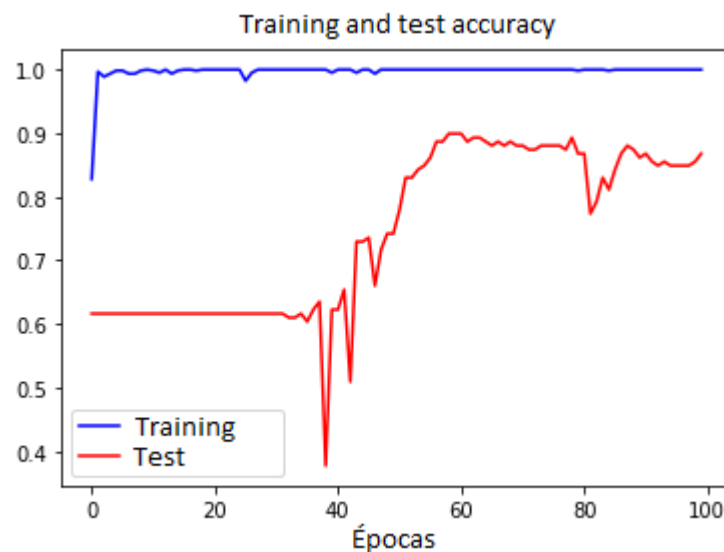


Figura 40 Exactitud del entrenamiento y validación del modelo utilizando ResNet101

En la Figura 41, se observa la pérdida que se obtuvo durante el entrenamiento y la prueba durante el entrenamiento del modelo. En la Figura 41, la pérdida en el entrenamiento fue descendiendo durante el avance de las épocas, donde se tiene una pérdida de 0, y en el caso de la prueba también la pérdida fue descendiendo, y durante las épocas se fue estabilizando.

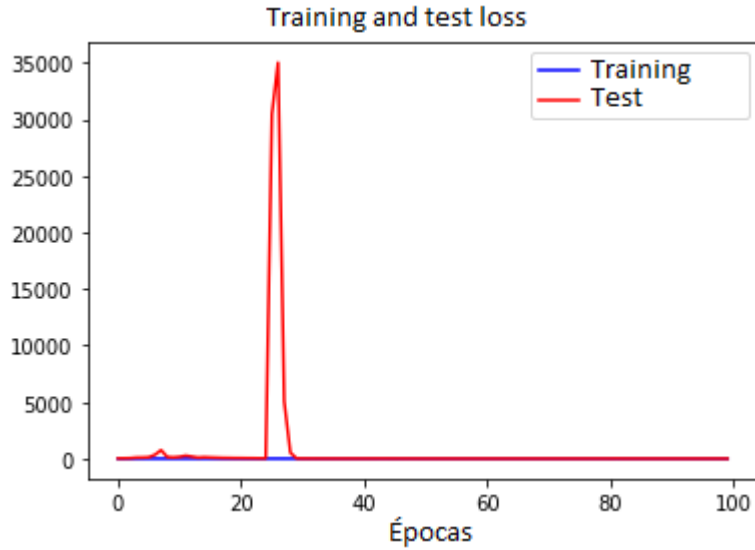


Figura 41 Pérdida del entrenamiento y validación del modelo utilizando ResNet101

5.3. Desarrollo del sistema

Esta fase representa el desarrollo del sistema, en el cual se realizó el diseño del sistema, la implementación del modelo, y el uso del sistema. El desarrollo del sistema se realizó bajo una metodología ágil.

5.3.1. Diseño del sistema

Para el diseño del sistema se realizó el documento de requerimientos que se explica en mayor detalle en el Apéndice A, en la Tabla 14, se muestran los módulos del sistema con sus respectivos requerimientos.

Tabla 14 Tabla de módulos con sus requerimientos

Módulo	Requisitos
Módulo diagnóstico	Cargar una imagen Segmentar la imagen Clasificación Mostrar Diagnóstico Consultar Historial de pacientes
Módulo gestión	Registrar paciente Registrar usuario Modificar usuario

En este apartado se muestra la arquitectura del sistema, así como se observa en la Figura 42.

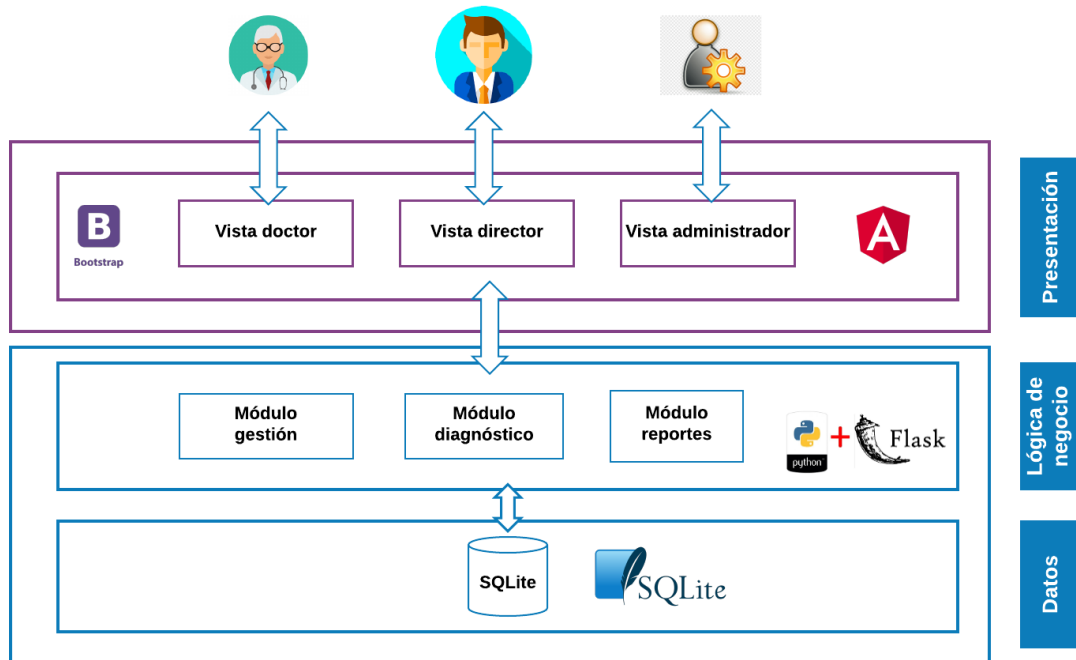


Figura 42 Detalle de la arquitectura

Detalle de Capas

a. **Presentación:** Es la capa que se encarga de la interacción del usuario con el sistema, la cual está desarrollada en angular y bootstrap, y está alojada en heroku.

b. **Lógica de negocio:** Es la capa que se encarga del core del sistema que está desarrollado con el framework flask, la cual consta de módulo gestión, módulo diagnóstico, módulo reportes.

- **Módulo gestión:** Se realiza la gestión de los usuarios, el registro, modificación, así como también el soporte de las acciones por el rol de cada usuario, que en este caso son doctor, administrador y director. Además, se realiza el registro de los pacientes.

- Módulo diagnóstico: Se realiza el diagnóstico de cáncer de cuello uterino, en el cual se hace uso del modelo de RNC, previamente entrenado.

- Módulo reportes: Se pueden ver los gráficos históricos de los diagnósticos realizados.

c. Datos: Es la capa que se encarga de guardar los datos, en un sistema gestor de base de datos que es SQLite.

5.3.2. Implementación del modelo

Para la implementación del sistema experto se exportó el modelo que se obtuvo del entrenamiento, en la Figura 43, se muestra la integración del modelo entrenado junto al sistema, el cual consta de una interfaz de usuario, y de los módulos de diagnóstico, gestión y reportes.

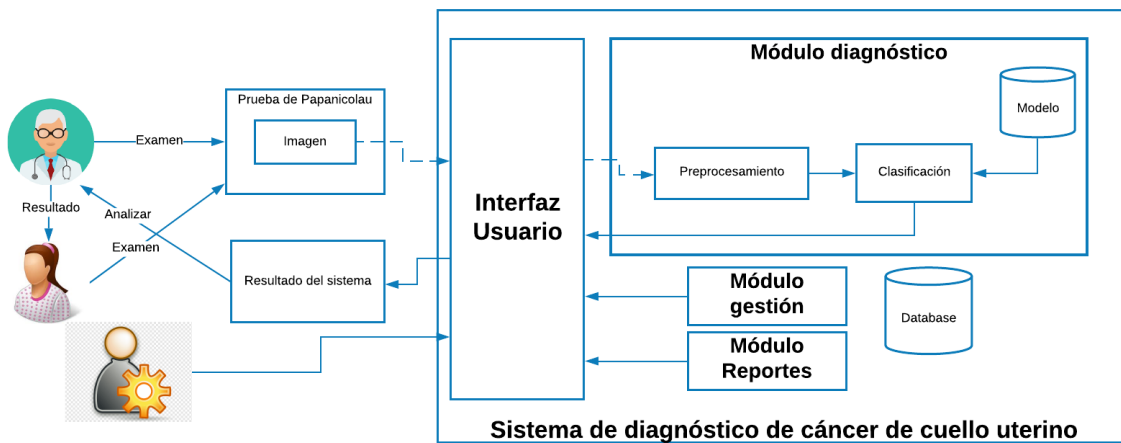


Figura 43 Descripción del sistema

5.3.3. Uso del sistema

El sistema cuenta con un apartado de Inicio de Sesión, tal como se observa en la Figura 44. Aquí el usuario de tipo Admin o Doctor ingresará sus credenciales. Acorde al tipo de usuario se le concederán ciertas opciones.

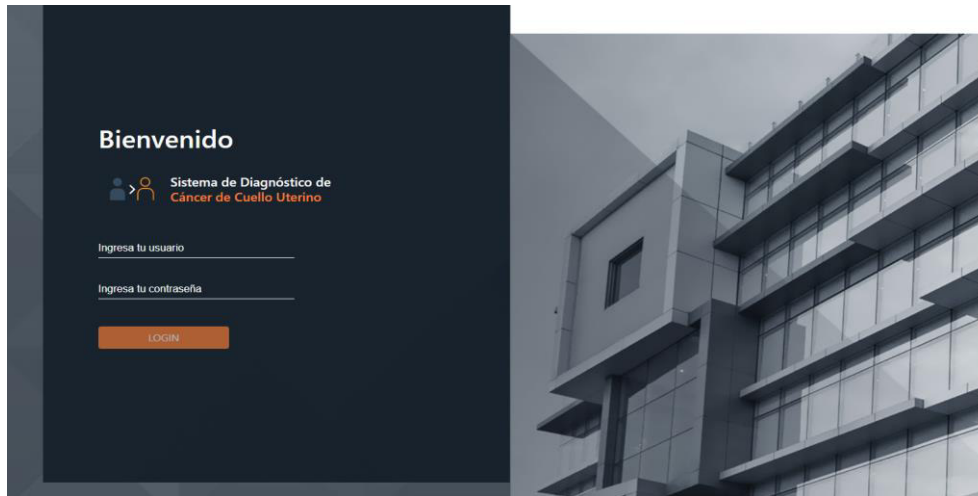


Figura 44 Login del sistema

Si el usuario es de tipo Doctor, podrá tener a su disposición el apartado de Diagnóstico, tal como se observa en la Figura 45. El doctor ingresará el código del paciente y la imagen de prueba de papanicolaou correspondiente. El sistema determinará, con base a un modelo entrenado, si la imagen corresponde a un diagnóstico Normal o Anormal.




Figura 45 Módulo diagnóstico

Adicionalmente, el Doctor tendrá acceso al historial del paciente. Tal como se observa en la Figura 46, el doctor puede visualizar las veces que se han realizado las pruebas a determinado paciente. Basta con introducir su código.

