

UNIVERSIDAD EAN
FACULTAD DE INGENIERIA

IDENTIFICACIÓN DE ANOMALÍAS DE LAS CÉLULAS CERVICALES
MEDIANTE INTELIGENCIA ARTIFICIAL

DIEGO ALEJANDRO CIRO MARÍN
SERGIO ALEJANDRO HURTADO SOTO

CHACÓN RIVERA LINA MARIA

BOGOTÁ, D.C.

2024

CONTENIDO

RESUMEN EJECUTIVO.....	3
INTRODUCCIÓN.....	3
DEFINICION DEL PROBLEMA.....	4
OBJETIVOS	6
JUSTIFICACIÓN	6
ANALISIS DE REQUERIMIENTOS.....	8
MARCO DE REFERENCIA.....	10
ANALISIS DE ALTERNATIVAS.....	23
ANALISIS DE RESTRICCIONES.....	24
METODOLOGÍA PARA LA SELECCION Y DESARRROLLO DE LA SOLUCIÓN.....	26
OFERTA DE VALOR.....	28
ANÁLISIS DE COSTOS Y MODELO DE NEGOCIO.....	29
RESULTADOS Y ANÁLISIS.....	32
CONCLUSIONES.....	41
RECOMENDACIONES.....	42
REFERENCIAS.....	42

RESUMEN EJECUTIVO.

Este proyecto aborda la necesidad de mejorar el diagnóstico precoz y preciso de lesiones premalignas en células cervicales, mediante el desarrollo de un sistema innovador basado en tecnologías de inteligencia artificial (IA). Se ha concebido un enfoque que se fundamenta en un algoritmo de aprendizaje automático entrenado con una extensa base de datos de imágenes celulares, previamente categorizadas por expertos médicos como sanas o con Lesiones intraepiteliales escamosas de bajo grado (L-SIL) o Lesión intraepitelial escamosa de alto grado (H-SIL).

Al emplear técnicas de procesamiento de imágenes y algoritmos de aprendizaje automático, se busca entrenar al modelo de IA para identificar patrones distintivos en las células que están asociados con la presencia de cáncer. Esta solución no solo ofrece una herramienta precisa y rápida para la detección temprana del cáncer, sino que también tiene el potencial de mejorar los tratamientos y las tasas de supervivencia de los pacientes al permitir intervenciones oportunas. Además, al automatizar el análisis de imágenes, se puede reducir la carga de trabajo para los profesionales médicos, lo que resulta en una mayor eficiencia del diagnóstico. En última instancia, este proyecto representaría un avance significativo en el campo del diagnóstico médico asistido por IA y se espera que contribuya de manera sustancial a la lucha contra el cáncer, con el objetivo de mejorar la calidad de vida de los pacientes y salvar vidas.

INTRODUCCIÓN.

El cáncer, es una enfermedad que afecta diariamente a millones de personas en todo el mundo, y sigue siendo un desafío formidable para la comunidad médica y científica. A pesar de los avances en la investigación y el tratamiento, la detección temprana sigue siendo una pieza clave en la lucha contra esta enfermedad. La detección precoz no solo aumenta significativamente las posibilidades de éxito en el tratamiento, sino que también puede reducir la necesidad de tratamientos agresivos y mejorar la calidad de vida de los pacientes. A pesar de eso, el proceso para diagnosticar el cáncer sigue siendo un campo que se enfrenta a varios desafíos, desde la interpretación de los síntomas hasta el análisis de pruebas diagnósticas como imágenes celulares.

La tecnología de inteligencia artificial (IA) se puede considerar como un área de investigación prometedora en el diagnóstico del cáncer. La capacidad de la IA para analizar conjuntos de datos de gran tamaño de manera rápida y precisa ha llevado a que se explore su potencial en la detección y diagnóstico del cáncer. A través del aprendizaje automático y la visión computacional, la IA puede identificar patrones sutiles en imágenes médicas que podrían pasar desapercibidos para el ojo del oncólogo. Este enfoque tiene la capacidad de mejorar la eficiencia y precisión del diagnóstico del cáncer, lo que podría tener un impacto significativo en los tiempos de detección y tratamiento oportuno del cáncer.