The screenshot shows a web application interface for a cervical cancer diagnostic system. The header includes the system name and the user role 'Doctor'. A sidebar menu on the left contains 'Diagnóstico' and 'Historial'. The main content area is titled 'Historial del paciente' and contains a search form with the text 'Ingrese el código del paciente:' and a text input field containing '001'. Below the search field is a 'Consultar' button. The patient's name 'Manuela Paredes' and birth date '2007-01-01' are displayed. A table below shows the consultation history with the following data:

#	Fecha de consulta	Doctor a cargo	Resultado de la consulta
0	2020-06-22	Administrador	Anormal
1	2020-06-22	Administrador	Anormal
2	2020-06-23	Administrador	Anormal
3	2020-06-23	Administrador	Normal
4	2020-06-23	Doctor	Anormal

Figura 46 Historial de pacientes

Si el tipo de usuario es Admin, este tendrá otras opciones en el apartado izquierdo. Dentro de ella se encuentra Gestionar Paciente, tal como se observa en la Figura 47. Los pacientes serán visualizados, creados y almacenados en la BD para su posterior interacción.

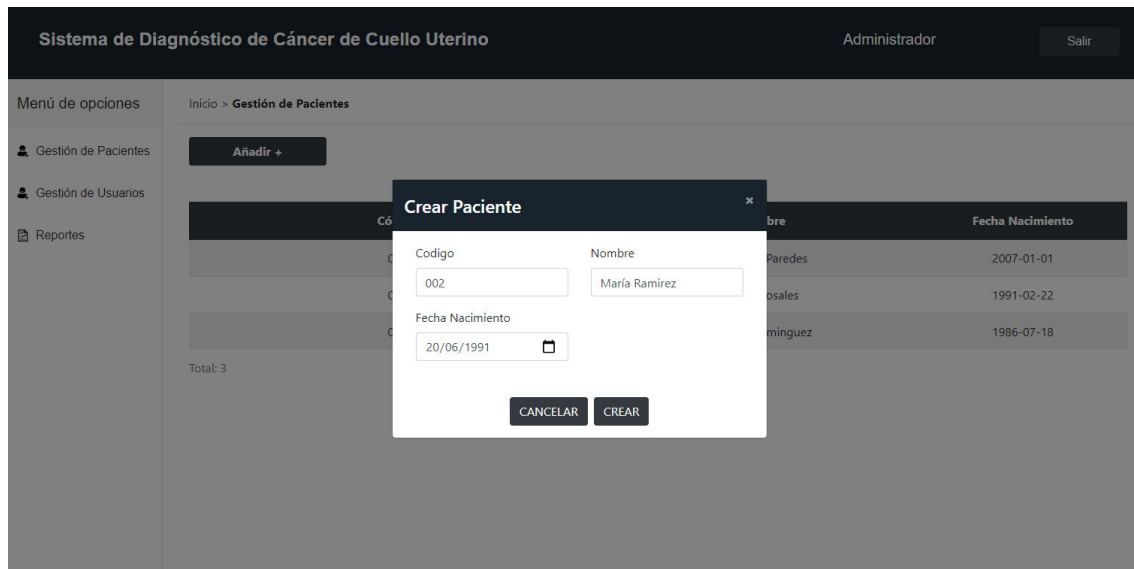


Figura 47 Crear Paciente

También el Admin podrá Gestionar Usuarios. Tal como se aprecia en la Figura 48, el Admin visualizará, creará y editará los usuarios del sistema.

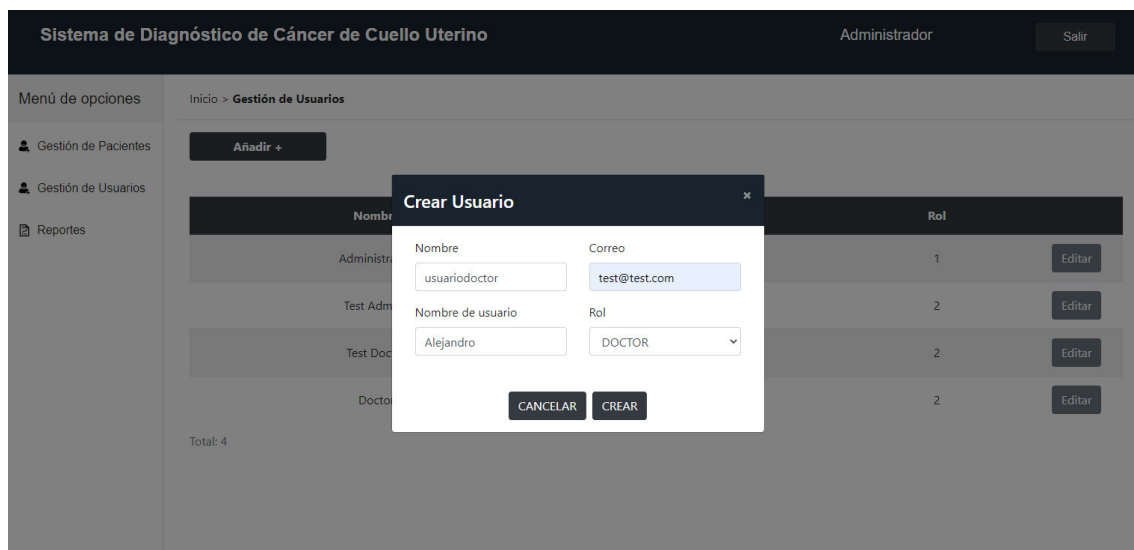


Figura 48 Crear Usuario

Además, el Admin podrá visualizar un apartado de reportes, en donde se apreciará las cantidades de resultados obtenidos por mes en cada año, tal como se muestra en la Figura 49.

Menú de opciones

Gestión de Pacientes

Gestión de Usuarios

Reportes

Ingrese año:

Consultar




Figura 49 Módulo reportes

Capítulo VI: Caso de estudio

En este capítulo se describe nuestra población, muestra y unidad de análisis seleccionada para el trabajo de investigación a diferentes casos de estudio mostrando los resultados obtenidos.

6.1. Población y muestra

Para la población del siguiente estudio, se considera el dataset obtenido de (Hussain, 2019), en su artículo *Liquid based cytology pap smear images for multi-class diagnosis of cervical cancer* y las imágenes brindadas por el Instituto Nacional de Enfermedades Neoplásicas de pruebas de Papanicolaou. En la muestra, se consideran 194 imágenes del dataset y 8 imágenes del instituto nacional de enfermedades neoplasicas de pruebas de Papanicolaou. Como unidad de análisis, se está considerando una imagen obtenida por medio de la prueba de Papanicolaou.

6.2. Validación del sistema

En primera instancia, se realizará la validación de los modelos utilizados en esta investigación. El diagrama de flujo del proceso de esta validación que se usará en el presente trabajo se muestra en la Figura 50.

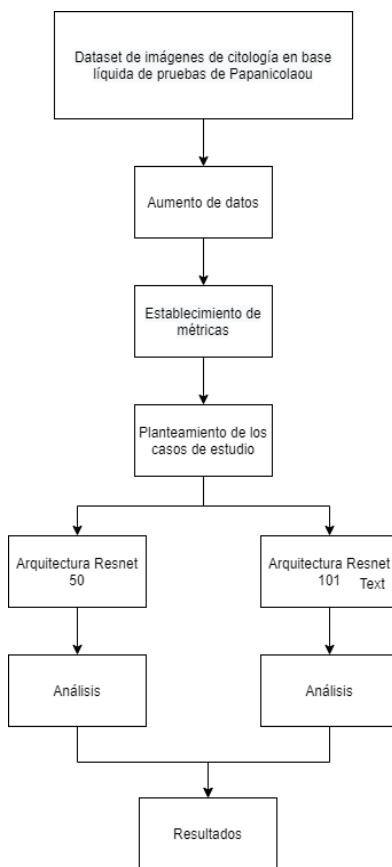


Figura 50 *Proceso de validación.*

En la Tabla 15, se muestra el número de imágenes con el cual se va a realizar la validación del modelo.

Tabla 15 *Número de imágenes por tipo de clasificación*

Categoría	Total
Normal	123
Lesión leve	22
Lesión Grave	35
Cáncer	14

Por otro lado, para la validación del sistema, se utilizarán 8 imágenes de citología en base líquida de Papanicolau de pacientes de un instituto enfermedades neoplásicas, de las cuales 2 imágenes corresponden a lesiones leves y 6 a lesiones graves.

6.3. Métricas

Acorde con (Tharwat, 2018), para la evaluación de los modelos pre-entrenados aplicados, se tomará en cuenta las siguientes métricas que se pueden apreciar en la Tabla 16, que refleja la matriz de confusión.

Tabla 16 Matriz de confusión

		Predicción	
		Positive	Negative
Real	Positivo	Verdadero positivo	Falso negativo
	Negativo	Falso positivo	Verdadero negativo

Precisión: Es el número de resultados correctamente clasificados dividido entre el número de resultados positivos predichos en la clasificación.

$$Precision = \frac{Verdadero\ positivo}{Verdadero\ positivo + Falso\ positivo} \quad (1)$$

Recall: Es el número de resultados correctamente clasificados divididos entre el número de todas las muestras que debieron haber sido clasificadas como positivas.

$$Recall = \frac{Verdadero\ positivo}{Verdadero\ positivo + Falso\ negativo} \quad (2)$$

Exactitud: Es la relación entre el número de predicciones correctas y el número total de muestras dadas. Esto funciona bien solo si hay un mismo número de muestras pertenecientes para cada categoría.

$$Exactitud = \frac{Número\ de\ predicciones\ correctas}{Total\ de\ predicciones} \quad (3)$$

F1 Score: Es la media armónica entre la Precisión y el Recall, el cual nos dice que tan preciso es el clasificador, así como cuán robusto es.

$$F1 = 2 * \frac{precision*recall}{precision+recall} \quad (4)$$

6.4. Resultados

6.4.1. Validación del modelo

- **ResNet 50**

Para este caso de estudio, se considerará también el dataset de base líquida (LBC) divididas en cuatro conjuntos de imágenes. Se aplicará el modelo CNN pre-entrenado ResNet 50, los resultados de la matriz de confusión se dan en la Tabla 17.

Tabla 16 Matriz de confusión del modelo ResNet50

		Predicciones			
		Normal	Lesión leve	Lesión grave	Cáncer
Real	Normal	123	0	0	0
	Lesión leve	0	22	0	0
	Lesión grave	2	0	29	4
	Cáncer	0	0	11	3

- Precisión

Tabla 178 Resultados de la precisión del modelo ResNet 50

Clasificación	Verdadero Positivo	Falso Positivo	Precisión
Normal	123	2	0.98
Lesión leve	22	0	1.00
Lesión grave	29	11	0.72
Cáncer	3	4	0.43

Con base en los datos obtenidos y aplicando la fórmula 1, se obtiene como resultado que existe una mayor precisión para la categoría Normal y Lesión Leve. Caso contrario ocurre con la categoría Cáncer, dado que se obtiene una precisión de 0.43, notándose así que existe una pobre clasificación en este.

- Recall

Tabla 18 Resultados de Recall del modelo ResNet 50

Clasificación	Verdadero Positivo	Falso Negativo	Recall
Normal	123	0	1.00
Lesión leve	22	0	1.00
Lesión grave	29	6	0.83
Cáncer	3	11	0.21

Con base en los datos obtenidos y aplicando la fórmula (2), se obtiene como resultado que existe un mayor recall para la categoría Normal y Lesión Leve. Caso contrario ocurre con la categoría Cáncer, dado que se obtiene un recall de 0.21, notándose así que existe una pobre clasificación en este.

- Exactitud

Tabla 19 Predicciones correctas e incorrectas del modelo ResNet 50

Clasificación	Predicciones Correctas	Predicciones Incorrectas	Total
Normal	123	0	123
Lesión leve	22	0	22
Lesión grave	29	6	35
Cáncer	3	11	14
Total	177	17	194

Dado los siguientes datos y aplicando la fórmula (3) como $177 / 194$, se obtiene una exactitud de 0.91, lo cual es un buen resultado, pero no demuestra que el modelo sea tan robusto y exacto, ya que el número de muestras no es la misma para cada categoría.

- F1 Score

Tabla 20 Resultados de F1 Score del modelo ResNet 50

Clasificación	Precisión	Recall	F1 Score
Normal	0.98	1.00	0.99
Lesión leve	1.00	1.00	1.00
Lesión grave	0.72	0.83	0.77
Cáncer	0.43	0.21	0.29

Con base en los datos obtenidos y aplicando la fórmula (4), se obtiene como resultado que existe un mayor F1 Score para la categoría Normal y Lesión Leve. Caso contrario ocurre con la categoría Cáncer, dado que se obtiene un F1 Score de 0.29, notándose así que existe una pobre clasificación en este.

Además, se puede notar que el modelo es preciso y robusto en la clasificación de las categorías de Normal, Lesión leve y Lesión Grave, y en el caso de la categoría de Cáncer, el modelo no obtiene buenos resultados, pero esto mejoraría si se tuviera una mayor cantidad de imágenes para esta categoría.

- **ResNet 101**

Para este caso de estudio se considerará también el dataset de base líquida (LBC) divididas en cuatro conjuntos de imágenes. Se aplicará el modelo CNN pre-entrenado ResNet 101.

Tabla 21 Matriz de confusión del modelo ResNet 101

		Predicciones			
		Normal	Lesión leve	Lesión grave	Cáncer
Real	Normal	121	0	2	0
	Lesión leve	0	22	0	0
	Lesión grave	5	0	24	6
	Cáncer	1	0	8	5

- Precisión

Tabla 22 Resultados de la precisión del modelo ResNet 101

Clasificación	Verdadero Positivo	Falso Positivo	Precisión
Normal	121	6	0.95
Lesión leve	22	0	1.00
Lesión grave	24	10	0.71
Cáncer	5	6	0.45

Con base en los datos obtenidos y aplicando la fórmula 1, se obtiene como resultado que existe una mayor precisión para la categoría Lesión leve. Caso contrario ocurre con la categoría Cáncer, dado que se obtiene una precisión de 0.45.

- Recall:

Tabla 23 Resultados del Recall del modelo ResNet 101

Clasificación	Verdadero Positivo	Falso Negativo	Recall
Normal	121	2	0.98
Lesión leve	22	0	1.00
Lesión grave	24	11	0.69
Cáncer	5	9	0.36

Con base en los datos obtenidos y aplicando la fórmula (2), se obtiene como resultado que existe un mayor recall para la categoría Lesión leve. Caso contrario ocurre con la categoría Cáncer, dado que se obtiene un recall de 0.36.

- Exactitud

Tabla 24 Resultados de las predicciones correctas e incorrectas del modelo ResNet 101

Clasificación	Predicciones Correctas	Predicciones Incorrectas	Total
Normal	121	2	123
Lesión leve	22	0	22
Lesión grave	24	11	35
Cáncer	5	9	14
Total	172	22	194

Dado los siguientes datos y aplicando la fórmula (3) como $172/194$, se obtiene una exactitud de 0.89, lo cual es un buen resultado, pero no demuestra que el modelo sea tan robusto y exacto, ya que el número de muestras no es la misma para cada categoría.

- F1 Score:

Tabla 25 Resultados de F1 Score del modelo ResNet 101

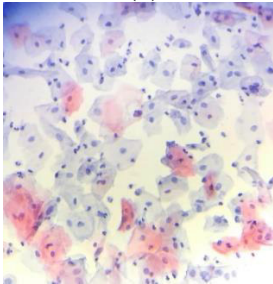
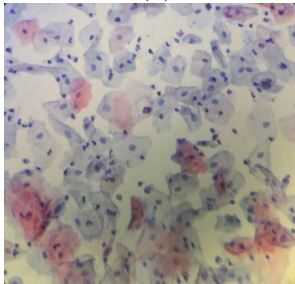
Clasificación	Precisión	Recall	F1 Score
Normal	0.95	0.98	0.97
Lesión leve	1.00	1.00	1.00
Lesión grave	0.71	0.69	0.70
Cáncer	0.45	0.36	0.40


Con base en los datos obtenidos y aplicando la fórmula (4), se obtiene como resultado que existe un mayor F1 Score para la categoría Lesión leve. Caso contrario ocurre con la categoría Cáncer, dado que se obtiene un F1 Score de 0.40, notándose así que existe una muy pobre clasificación en este.

6.4.2. Validación del sistema

Para la validación del sistema, se hará uso de las imágenes brindadas por el Instituto Nacional de Enfermedades Neoplásicas (INEN). En la Tabla 28, se puede observar imágenes que corresponden al tipo de Lesión Leve y Lesión Grave.

Tabla 26 Imágenes del INEN

Clasificación	Precisión	
	(1)	(2)
Lesión leve		



- **ResNet 50**

Para este caso de estudio, se consideran las imágenes proporcionadas por el INEN. En el sistema propuesto se hará uso del modelo CNN pre-entrenado ResNet 50.

En la Figura 51, se puede apreciar que el sistema clasificó la imagen (1) de lesión leve de la Tabla 27 como lesión grave.



Figura 51 Primera imagen de lesión leve de la Tabla 27

En la Figura 52, se puede apreciar que el sistema clasificó la imagen (2) de lesión leve de la Tabla 27 como normal.




Figura 52 Segunda imagen de lesión leve de la Tabla 27

En la Figura 53, se puede apreciar que el sistema clasificó la imagen (1) de lesión grave de la Tabla 27 como lesión grave.




Figura 53 Primera imagen de lesión grave de la Tabla 27

En la Figura 54, se puede apreciar que el sistema clasificó la imagen (2) de lesión grave de la Tabla 27 como lesión grave.




Figura 54 Segunda imagen de lesión grave de la Tabla 27

En la Figura 55, se puede apreciar que el sistema clasificó la imagen (3) de lesión grave de la Tabla 27 como lesión grave.




Figura 55 Tercera imagen de lesión grave de la Tabla 27

En la Figura 56, se puede apreciar que el sistema clasificó la imagen (4) de lesión grave de la Tabla 27 como normal.

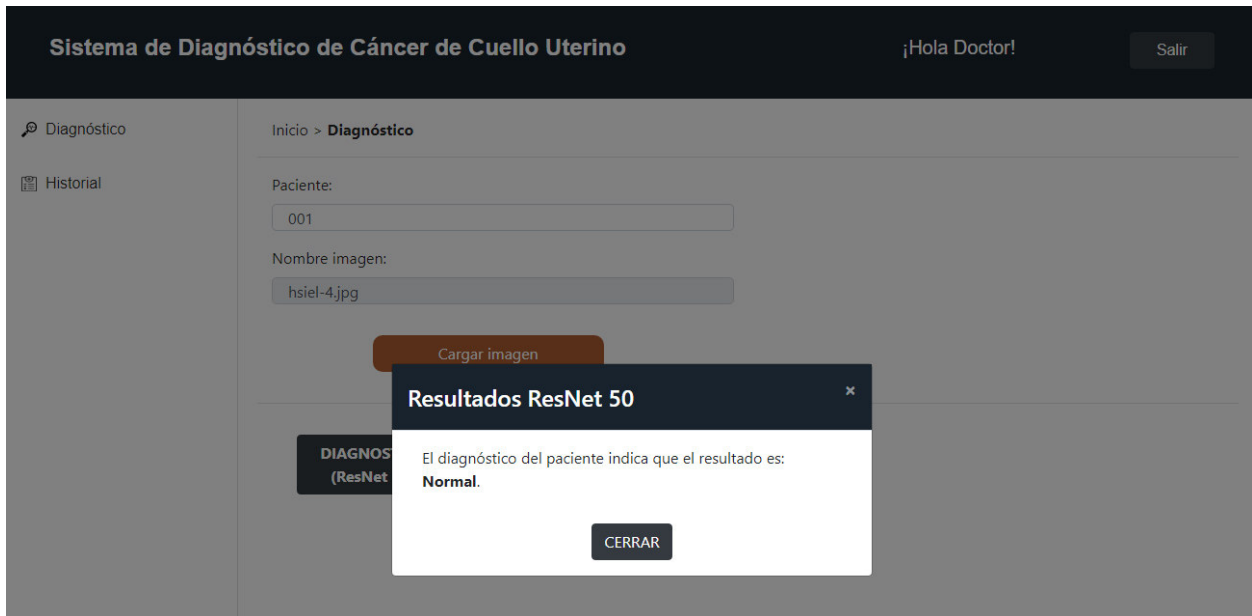


Figura 56 Cuarta imagen de lesión grave de la Tabla 27

En la Figura 57, se puede apreciar que el sistema clasificó la imagen (5) de lesión grave de la Tabla 27 como lesión grave.




Figura 57 Quinta imagen de lesión grave de la Tabla 27

En la Figura 58, se puede apreciar que el sistema clasificó la imagen (6) de lesión grave de la Tabla 27 como lesión grave.




Figura 58 Sexta imagen de lesión grave de la Tabla 27

- **ResNet 101**

Para este caso de estudio se consideran las imágenes proporcionadas por el INEN. En el sistema propuesto, se hará uso del modelo CNN pre-entrenado ResNet 101.

En la Figura 59, se puede apreciar que el sistema clasificó la imagen (1) de lesión leve de la Tabla 27 como lesión grave.

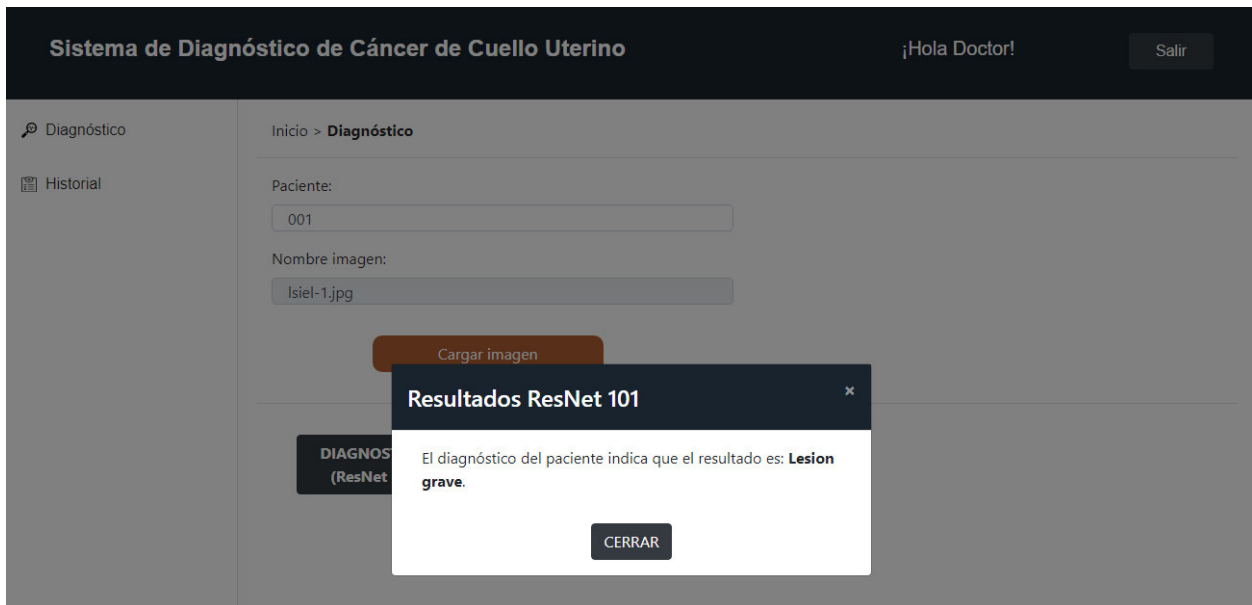


Figura 59 Primera imagen de lesión leve de la Tabla 27

En la Figura 60, se puede apreciar que el sistema clasificó la imagen (2) de lesión leve de la Tabla 27 como lesión grave.