En los últimos años la literatura científica ha documentado diferentes investigaciones que exploran el uso de la IA en el análisis de imágenes médicas para la detección de cáncer. Estos estudios han demostrado resultados prometedores en términos de precisión y eficiencia en el diagnóstico del cáncer. Por ejemplo, una investigación realizada por Melissa Escalante. (2023) Señala como el MIT creó un dispositivo que con ayuda de la IA es capaz de detectar tumores mamarios en etapas tempranas. Y recalca que, si se usan exámenes de detección más frecuentes, puede aumentar la tasa de supervivencia hasta un 98 %. Además, en otro estudio realizado en China, científicos usaron escáneres para la detección de cáncer de cuello uterino, estos escáneres toman más de 50 fotografías y gracias a la ayuda de la inteligencia artificial una evaluación citológica es capaz de hacerse en menos de 2 minutos con resultados sorprendentes (Zhu Xingce, et al, 2023).

Sin embargo, aún existen desafíos significativos en la implementación efectiva de estas tecnologías en la práctica clínica. La validación clínica, la interoperabilidad con sistemas existentes y la aceptación por parte de los profesionales de la salud son solo algunos de los aspectos que requieren atención.

El proyecto se centra en abordar estos desafíos desarrollando un sistema basado en IA para detectar anomalías de las células cervicales escamosas desde la definición del sistema Bethesda 2014.

El enfoque se centra en el entrenamiento de un modelo de aprendizaje automático con una base de datos extensa y debidamente clasificada de imágenes celulares. Al utilizar técnicas avanzadas de procesamiento de imágenes y algoritmos de aprendizaje automático, se busca mejorar la eficiencia y precisión del diagnóstico del cáncer de cuello uterino. Este proyecto tiene como objetivo no solo mejorar los resultados clínicos para los pacientes, sino también facilitar el camino para una práctica médica más efectiva y basada en datos. En última instancia, se espera que este trabajo en un futuro contribuya en la lucha contra este tipo de cáncer, mejorando así la calidad de vida de las personas afectadas por esta enfermedad.

DEFINICION DEL PROBLEMA.

El problema abordado se centra en los desafíos presentes en la detección del cáncer cervicouterino, donde los procesos actuales enfrentan dificultades significativas. La demora en el procesamiento de muestras, que puede extenderse hasta tres días, genera incertidumbre

y ansiedad en los pacientes. Además, el volumen de muestras que las personas deben procesar diariamente, aproximadamente 500, fluctúa drásticamente, lo que afecta la consistencia y la precisión del diagnóstico, provocando una sobrecarga de trabajo en el personal del área de citología. Estas limitaciones destacan la necesidad de mejorar del proceso mediante el uso de inteligencia artificial. Sin embargo, la IA puede enfrentar deficiencias en el reconocimiento de patrones debido a la complejidad y variabilidad de las muestras, lo que requiere una cuidadosa evaluación y ajuste para garantizar su eficacia en la detección temprana y el tratamiento oportuno del cáncer de este tipo.

OBJETIVOS

OBJETIVO GENERAL

- Desarrollar un sistema basado en inteligencia artificial para detectar lesiones premalignas de cáncer cervical en muestras citológicas, para mejorar la eficiencia y precisión del diagnóstico en comparación con el método manual.

OBJETIVOS ESPECIFICOS

- Depurar una base de datos de imágenes citológicas debidamente clasificadas según el tipo de lesión para el entrenamiento del modelo de inteligencia artificial.
- Diseñar un modelo de aprendizaje supervisado utilizando técnicas avanzadas de visión computacional y procesamiento de imágenes, para identificar patrones característicos de células cancerígenas en las muestras citológicas
- Entrenar el modelo de IA usando una base de datos previamente clasificada para que el modelo pueda definir y clasificar correctamente según los patrones definidos por la misma herramienta.
- Evaluar la efectividad del sistema desarrollado mediante pruebas exhaustivas con un conjunto de datos independiente, comparando los resultados de la detección automatizada con los diagnósticos realizados por citólogos expertos, en términos de precisión, sensibilidad y especificidad.

JUSTIFICACIÓN

El proyecto surge en respuesta a la necesidad de mejorar el diagnóstico precoz y preciso del cáncer, una enfermedad devastadora que es un desafío para la comunidad médica y científica a nivel global. Según la Organización Mundial de la Salud (OMS) La detección temprana del cáncer aumenta significativamente las posibilidades de éxito en el tratamiento, reduce los costos de tratamiento, reduce la necesidad de intervenciones agresivas y mejora la calidad de vida de los pacientes.