Figura 60 Segunda imagen de lesión leve de la Tabla 27

En la Figura 61, se puede apreciar que el sistema clasificó la imagen (1) de lesión grave de la Tabla 27 como normal.




Figura 61 Primera imagen de lesión grave de la Tabla 27

En la Figura 62, se puede apreciar que el sistema clasificó la imagen (2) de lesión grave de la Tabla 27 como lesión grave.




Figura 62 Segunda imagen de lesión grave de la Tabla 27

En la Figura 63, se puede apreciar que el sistema clasificó la imagen (1) de lesión grave de la Tabla 27 como lesión grave.




Figura 63 Tercera imagen de lesión grave de la Tabla 27

En la Figura 64, se puede apreciar que el sistema clasificó la imagen (4) de lesión grave de la Tabla 27 como normal.




Figura 64 Cuarta imagen de lesión grave de la Tabla 27

En la Figura 65, se puede apreciar que el sistema clasificó la imagen (5) de lesión grave de la Tabla 27 como normal.




Figura 65 Quinta imagen de lesión grave de la Tabla 27

En la Figura 66, se puede apreciar que el sistema clasificó la imagen (6) de lesión grave de la Tabla 27 como normal.




Figura 66 Sexta imagen de lesión grave de la Tabla 27

6.5. Análisis de los resultados

A continuación, se realizará una comparación entre ambas arquitecturas. Para ello, se tendrá en cuenta en el análisis previamente realizado, donde se puede destacar las dos métricas anteriormente mencionadas: Exactitud y F1 Score.

Resnet-50 vs Resnet-101

La exactitud ayuda a identificar la relación existente entre el número de predicciones correctas y el número total de muestras dadas. La tabla 28 muestra los resultados obtenidos en ambas arquitecturas, en la cual se puede observar que el modelo basado en ResNet50 obtiene el mejor resultado.

Tabla 27 Exactitud de los modelos ResNet 50 y ResNet 101

Arquitectura	Exactitud
Resnet-50	0.91
Resnet-101	0.89

El F1 Score sirve de indicador para saber cuán preciso y robusto es el clasificador. la tabla X muestra los resultados obtenidos en cada una de las clasificaciones frente a ambas arquitecturas, en la cual se puede observar, en la Tabla 29, que el modelo pre-entrenado Resnet-50 arroja mejores resultados.

Tabla 29 Comparación del F1 Score del modelo ResNet 50 y ResNet 101

Arquitectura	Clasificación	Precisión	Recall	F1Score
Resnet-50	Normal	0.98	1.00	0.99
	Lesión leve	1.00	1.00	1.00
	Lesión grave	0.72	0.83	0.77
	Cáncer	0.43	0.21	0.29
Resnet-101	Normal	0.95	0.98	0.97

Lesión leve	1.00	1.00	1.00
Lesión grave	0.71	0.69	0.70
Cáncer	0.45	0.36	0.40

Evaluando el F1 Score, se puede notar que ambos modelos son robustos en las clasificaciones de Normal, Lesión Leve y Lesión Grave, ya que tienen un F1 Score mayor a 0.70, pero, en la clase Cáncer tienen una baja robustez, pero el modelo de ResNet101 sobresale con un F1 Score de 0.40 sobre el 0.29 del modelo ResNet50.

En cuanto a la precisión para ambos modelos los resultados son similares, por tanto, se tiene una diferencia notable, y, en cuanto al Recall, se puede notar que en la clase Lesión Grave el modelo ResNet50 supera en buena medida al modelo ResNet101, pero ocurre lo contrario con la clase Cáncer, aunque la diferencia con esta clase no es tan significativa.

Adicionalmente, se puede mencionar que las imágenes brindadas por el instituto de enfermedades neoplásicas, pese a solo contar con las categorías de Lesion Leve y Lesion Grave, pueden ser diagnosticadas y brindar el estado actual del paciente. Con el apoyo del ResNet50, se logra tener una exactitud del 0.63, pese a las limitaciones que se tienen en cuanto a la cantidad y calidad de imagen. Estos resultados pueden acrecentar si se cuenta con la cantidad y calidad de imágenes adecuadas.

Capítulo VII: Conclusiones y trabajos futuros

7.1. Conclusiones

7.1.1. Conclusión general

En la presente investigación, se desarrolló un sistema de diagnóstico de cáncer de cuello uterino, donde se utilizó dos modelos de redes neuronales convolucionales: ResNet50 y ResNet101, del que se obtuvo una clasificación de cuatro tipos de las imágenes de citología en base líquida de pruebas de Papanicolau, en que el modelo ResNet50 obtuvo una mejor exactitud. La metodología de investigación estuvo compuesta por 4 fases: (i) Planteamiento de la pregunta de investigación; (ii) Diseño del modelo, (iii) Desarrollo del sistema experto y (iv) Validación de la propuesta.

7.1.2. Conclusiones específicas

- ***OE1: Analizar diversos trabajos de investigación que están relacionados a los factores de riesgo, medidas de prevención y técnicas de diagnóstico con IA de cáncer de cuello uterino.***

Se analizó 25 trabajos de investigación, de los cuales 5 se refieren a los factores de riesgo, 5 pertenecen a las medidas de prevención y 15 relacionados en las técnicas de diagnóstico con IA de cáncer de cuello uterino. Se observó que las técnicas de detección presentadas se complementan, como lo observamos en las técnicas de algoritmo de agrupamiento, clasificación y aprendizaje profundo, que son técnicas de machine learning. Recomendamos que se fomente mayor estudio en estas técnicas ya que está en constante actualización, por ende, ayudan a los expertos en la detección del CCU.

- ***OE2: Diseñar el algoritmo basado en redes neuronales convolucionales para el diagnóstico de cáncer de cuello uterino.***

Se diseñó y entrenó dos modelos de redes neuronales convolucionales utilizando el 80% del dataset de imágenes de citología en base líquida de pruebas de Papanicolau (Hussain, 2019), el primero basado en el modelo ResNet50 y el segundo en el ResNet101, de los cuales el que obtuvo mejores resultados en la fase de validación fue el modelo ResNet50, con una exactitud del 91%. Este modelo se implementó y utilizó de forma final en el sistema inteligente. Adicionalmente, notamos que el modelo ResNet101 también tuvo buenos resultados con una exactitud de 89%.

- ***OE3: Diseñar el sistema inteligente que sirva de apoyo para el diagnóstico de cáncer de cuello uterino.***

Se diseñó e implementó el sistema inteligente para el apoyo de los expertos en la detección de cáncer de cuello uterino, que cuenta con 3 módulos para gestionar, diagnosticar y ver reportes de los diagnósticos realizados. Se utilizó el modelo basado en ResNet50 para el módulo diagnóstico.

- ***OE4: Definir un caso de estudio para corroborar la validez del sistema para el diagnóstico de cáncer de cuello uterino.***

Se definieron dos casos de estudio, en el primer caso de estudio se utilizó el 20% del dataset de imágenes de citología en base líquida de pruebas de Papanicolau (Hussain, 2019), y en el segundo caso se utilizó 8 imágenes brindadas por un instituto de enfermedades neoplásicas, dividido en 2 clasificaciones que son lesión leve y lesión grave, estos caso de estudio se validaron con las siguientes métricas (Tharwat, 2018): precisión, exactitud, recall y f1-score estos dos últimos con mayor importancia ya que definen que nuestro modelo basado en ResNet50 con el mejor resultado es robusto.

7.2. Trabajos futuros

Como futuro trabajo se recomienda implementar el sistema propuesto con un dataset de un hospital local, además este dataset debe tener una cantidad considerable de imágenes para que el modelo pueda ser entrenado de manera eficiente y se mejoren los resultados, cabe resaltar que se debe tener la misma cantidad de imágenes para todos los tipos de clasificación que se desea tener.

Referencias

- Almazrou, S., Saddik, B., & Jradi, H. (2019). Knowledge, attitudes, and practices of Saudi physicians regarding cervical cancer and the human papilloma virus vaccine. *Journal of Infection and Public Health*, 13(4), 584–590. <https://doi.org/10.1016/j.jiph.2019.09.002>
- Bandyopadhyay, H., & Nasipuri, M. (2020). Segmentation of Pap Smear Images for Cervical Cancer Detection. *2020 IEEE Calcutta Conference, CALCON 2020 - Proceedings*, 30–33. <https://doi.org/10.1109/CALCON49167.2020.9106484>
- Basak, H., Kundu, R., Chakraborty, S., & Das, N. (2021). Cervical Cytology Classification Using PCA and GWO Enhanced Deep Features Selection. *SN Computer Science*, 2(5). <https://doi.org/10.1007/s42979-021-00741-2>
- Bhuvaneshwari, K. V., & Poornima, B. (2019). Cervical cancer cell identification & detection using fuzzy C mean and K nearest neighbor techniques. *International Journal of Innovative Technology and Exploring Engineering*, 8(10), 1080–1084. <https://doi.org/10.35940/ijitee.I7892.0881019>
- Bray, F., Ferlay, J., Soerjomataram, I., Siegel, R. L., Torre, L. A., & Jemal, A. (2018). Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: A Cancer Journal for Clinicians*, 68(6), 394–424. <https://doi.org/10.3322/caac.21492>
- Cohen, P. A., Jhingran, A., Oaknin, A., & Denny, L. (2019). Cervical cancer. *The Lancet*, 393(10167), 169–182. [https://doi.org/10.1016/S0140-6736\(18\)32470-X](https://doi.org/10.1016/S0140-6736(18)32470-X)
- Elgendy, M. (2020). Deep Learning for Vision Systems. In *Maning* (Vol. 1999, Issue December).
- Fani, M., Mahmoodi, P., Emadzadeh, M., Avan, A., Karimi, E., Ferns, G. A., Rezayi, M., &

- Amiri, I. S. (2019). Correlation of human papillomavirus 16 and 18 with cervical cancer and their diagnosis methods in Iranian women: A systematic review and meta-analysis. In *Current Problems in Cancer* (Vol. 44, Issue 1). Mosby Inc.
<https://doi.org/10.1016/j.currproblcancer.2019.06.008>
- Fernández, H. (n.d.). *Cómo aplicar la Ley de Pareto (80/20) para ser más productivo*. Economiatic. <https://economiatic.com/ley-de-pareto/>
- Firmino-Machado, J., Varela, S., Mendes, R., Moreira, A., Lunet, N., Carmo, A., Cancela, A., Firmino, A., Ramos, A., Teixeira, A., Vieira, A., Badim, B., Tojal, C., Junqueira, C., Pinheiro, C., Peneda, E., Monte, H., Vieira, H. M., Proença, I., ... Santos, V. (2019). A 3-step intervention to improve adherence to cervical cancer screening: The SCAN randomized controlled trial. *Preventive Medicine*, *123*, 250–261.
<https://doi.org/10.1016/j.ypmed.2019.03.025>
- Ghoneim, A., Muhammad, G., & Hossain, M. S. (2019). Cervical cancer classification using convolutional neural networks and extreme learning machines. *Future Generation Computer Systems*, *102*, 643–649. <https://doi.org/10.1016/j.future.2019.09.015>
- Hussain, E. (2019). *Liquid based cytology pap smear images for multi-class diagnosis of cervical cancer*. Mendeley. <https://doi.org/10.17632/zddtpgzv63.4>
- Hyeon, J., Choi, H.-J., Lee, B. D., & Lee, K. N. (2017). Diagnosing Cervical Cell Images Using Pre-trained Convolutional Neural Network as Feature Extractor. *2017 IEEE International Conference on Big Data and Smart Computing (BigComp)*.
- IARC. (2020). *Global Cancer Observatory*. <https://gco.iarc.fr/>
- Koh, W.-J., Greer, B. E., Abu-Rustum, N. R., Apte, S. M., Campos, S. M., Chan, J., Cho, K. R., Cohn, D., Crispens, M. A., DuPont, N., Eifel, P. J., Gaffney, D. K., Giuntoli, R. L. 2nd,

- Han, E., Huh, W. K., Lurain, J. R. 3rd, Martin, L., Morgan, M. A., Mutch, D., ... Hughes, M. (2013). Clinical practice guidelines in oncology - Cervical cancer. *JNCCN Journal of the National Comprehensive Cancer Network*, *11*(3), 320–343.
<https://doi.org/10.6004/jnccn.2013.0043>
- Kuko, M., & Pourhomayoun, M. (2019). An Ensemble Machine Learning Method for Single and Clustered Cervical Cell Classification. *IEEE 20th International Conference on Information Reuse and Integration for Data Science (IRI)*.
- Lewis, M. J. (2004). *Análisis de la situación del cáncer cervicouterino en América Latina y el Caribe*. <https://iris.paho.org/handle/10665.2/762>
- Manasa Ungrapalli, N. S., & Myna, A. N. (2019). Classification of pap smear images for cervical cancer using convolutional neural network. *International Journal of Innovative Technology and Exploring Engineering*, *9*(1), 2801–2807. <https://doi.org/10.35940/ijitee.J1226.119119>
- MathWorks. (n.d.-a). *resnet101*.
<https://es.mathworks.com/help/deeplearning/ref/resnet101.html;jsessionid=28135c24138583e52fbc29c3ef86>
- MathWorks. (n.d.-b). *resnet50*. <https://www.mathworks.com/help/deeplearning/ref/resnet50.html>
- MINSA. (2016). *GUÍA DE PRÁCTICA CLÍNICA PARA LA PREVENCIÓN Y MANEJO DEL CÁNCER DE CUELLO UTERINO*.
- Molina, M. (2022). *What is an Intelligent System?*
https://www.researchgate.net/publication/344334868_What_is_an_intelligent_system
- Okunade, K. S., Dawodu, O. O., Salako, O., Osanyin, G. E., Okunowo, A. A., & Anorlu, R. I. (2018). Comparative analysis of serum trace element levels in women with invasive cervical cancer in Lagos, Nigeria. *Pan African Medical Journal*, *31*.

<https://doi.org/10.11604/pamj.2018.31.194.14425>

Orr, J. (1998). Cervical cancer. *Surgical Oncology Clinics of North America*, 7(2), 299–316.

[https://doi.org/10.1016/s1055-3207\(18\)30272-2](https://doi.org/10.1016/s1055-3207(18)30272-2)

Rohmatillah, M., Pramono, S. H., Rahmadwati, Suyono, H., & Sena, S. A. (2018). Automatic Cervical Cell Classification Using Features Extracted by Convolutional Neural Network. *2018 Electrical Power, Electronics, Communications, Controls and Informatics Seminar, EECCIS 2018*, 382–386. <https://doi.org/10.1109/EECCIS.2018.8692888>

Shalini, N., Jagdish, L. R., Kaustubh, B., & Ameya, Z. (2018). *Detection of Cervical Cancer using GLCM and Support Vector Machines Shalini*.

Sharma, D., Bhan, A., & Goyal, A. (2018). Cervical Cancer Screening in Pap Smear Images Using Improved Distance Regularized Level Sets. *Proceedings of the 2nd International Conference on Trends in Electronics and Informatics, ICOEI 2018, Icoei*, 1445–1448. <https://doi.org/10.1109/ICOEI.2018.8553943>

Sharma, P., & Pattanshetty, S. M. (2017). A study on risk factors of cervical cancer among patients attending a tertiary care hospital: A case-control study. *Clinical Epidemiology and Global Health*, 6(2), 83–87. <https://doi.org/10.1016/j.cegh.2017.10.001>

Shrivastav, K. D., Taneja, N., Das, A. M., Rana, S., Ranjan, P., Singh, H., Jaggi, V. K., & Janardhanan, R. (2021). Socio-demographic and Clinico-pathological Profile of Cervical Cancer Patients at a Tertiary Care Centre in New Delhi: A Five-Year Retrospective analysis. *Indian Journal of Community Health*, 33(4), 634–639. <https://doi.org/10.47203/IJCH.2021.v33i04.016>

Smith, M. A., Hall, M., Lew, J. Bin, & Canfell, K. (2018). Potential for HPV vaccination and primary HPV screening to reduce cervical cancer disparities: Example from New Zealand.

- Vaccine*, 36(42), 6314–6324. <https://doi.org/10.1016/j.vaccine.2018.08.063>
- Sompawong, N., Mopan, J., Pooprasert, P., Himakhun, W., Suwannarurk, K., Ngamvirojcharoen, J., Vachiramon, T., & Tantibundhit, C. (2019). Automated Pap Smear Cervical Cancer Screening Using Deep Learning. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 7044–7048. <https://scihub.se/10.1109/embc.2019.8856369>
- Stewart, T. S., Moodley, J., & Walter, F. M. (2018). Population risk factors for late-stage presentation of cervical cancer in sub-Saharan Africa. *Cancer Epidemiology*, 53, 81–92. <https://doi.org/10.1016/j.canep.2018.01.014>
- Tharwat, A. (2018). Classification assessment methods. *Applied Computing and Informatics*, 17(1), 168–192. <https://doi.org/10.1016/j.aci.2018.08.003>
- Torres, J. (n.d.). *Deep Learning Introducción práctica con Keras*.
- Win, K. P., Kitjaidure, Y., Hamamoto, K., & Aung, T. M. (2020). Computer-assisted screening for cervical cancer using digital image processing of pap smear images. *Applied Sciences (Switzerland)*, 10(5). <https://doi.org/10.3390/app10051800>
- Win, K. P., Kitjaidure, Y., Paing, M. P., & Hamamoto, K. (2019). Cervical cancer detection and classification from pap smear images. *ACM International Conference Proceeding Series*, 47–54. <https://doi.org/10.1145/3366174.3366178>
- Wong, L. R., Mauricio, D., & Rodriguez, G. D. (2017). A systematic literature review about software requirements elicitation. *Journal of Engineering Science and Technology*, 12(2), 296–317.
- Xia, M., Zhang, G., Mu, C., Guan, B., & Wang, M. (2020). Cervical Cancer Cell Detection Based on Deep Convolutional Neural Network. *Chinese Control Conference, CCC, 2020-*

July, 6527–6532. <https://doi.org/10.23919/CCC50068.2020.9188454>

Xu, H., Egger, S., S Velentzis, L., L O'Connell, D., Banks, E., Darlington-Brown, J., Canfell, K., & Sitas, F. (2018). Hormonal contraceptive use and smoking as risk factors for high-grade cervical intraepithelial neoplasia in unvaccinated women aged 30–44 years: A case-control study in New South Wales, Australia. *Cancer Epidemiology*, *55*, 162–169.
<https://doi.org/10.1016/j.canep.2018.05.013>

Yaman, O., & Tuncer, T. (2022). Exemplar pyramid deep feature extraction based cervical cancer image classification model using pap-smear images. *Biomedical Signal Processing and Control*, *73*(December 2021). <https://doi.org/10.1016/j.bspc.2021.103428>

Zahras, D., & Rustam, Z. (2018). Cervical Cancer Risk Classification Based on Deep Convolutional Neural Network. In *Proceedings of ICAITI 2018 - 1st International Conference on Applied Information Technology and Innovation: Toward A New Paradigm for the Design of Assistive Technology in Smart Home Care*.
<https://doi.org/10.1109/ICAITI.2018.8686767>

Anexos

Anexo A

Documento de Requerimientos y Prototipos

Propiedad

Andrés Ccopa

Elmer Diaz

Responsables

Andrés Ccopa

Elmer Diaz

Control de versiones

Versión	Fecha	Elaborado por	Log de cambios
1.0	2021-12-17	Andrés Ccopa	Creación
1.1	2021-12-19	Andrés Ccopa	Requerimientos añadidos
2.0	2022-01-20	Andrés Ccopa	Casos de uso añadidos
2.1	2022-01-13	Elmer Diaz	Prototipos adjuntados

Objetivo	130
Alcance	130
Definiciones	130
Dueño del documento	121
Descripción	121
Propósito	121
Actores involucrados	121
Requerimientos Funcionales	121
Requerimientos No Funcionales	122
Caso de Uso y Prototipos	122
UC001 - Diagnosticar cáncer de cuello uterino	123
UC002 - Gestionar Usuarios	124
UC003 - Gestión de Pacientes	126
UC004 - Ver historial del paciente	127
UC005 - Ver reportes	128
Referencias	129

Objetivo

El objetivo de este documento es ayudar al personal médico en el diagnóstico de cáncer de cuello uterino, brindar diagramas históricos de los diagnósticos y dar accesibilidad a la información

Alcance

Los interesados que quieran entender y conocer todo lo relacionado a los requerimientos del sistema.

Definiciones

Redes Neuronales Convolucionales: Algoritmo de Deep Learning que está diseñado para trabajar con imágenes, tomando estas como input, asignándole importancias (pesos) a ciertos elementos en la imagen para así poder diferenciar unos de otros.

Dueño del documento

Es el equipo involucrado en la Tesis “Sistema para el diagnóstico de cáncer de cuello uterino aplicando redes neuronales convolucionales en imágenes de citología en base líquida de pruebas de papanicolaou”.

Descripción

- Propósito

Ayudar en el diagnóstico, por medio de imágenes que se toman a las pruebas de papanicolaou, el sistema clasificará las imágenes en dos tipos, prueba normal o anormal.

- Actores involucrados

Doctor, quien tiene acceso al diagnóstico y al historial de pacientes.

Administrador, quien tiene acceso al mantenimiento de usuarios y pacientes.

Director, quien tiene acceso a los diagramas históricos.

- Requerimientos Funcionales

Los requerimientos funcionales son los siguientes:

- Funcionalidad general del módulo diagnóstico
 - FR001 – Cargar una imagen: Se debe permitir subir una imagen de una biopsia para su posterior análisis y diagnóstico.
 - FR002 – Segmentar la imagen: Se debe realizar un proceso de segmentación de la imagen para mejorar la calidad y obtener un mejor diagnóstico.
 - FR003 – Clasificación: Se debe cargar el modelo de redes neuronales convolucionales ya entrenado, el cual clasificará la imagen.
 - FR004 – Mostrar Diagnóstico: Se debe mostrar el resultado del diagnóstico, por paciente.
 - FR009 – Consultar Historial de Pacientes: Se debe mostrar el historial del diagnóstico, por paciente.
- Funcionalidad general del módulo gestión
 - FR005 – Registrar paciente: Se debe permitir el registro de los pacientes, por medio de un usuario administrador.
 - FR006 – Registrar usuario: Se debe permitir el registro de usuarios los cuales pueden ser Doctor y administrador.
 - FR007 – Modificar usuario: Se debe permitir modificar el rol de un usuario.
 - FR008 – Modificar acciones por rol: Se debe permitir modificar las acciones de cada rol.
- Funcionalidad reporte
 - FR010 – Consultar Reportes: Se debe permitir consultar el reporte por año detallando el número de casos por meses.