En el ámbito del diagnóstico médico, la IA emerge como una herramienta prometedora, con beneficios significativos. Su capacidad para analizar grandes conjuntos de datos de manera rápida y precisa ha despertado un interés creciente en su aplicación para la detección y

diagnóstico del cáncer. La IA identifica patrones sutiles en imágenes celulares, con aprendizaje automático y visión computacional. Este enfoque destaca especialmente por la notable reducción del tiempo necesario para el diagnóstico. Comparado con los métodos tradicionales, el análisis de imágenes celulares se realiza de manera más rápida y eficiente, aliviando la carga de trabajo de los médicos y resultando crucial en la detección temprana del cáncer, donde cada minuto cuenta.

Numerosos estudios científicos respaldan la efectividad de la inteligencia artificial (IA) en el análisis de imágenes médicas para la detección de cáncer. Por ejemplo, investigaciones realizadas en instituciones como el MIT (Instituto Tecnológico de Massachusetts) han demostrado resultados prometedores en términos de precisión y eficiencia en el diagnóstico del cáncer utilizando dispositivos asistidos por IA. Esta efectividad en el diagnóstico se traduce en una mejora notable. Al entrenar un modelo de aprendizaje automático con una extensa base de datos de imágenes celulares debidamente clasificadas, se alcanza una mayor precisión en la identificación de patrones cancerígenos. Esto conlleva a minimizar los errores de diagnóstico y aumentar la confiabilidad de los resultados, lo que puede tener un impacto significativo en la práctica clínica y, en última instancia, en la mejora de los resultados para los pacientes.

Al automatizar parte del proceso de diagnóstico mediante la inteligencia artificial (IA), se libera el tiempo de los profesionales de la salud para tareas más especializadas, lo que conduce a una mayor eficiencia en la atención médica y una mejor asignación de recursos. Esta automatización no solo reduce la carga de trabajo asociada al análisis manual de las imágenes, sino que también permite una atención más centrada en el paciente y en sus necesidades específicas.

Además, la identificación de anomalías en las células cervicales gracias a la IA puede contribuir al desarrollo de tratamientos más personalizados y efectivos, adaptados a las características individuales de cada paciente. Este no solo busca mejorar los resultados clínicos para los pacientes, sino también facilitar el camino para una práctica médica más efectiva y basada en datos.

En última instancia, este proyecto representa un avance significativo en el campo del diagnóstico médico asistido por IA. Se espera que, con mejoras continuas, sea capaz de contribuir de manera sustancial a la lucha contra el cáncer, mejorando así la calidad de vida de las personas afectadas por esta enfermedad y proporcionando esperanza para un futuro con mejores opciones de tratamiento y diagnóstico.

ANALISIS DE REQUERIMIENTOS.

El desarrollo del proyecto no solo implica la consecución de objetivos en tiempo y forma, sino también el cumplimiento integral de los requerimientos funcionales y técnicos establecidos. En el contexto de nuestro proyecto, es crucial iniciar con un análisis exhaustivo de los requerimientos para garantizar el diseño y la implementación adecuados de la solución. Este análisis no solo implica definir la intención del producto, sino también verificar los parámetros de diseño y estimar las características técnicas necesarias para su desarrollo.

La intención principal del proyecto producto es revolucionar el proceso de detección y diagnóstico del cáncer cervicouterino, haciendo uso de tecnologías avanzadas como la inteligencia artificial. Se propone desarrollar un sistema innovador que pueda analizar imágenes de anomalías de las células cervicales con precisión y rapidez, superando las limitaciones inherentes a los métodos manuales tradicionales. Este sistema se concibe como una herramienta complementaria para los profesionales de la salud, que les permita realizar diagnósticos más precisos y oportunos, mejorando así la calidad de atención a los pacientes y contribuyendo a salvar vidas.

Para el correcto desarrollo y funcionamiento del software, es necesario tener en cuenta los siguientes factores técnicos:

Potencia de Procesamiento:

Se necesita un sistema con una potencia de procesamiento suficiente para ejecutar algoritmos de IA complejos en tiempo real. Los expertos recomiendan utilizar procesadores de alto rendimiento, como CPUs multi-core como el Intel core Ultra que cuenta con 12 núcleos y 4.3 GHz de frecuencia o GPUs especializadas en tareas de aprendizaje profundo como la Nvidia Tesla V 100 o Nvidia Tesla A100.

Sin embargo, Google desarrolló componentes especializados llamados unidades de procesamiento tensorial (TPU) los cuales su principal función es acelerar las operaciones matriciales, proceso fundamental en las redes neuronales.

Memoria RAM:

Se requiere una cantidad adecuada de memoria RAM para almacenar y manipular grandes volúmenes de datos de imágenes médicas. Para proyectos de IA, se recomienda tener al menos 16 GB de RAM para garantizar un rendimiento fluido del sistema.