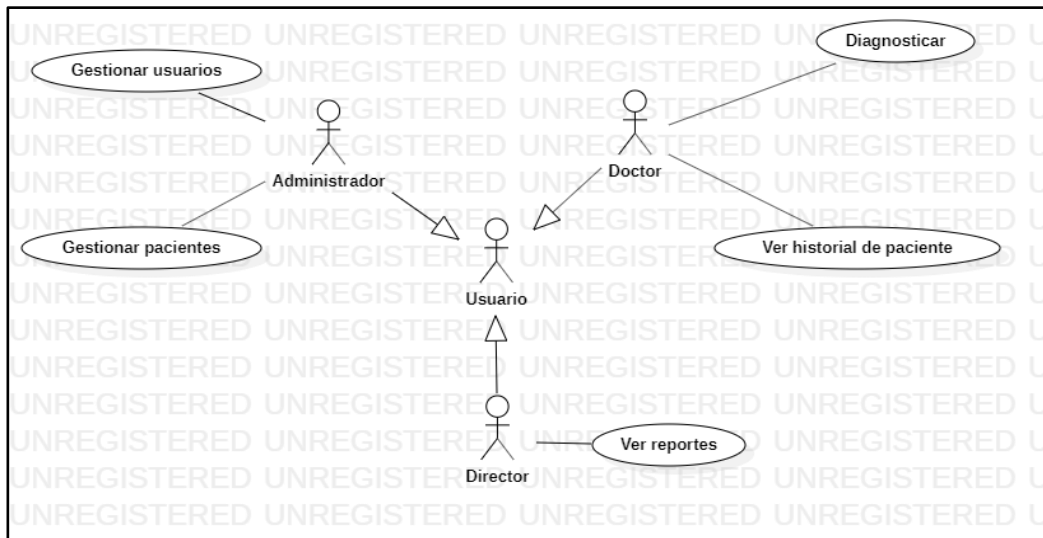
- Requerimientos No Funcionales

Los requerimientos no funcionales son los siguientes:

- Usabilidad: El sistema desarrollado debe poder ser utilizado las veces que sea necesario. Los encargados de interactuar con el sistema deberían ser capaces de entender cómo trabajar con ella.
- Portabilidad: Se debe tener un sistema que sea capaz de ser ejecutado sobre distintas plataformas software.
- Mantenibilidad: Este sistema debe ser sencillo y fácil de mantener, además de que el código y diseño se encuentre documentado, brindando facilidades de actualización.
- Rendimiento: Los tiempos en dar la respuesta deben ser cortos.
- Fiabilidad: Los resultados deben ser altamente confiables.

- Caso de Uso y Prototipos

En la siguiente figura se muestra el diagrama de casos de uso del sistema de diagnóstico de cáncer de cuello uterino con sus módulos.



UC001 - Diagnosticar cáncer de cuello uterino

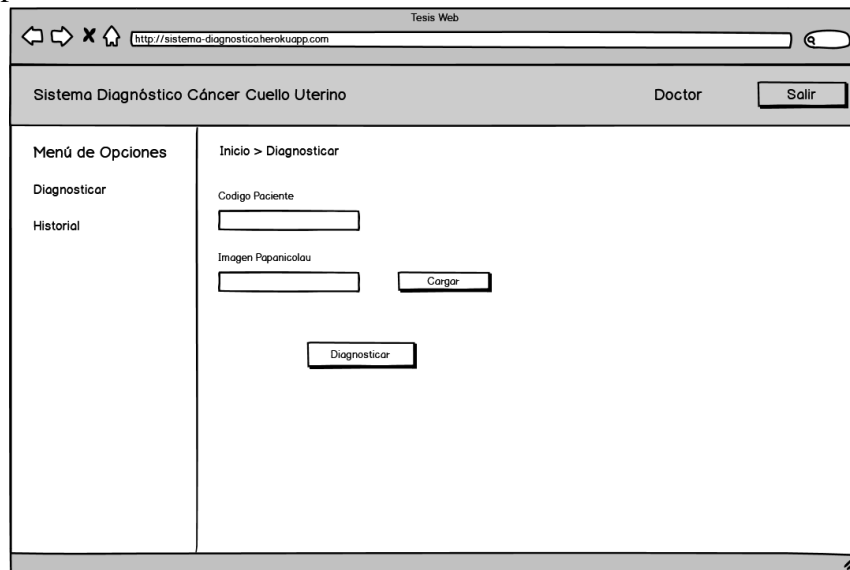
En este caso de uso se da el diagnóstico de cáncer de cuello uterino. Para ello se requiere cargar la imagen, y posteriormente se mostrará el resultado.

- Actor(es)
 - Doctor
- Pre-Condiciones
 - Se tiene la imagen de una prueba de Papanicolaou.
 - El usuario es un doctor.
- Post-Condiciones
 - El sistema muestra el diagnóstico correspondiente.
- Flujo Básico
 - El Doctor ingresa al sistema con su usuario.
 - El doctor ingresa el código del paciente.
 - El Doctor carga la imagen de la prueba de Papanicolaou.
 - El sistema realiza el preprocesamiento de la imagen.
 - El sistema realiza el diagnóstico.
 - El sistema muestra el resultado y lo guarda en la base de datos.
- Flujo de Excepción
 - El doctor no ingresa una imagen válida.
 - La herramienta indica el fallo del procesamiento.
- Criterios de aceptación:

- El sistema arrojará el resultado de haberse realizado correctamente el diagnóstico.
- Requerimientos Asociados

ID Requerimiento	Nombre del Requerimiento
FR001	Cargar una imagen
FR002	Segmentar la imagen
FR003	Clasificación
FR004	Mostrar diagnostico

- Prototipo



UC002 - Gestionar Usuarios

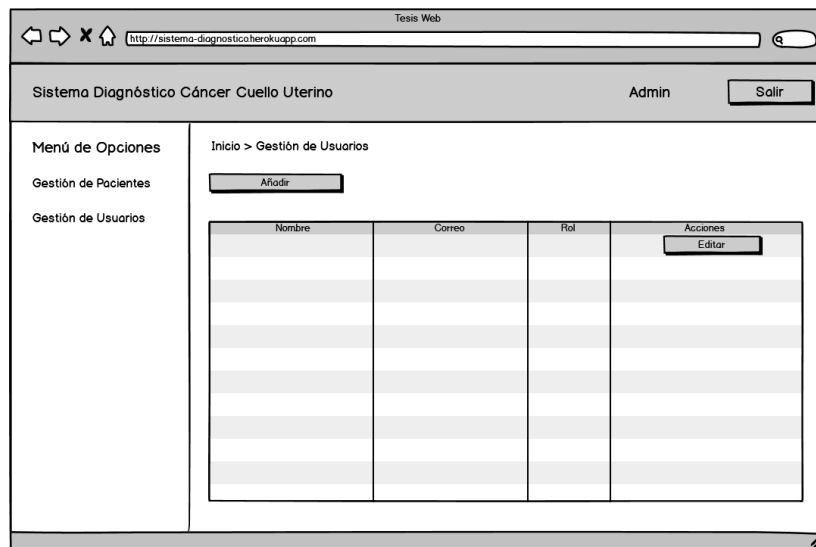
En este caso de uso se realiza la gestión de usuarios, en el cual se podrá registrar y modificar usuarios.

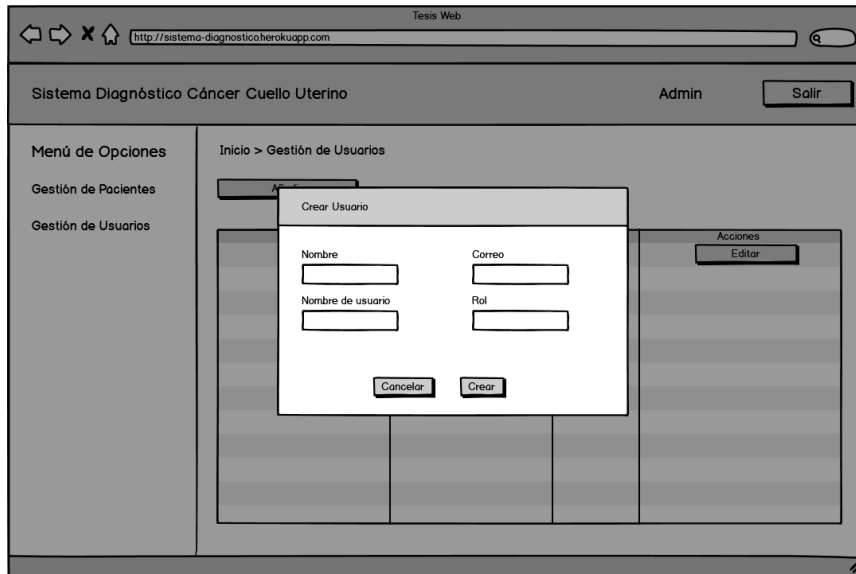
- Actor(es)
 - Administrador
- Pre-Condiciones
 - Se tiene una cuenta de administrador.
- Post-Condiciones
 - El sistema permite la gestión de usuarios.
- Flujo Básico
 - El administrador ingresa al sistema con su usuario.
 - El administrador registra un usuario con los siguientes datos: email, username, password.
 - El administrador selecciona registrar.
 - El sistema guarda al usuario en la base de datos.
- Flujo de Alternativo

- El administrador modifica un usuario.
- El administrador modifica el rol del usuario.
- El sistema guarda la modificación.
- El administrador modifica las acciones por rol.
- El sistema guarda la modificación.
- Criterios de aceptación:
 - El sistema guarda los datos en la base de datos.
- Requerimientos Asociados

ID Requerimiento	Nombre del Requerimiento
FR006	Registrar usuario
FR007	Modificar usuario
FR008	Modificar acciones por rol

- Prototipo







UC003 - Gestión de Pacientes

En este caso de uso se realiza la gestión de pacientes, en donde se registra a los pacientes.

- Actor(es)
 - Administrador
- Pre-Condiciones
 - Se tiene una cuenta de administrador.
- Post-Condiciones
 - El sistema permite la gestión de pacientes.
- Flujo Básico
 - El administrador ingresa al sistema con su usuario.
 - El administrador registra un paciente con los siguientes datos: código, nombre, fecha nacimiento.
 - El administrador selecciona registrar
 - El sistema guarda los datos en la base de datos.
- Criterios de aceptación:
 - El sistema guarda los datos en la base de datos.
- Requerimientos Asociados

ID Requerimiento	Nombre del Requerimiento
FR005	Registrar paciente

- Prototipo



UC004 - Ver historial del paciente


En este caso de uso se realiza la consulta del historial de pacientes.

- Actor(es)
 - Doctor
- Pre-Condiciones
 - Se tiene una cuenta de doctor.
- Post-Condiciones
 - El sistema permite la consulta del historial del paciente.
- Flujo Básico
 - El administrador ingresa al sistema con su usuario.
 - El administrador ingresa los siguientes datos: código del paciente.
 - El administrador selecciona consultar.

- El sistema mostrará el historial.
- Criterios de aceptación:
 - El sistema guarda los datos en la base de datos.
- Requerimientos Asociados

ID Requerimiento	Nombre del Requerimiento
FR009	Consultar pacientes

- Prototipo



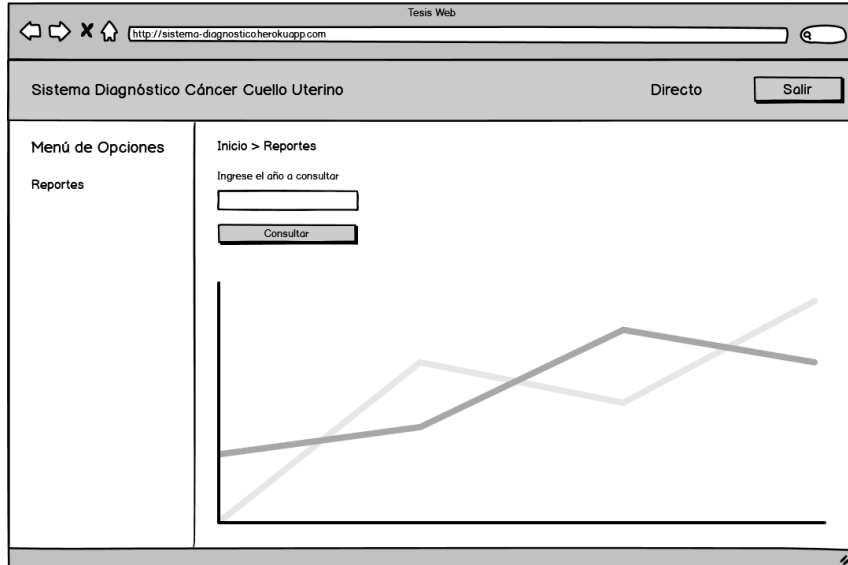
UC005 - Ver reportes

En este caso de uso se realiza la consulta de reportes.

- Actor(es)
 - Director
- Pre-Condiciones
 - Se tiene una cuenta de director.
- Post-Condiciones
 - El sistema permite la visualización de reportes.
- Flujo Básico
 - El administrador ingresa al sistema con su usuario.
 - El administrador ingresa los siguientes datos: año a consultar.
 - El administrador selecciona consultar.
 - El sistema mostrará el reporte.
- Criterios de aceptación:
 - El sistema guarda los datos en la base de datos.
- Requerimientos Asociados

ID Requerimiento	Nombre del Requerimiento
FR010	Consultar reportes

- Prototipo



Anexo B

Documento de Arquitectura de Software

Propiedad

Andrés Ccopa

Elmer Diaz

Responsables

Andrés Ccopa

Elmer Diaz

Control de versiones

Versión	Fecha	Elaborado por	Log de cambios
1.0	2021-12-17	Andrés Ccopa	Creación
1.1	2021-12-20	Elmer Diaz	Arquitectura y tecnología añadidas
2.0	2022-01-21	Elmer Diaz	Arquitectura a detalle
2.1	2022-03-24	Andrés Ccopa	Vistas del sistema

Objetivo	130
Alcance	130
Definiciones	130
Dueño del documento	121
Descripción	121
Propósito	121
Actores involucrados	121
Arquitectura del sistema	121
Tecnologías utilizadas	122
Arquitectura a detalle	135
Detalle de capas	136
Vistas del sistema	122
Vista modular	123
Vista de casos de uso	124
Vista de componentes	126
Referencias	129

Objetivo

El objetivo de este documento es ayudar al personal médico en el diagnóstico de cáncer de cuello uterino, brindar diagramas históricos de los diagnósticos y dar accesibilidad a la información

Alcance

Los interesados que quieran entender y conocer todo lo relacionado a la arquitectura de software del sistema.

Definiciones

Redes Neuronales Convolucionales: Algoritmo de Deep Learning que está diseñado para trabajar con imágenes, tomando estas como input, asignándole importancias (pesos) a ciertos elementos en la imagen para así poder diferenciar unos de otros.

Dueño del documento

Es el equipo involucrado en la Tesis “Sistema para el diagnóstico de cáncer de cuello uterino aplicando redes neuronales convolucionales en imágenes de citología en base líquida de pruebas de papanicolaou”.

Descripción

- Propósito

Ayudar en el diagnóstico, por medio de imágenes que se toman a las pruebas de papanicolaou, el sistema clasificará las imágenes en dos tipos, prueba normal o anormal.

- Actores involucrados

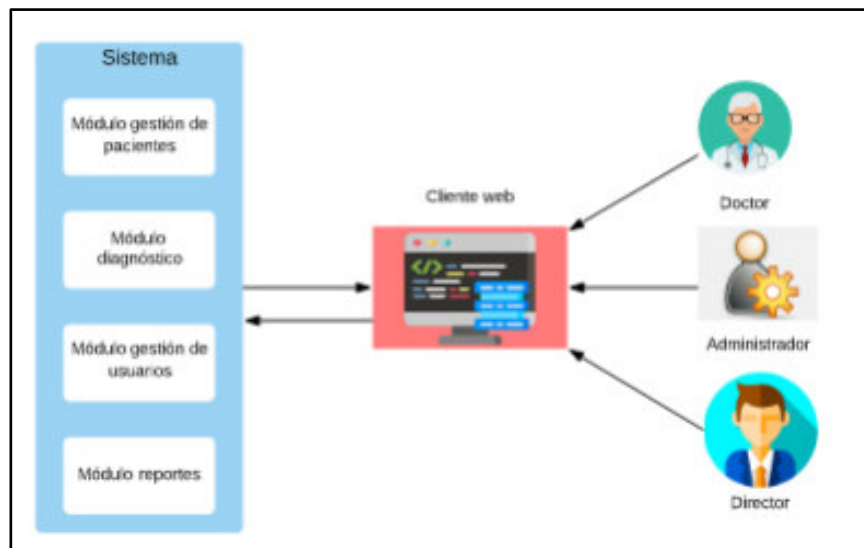
Doctor, quien tiene acceso al diagnóstico y al historial de pacientes.

Administrador, quien tiene acceso al mantenimiento de usuarios y pacientes.

Director, quien tiene acceso a los diagramas históricos.

- Arquitectura del sistema

En la siguiente figura se muestra la arquitectura general del sistema de diagnóstico de cáncer de cuello uterino con sus módulos, representados de manera general.



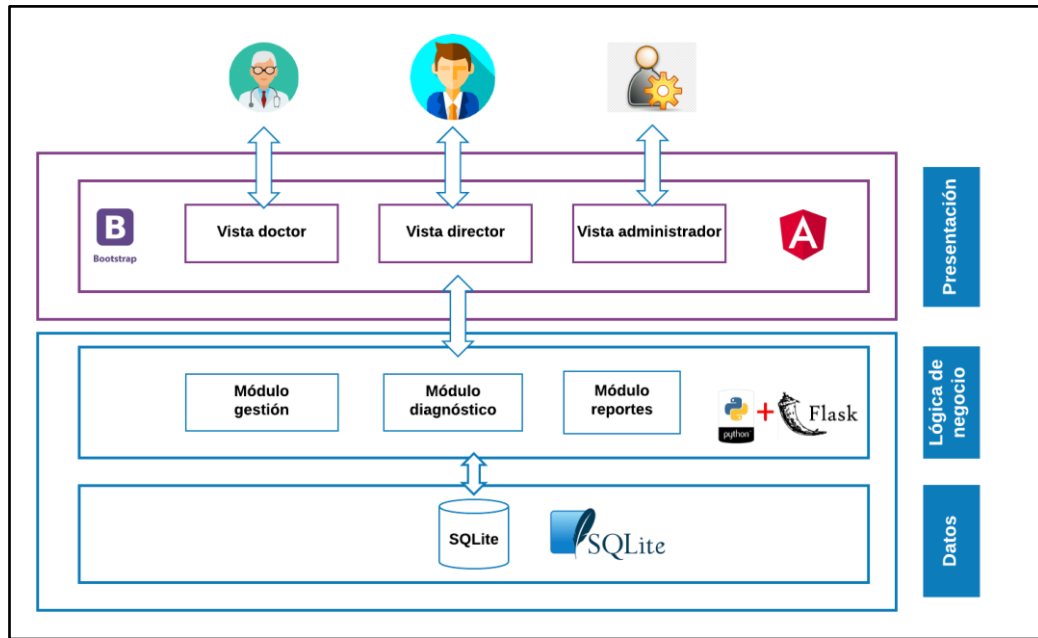
- Tecnologías utilizadas

Como parte de las tecnologías utilizadas se tiene lo siguiente:

- Flask: Es un framework desarrollado en Python, que permite desarrollar aplicaciones web de manera rápida, y con un número mínimo de líneas de código.
- Angular: Es un framework desarrollado en TypeScript, que permite desarrollar aplicaciones web de una sola página.
- Bootstrap: Es una biblioteca multiplataforma utilizada para el diseño de sitios web y aplicaciones web.
- SQLite: es un sistema de gestión de base de datos relacional, contenido en una pequeña biblioteca escrita en C.

- Arquitectura a detalle

En la siguiente figura se tiene la arquitectura al detalle del sistema de diagnóstico de cáncer de cuello uterino, con las capas de presentación, lógica de negocio y la de base de datos, en la sección detalle de capas se realiza la descripción de las capas y modelos de la arquitectura.



- Detalle de capas

A continuación, presentamos las capas:

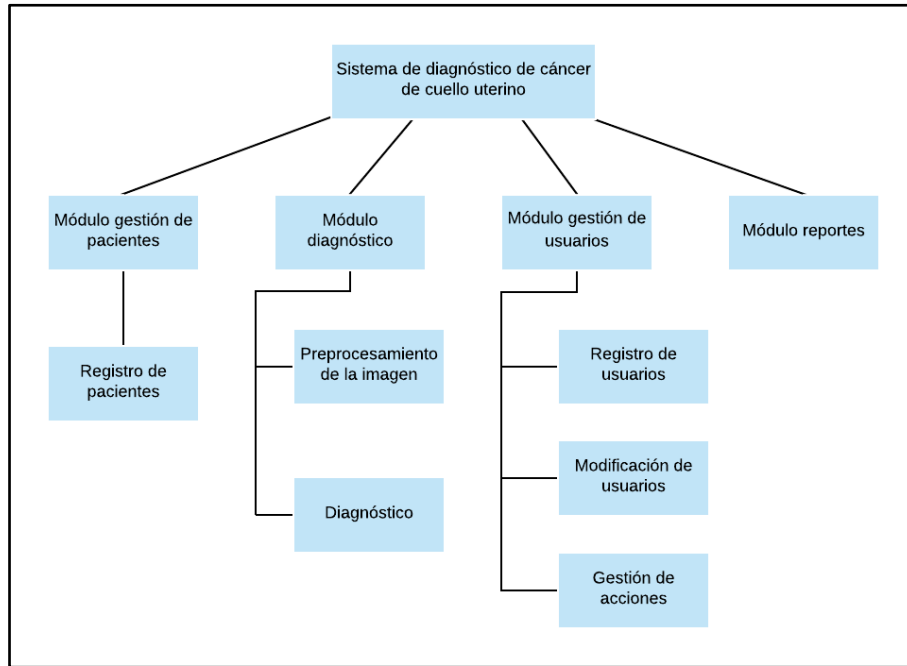
- **Presentación:** Es la capa que se encarga de la interacción del usuario con el sistema, la cual está desarrollada en angular y bootstrap, y está alojada en heroku.
- **Lógica de negocio:** Es la capa que se encarga del core del sistema que está desarrollado con el framework flask, la cual consta de módulo usuarios, módulo paciente, módulo diagnóstico, módulo reportes.
 - **Módulo usuarios:** Se realiza la gestión de los usuarios, el registro, modificación, así como también el soporte de las acciones por el rol de cada usuario, que en este caso son doctor, administrador y director. También, se realiza el registro de los pacientes.
 - **Módulo diagnóstico:** Se realiza el diagnóstico de cáncer de cuello uterino, en el cual se hace uso del modelo de RNC, previamente entrenado.
 - **Módulo reportes:** Se pueden ver los gráficos históricos de los diagnósticos realizados.
- **Datos:** Es la capa que se encarga de guardar los datos, en un sistema gestor de base de datos que es SQLite.

- Vistas del sistema

Teniendo en cuenta que una vista es una representación del sistema y sus componentes, en este documento podremos ver las vistas modulares, funcional, de componentes, de despliegue y de integración de la arquitectura.