Almacenamiento:

Es fundamental contar con un almacenamiento suficiente para mantener grandes conjuntos de datos de imágenes médicas, así como los modelos de IA entrenados y los resultados de los análisis. Se recomienda utilizar unidades de estado sólido (SSD) de alta capacidad para garantizar tiempos de carga y acceso rápidos a los datos, dado el alcance del proyecto, dos terabytes de almacenamiento sería más que suficiente.

Software y Frameworks de IA:

Se necesitarán herramientas y frameworks de IA adecuados para el desarrollo y la implementación de algoritmos de aprendizaje automático. Algunos ejemplos incluyen TensorFlow, PyTorch y scikit-learn. También se requerirá preprocesamiento de las imágenes con herramientas de diferentes Frameworks de uso libre.

Conectividad:

El sistema debe contar con conectividad adecuada para integrarse con otros sistemas y dispositivos médicos, así como para acceder a bases de datos y recursos en la nube. Se recomienda utilizar conexiones Ethernet de alta velocidad (preferiblemente gigabit) y/o conexiones inalámbricas confiables para garantizar una comunicación fluida.

Seguridad y Privacidad:

Se deben implementar medidas de seguridad y privacidad robustas para proteger los datos médicos sensibles, haciendo uso de encriptación de los datos y transmisión segura de los mismos ya sea en la red interna o a través de una VPN, adicionalmente es necesario garantizar el cumplimiento de las regulaciones de privacidad, como HIPAA (Health Insurance Portability and Accountability Act) en los Estados Unidos, en Colombia no se cuenta con un estándar pero se cuenta con diferentes regulaciones como:

Ley Estatutaria 1581 de 2012: Regula el tratamiento de datos personales en Colombia y establece los principios, deberes y derechos que deben ser observados al manejar información personal, incluida la información de salud.

Resolución 1995 de 1999: Regula la protección de datos personales en el sector de la salud en Colombia. Establece las medidas de seguridad y procedimientos para garantizar la confidencialidad, integridad y disponibilidad de la información de salud.

Resolución 1995 de 2019: Esta resolución actualiza y fortalece las medidas de seguridad para la protección de datos personales en el sector de la salud, incluyendo la implementación de medidas técnicas y organizativas para prevenir el acceso no autorizado a la información de salud.

Ley 1273 de 2009: Esta ley establece disposiciones sobre delitos informáticos en Colombia, incluyendo el acceso ilegal a sistemas informáticos y la protección de datos personales contra la interceptación y acceso no autorizado.

MARCO DE REFERENCIA.

Métodos actuales para detectar el cáncer de cuello uterino.

La detección efectiva del cáncer de cuello uterino es de vital importancia para mejorar los resultados del tratamiento y reducir la carga de esta enfermedad en el sistema de salud. Se han hecho varias investigaciones y publicaciones que proporcionan una visión integral de los métodos actuales utilizados en la detección y gestión del cáncer cervical.

En el estudio hecho por Arbyn et al. (2020) se destaca la efectividad de la vacunación contra el virus del papiloma humano (VPH) y la detección temprana en la prevención del cáncer de cuello uterino. Según sus hallazgos, las vacunas contra el VPH ofrecen una protección significativa contra la infección y las lesiones precancerosas asociadas con ciertos tipos de este virus, lo que subraya su importancia en la prevención primaria. Además, evidencian que las pruebas de detección de VPH superan a la citología cervical tradicional en la identificación de lesiones precancerosas y cánceres invasivos, lo que respalda la necesidad de implementar estrategias combinadas de vacunación y detección para mitigar la carga global de esta enfermedad.

Estos resultados resaltan la urgencia de adoptar enfoques integrados que incorporen tanto la vacunación contra el VPH como la detección precoz en la planificación de programas de control del cáncer de cuello uterino. La información detallada proporcionada por este estudio es fundamental para guiar políticas de salud pública, especialmente en regiones con recursos limitados donde la carga de la enfermedad es más elevada. En este contexto, comprender la efectividad de estas intervenciones es crucial para desarrollar estrategias que maximicen el impacto en la prevención y el tratamiento del cáncer cervical.