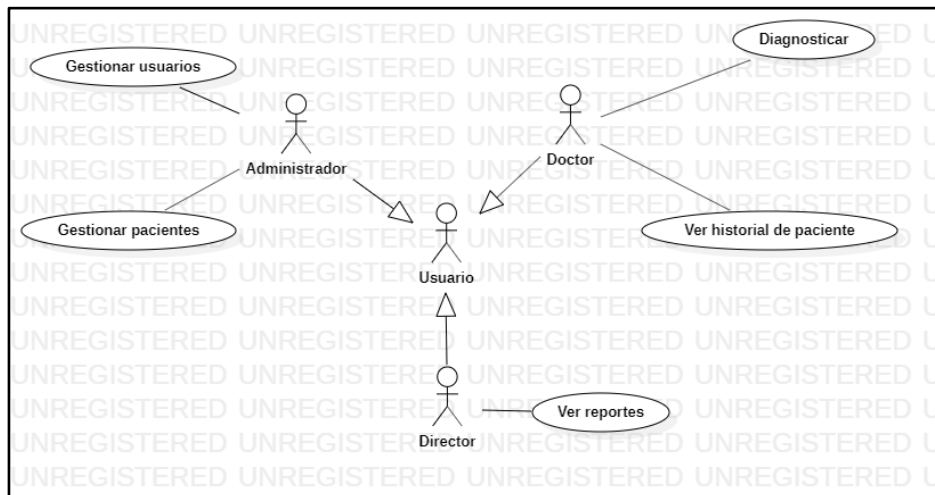
- Vista modular

En la siguiente figura, se muestra la vista de cada módulo está dividida en submódulos, el Sistema dispone de los siguientes módulos: diagnóstico, gestión de usuarios, gestión de pacientes y reportes.



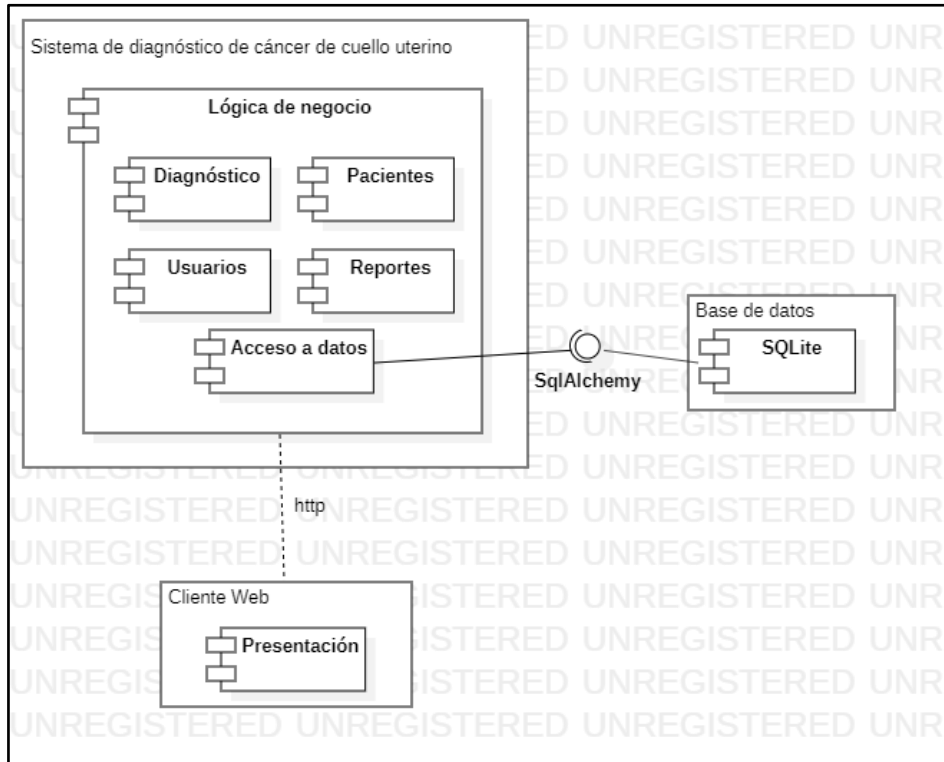
- Vista de casos de uso

En la siguiente figura se muestra la vista de los casos de uso del sistema, que definieron previamente el documento de requisitos.



- Vista de componentes

En la siguiente figura se muestra la vista de componentes del sistema y su integración con los componentes de la base de datos y el cliente web.



Anexo C

Documento de Entrenamiento de los Modelos

Propiedad

Andrés Ccopa

Elmer Diaz

Responsables

Andrés Ccopa

Elmer Diaz

Control de versiones

Versión	Fecha	Elaborado por	Log de cambios
1.0	2022-01-03	Elmer Diaz	Creación
1.1	2022-02-15	Andrés Ccopa	Modificación
2.0	2022-03-01	Elmer Diaz	Actualización
2.1	2022-04-23	Andrés Ccopa	Modificación

Objetivo

El objetivo de este documento es ayudar al personal médico en el diagnóstico de cáncer de cuello uterino, explicar la arquitectura y entrenamiento del modelo de red neuronal convolucional.

Alcance

Los interesados que quieran entender y conocer todo lo relacionado a los requerimientos del sistema.

Definiciones

- **Redes Neuronales Convolucionales:** Algoritmo de Deep Learning que está diseñado para trabajar con imágenes, tomando estas como input, asignándole importancias (pesos) a ciertos elementos en la imagen para así poder diferenciar unos de otros.
- **Keras:** Es una biblioteca de Redes Neuronales de Código Abierto escrita en Python
- **Tensorflow:** Es una biblioteca de código abierto para aprendizaje automático
- **Sklearn:** Librería de aprendizaje automático
- **K-means:** Algoritmo de agrupamiento

Dueño del documento


Es el equipo involucrado en la Tesis “Sistema para el diagnóstico de cáncer de cuello uterino aplicando redes neuronales convolucionales en imágenes de citología en base líquida de pruebas de papanicolaou”.

Descripción

- **Modelo de red neuronal convolucional ResNet50**


En el modelo se ha utilizado la arquitectura del modelo Resnet50 que ofrece la librería de tensorflow, en el cual se carga con pesos ya entrenados que ofrece Imagenet, para este caso se

deshabilitó las capas totalmente conectadas que son propias del ResNet50 para la clasificación, como se muestra en la siguiente figura.



La siguiente figura se muestra la estructura de la arquitectura elaborada para el modelo ResNet 50, modelo que consiste en las capas anteriormente mencionadas, propias del ResNet 50, y que adicionalmente se añadirán las nuestras propias para mejorar los resultados del entrenamiento. En primer lugar, se ha agregado una capa Flatten, la cual ayudará a redimensionar las capas llevándolas a una sola (aplanar). Posteriormente se agregarán 3 capas Dense con función de activación “ReLU” y 3 capas Gaussian Noise que serán utilizadas para mitigar el sobreajuste (una forma de aumento de datos aleatorios). Finalmente se añadirá una capa Dense con función de activación “softmax” para la clasificación de imágenes.

La primera capa dense recibe como entrada un espacio con dimensionalidad 163840 y como salida da un espacio con dimensionalidad 2048, la segunda capa dense da como salida una dimensionalidad 512, la tercera capa dense con una salida de dimensionalidad 128, y la última capa dense una salida con dimensionalidad 4, ya que se tienen 4 clases de imágenes.



En cuanto a la compilación del modelo, se utilizaron argumentos que serán mencionados a continuación. En primer lugar, el Optimizador, configurado con un “RMSprop (learning_rate=1e-4)”, la Función de pérdida, configurada con “categorical_crossentropy”, y la Métrica dada como “accuracy”.


En la siguiente tabla se prosigue a explicar el código que se ha utilizado para ambos modelos, solo se realiza la modificación en la línea con respecto al modelo que se utiliza.

En la línea 0 obtenemos la data en base a una función propia encargada de procesar las imágenes de papanicolau. Esta data será usada posteriormente en el entrenamiento (línea 14). En la línea 1 se procede a instanciar la variable resnet con el Modelo pre entrenado ResNet50, con los pesos de imagenet, se desactivó las capas totalmente conectadas. A partir de la línea 2 hasta la 12, se construye el modelo donde se le añade la arquitectura ResNet50, y capas adicionales para la


clasificación de las imágenes. En la línea 13, se realiza la compilación del modelo, con los siguientes parámetros el optimizador, configurado con un “RMSprop (learning_rate=1e-4)”, la función de pérdida, configurada con “categorical_crossentropy” y la métrica con “accuracy”. Por último, en la línea 14 se realiza el entrenamiento, con los parámetros que es el tamaño del Batch, definido con una cantidad de 32 y el número de Épocas dado como 100.

Línea	Código
0	x_train, y_train = get_data(train_dir)
1	resnet = ResNet50(weights='imagenet',include_top=False, input_shape=(240,320,3))
2	model = Sequential()
3	model.add(resnet)
4	model.add(layers.Flatten())
5	model.add(layers.Dense(2048, activation='relu'))
6	model.add(layers.GaussianNoise(0.2))
7	model.add(layers.Dense(512, activation='relu'))
8	model.add(layers.GaussianNoise(0.2))
9	model.add(layers.Dense(128, activation='relu'))
10	model.add(layers.GaussianNoise(0.2))
11	model.add(layers.Dense(4, activation='softmax'))
12	model.summary()
13	model.compile(optimizer=RMSprop(learning_rate=1e-4), loss='categorical_crossentropy', metrics=['accuracy'])
14	history = model.fit(x_train, y_train,batch_size = 32,validation_data = (x_val, y_val),epochs = 100,verbose = 1)

En la siguiente figura, podemos visualizar los resultados de la exactitud que se obtuvo luego del entrenamiento del modelo, y su respectiva prueba. Se obtuvo una exactitud promedio del 100% en el entrenamiento, pero en el caso de la validación se obtuvo la mayor exactitud de 91%, lo cual es inferior, pero es buen resultado, además podemos observar en la figura que a partir de la época 71 se tiene una uniformidad en el entrenamiento.




En la figura siguiente se observa la pérdida que se obtuvo durante el entrenamiento y la prueba del modelo. La pérdida en el entrenamiento fue descendiendo durante el avance de las épocas se tiene una pérdida de 0, y en el caso de la validación la pérdida también tuvo picos altos, pero a partir de época 30 fue descendiendo considerablemente, y así se mantuvo hasta la época 100, la cual varía entre 1.5 a 2.




- **Modelo de red neuronal convolucional ResNet101**

En el modelo se ha utilizado la arquitectura del modelo ResNet 101 que ofrece la librería de tensorflow, en el cual se carga con pesos ya entrenados que ofrece, pero en esta arquitectura solo se habilitó para el entrenamiento la capa 10. Además de que se deshabilitó las capas totalmente conectadas que son propias del Resnet 101 para la clasificación.




En la siguiente figura se muestra la estructura de la arquitectura elaborada para el modelo ResNet 101, modelo que consiste en las capas anteriormente mencionadas, propias del ResNet 101, y que adicionalmente se añadirán las nuestras propias para mejorar los resultados del entrenamiento. En primer lugar, se ha agregado una capa Flatten, la cual ayudará a redimensionar las capas llevándolas a una sola (aplanar). Posteriormente se agregarán 3 capas Dense con función de activación “ReLU” y 3 capas Gaussian Noise que serán utilizadas para mitigar el sobreajuste (una forma de aumento de datos aleatorios). Finalmente se añadirá una capa Dense con función de activación “softmax” para la clasificación de imágenes.



En cuanto a la compilación del modelo, se utilizaron argumentos que serán mencionados a continuación. En primer lugar, el Optimizador, configurado con un “RMSprop (learning_rate=1e-4)”. Adicionalmente, la Función de pérdida, configurada con “categorical_crossentropy”. Finalmente, la Métrica dada como “accuracy”.

Para el entrenamiento también se utilizaron algunos argumentos adicionales, tales como el tamaño del Batch, definido con una cantidad de 32. El número de Épocas dado como 100.

La siguiente figura, se visualizan los resultados de la exactitud que se obtuvo luego del entrenamiento del modelo, y su respectiva prueba. Se obtuvo una exactitud del 100% de exactitud en el entrenamiento, pero en el caso de la prueba la mayor exactitud obtenida fue de 89.93%.



En la siguiente figura, se observa la pérdida que se obtuvo durante el entrenamiento y la prueba durante el entrenamiento del modelo. En la Figura 41, la pérdida en el entrenamiento fue descendiendo durante el avance de las épocas se tiene una pérdida de 0, y en el caso de la prueba también la pérdida fue descendiendo, y durante las épocas se fue estabilizando.