En el ámbito del diagnóstico del cáncer cervical, Grigsby (2014) se dice que se debe destacar la importancia de considerar distintos factores de riesgo, como enfermedades de transmisión sexual, tabaquismo, antecedentes de infección por VIH, pruebas de Papanicolaou anormales previas, neoplasmas cervicales anteriores y tratamiento. Recomienda realizar colposcopias y biopsias dirigidas para mujeres con resultados anormales en las pruebas de Papanicolaou, así como procedimientos de conización para aquellas con diagnóstico histológico de neoplasia intraepitelial cervical de alto grado. Además, resalta la utilidad de medir marcadores tumorales séricos, como el antígeno del carcinoma de células escamosas (SCCag) y el antígeno carcinoembrionario (CEA), para evaluar la presencia y gravedad del cáncer cervical.

Los investigadores Rayappan y Lee (2021) resaltan cuales son los desafíos en el diagnóstico del cáncer cervical, enfocándose en los biomarcadores y biosensores. Destacando que solo el 1% de los pacientes infectados con VPH muestran verrugas visibles, lo que hace necesario el desarrollo de técnicas más sensibles para la detección temprana de lesiones internas. Se han

adoptado técnicas moleculares como PCR, microarrays y secuenciación de próxima generación para mejorar la sensibilidad de la detección del VPH.

A pesar de los avances en las técnicas de detección del VPH, los métodos actuales tienen limitaciones en términos de costo y sensibilidad. Los kits comerciales aprobados por la FDA (Food and Drug Administration) son costosos y tienen limitaciones de especificidad y sensibilidad. Se requiere una mejora en la accesibilidad y asequibilidad de las pruebas de detección del VPH para desarrollar sistemas de prueba a nivel mundial.

En el libro Farghaly (2019) se subraya la importancia de las técnicas ópticas, como la imagen hiper-espectral, en el diagnóstico del cáncer cervical. Lo que hace la imagen hiper-espectral es permitir el análisis de la composición bioquímica de las células y tejidos cervicales mediante la captura de información detallada en múltiples longitudes de onda del espectro electromagnético. Esta técnica proporciona una visión precisa y detallada de las características biomoleculares únicas de los tejidos cancerosos, permitiendo la detección temprana y la evaluación precisa de la progresión de la enfermedad. Al aprovechar la capacidad de la imagen hiper-espectral para revelar diferencias sutiles en la composición química de los tejidos, los profesionales de la salud pueden identificar lesiones cervicales con mayor precisión y tomar decisiones de tratamiento más informadas para mejorar los resultados clínicos de los pacientes.

Por otro lado, en el libro de Lowy (2011), se aprecia la visión histórica detallada de la evolución de la detección del cáncer cervical a lo largo del tiempo. Donde se destaca especialmente el papel crucial de las pruebas de cribado, como la citología cervical (Papanicolaou) y la detección del virus del papiloma humano (VPH), en el avance de esta área. Estas pruebas han permitido identificar lesiones precancerosas y factores de riesgo viral en etapas tempranas, aumentando así las posibilidades de intervención efectiva y tratamiento exitoso. Junto a los avances en tecnología óptica, como el colposcopio, han mejorado la capacidad de los profesionales de la salud para visualizar y evaluar las lesiones cervicales con mayor precisión, tal como lo enfatiza Farghaly (2019) al mencionar la imagen hiper-espectral.

Dejando como conclusión que el aspecto fundamental del progreso en la detección del cáncer cervical ha sido la comprensión cada vez mayor de los factores de riesgo y biomarcadores asociados con la enfermedad. Siendo esto lo que ha permitido el desarrollo de enfoques más personalizados y precisos para la detección temprana y el monitoreo de la progresión de la enfermedad en individuos de alto riesgo.

Métodos actuales para detectar el cáncer de cuello uterino patrones celulares y patrones en tejidos.

Es crucial entender la progresión del cáncer cervical para mejorar su detección efectiva. En un estudio realizado por Agoff et al. (2003), se presenta un marcador llamado p16INK4a, el cual se muestra prometedor en la detección del cáncer cervical con mayor precisión que otras pruebas, como la citología cervical. Este marcador exhibe una asociación clara entre su presencia y la gravedad del cáncer cervical. Por ejemplo, se ha observado que niveles más altos de p16INK4a están relacionados con lesiones más graves y carcinomas invasivos.

La detección de p16INK4a significa identificar el cáncer cervical en etapas más tempranas, facilitando su tratamiento. Además, este marcador también está vinculado con la presencia del virus del papiloma humano (VPH) de alto riesgo, lo que proporciona información adicional sobre el riesgo de desarrollar cáncer cervical.

La importancia de p16INK4a como herramienta complementaria en el diagnóstico de neoplasias cervicales. Su expresión correlacionada con el VPH de alto riesgo ofrece una valiosa perspectiva para evaluar y gestionar lesiones cervicales. En la Figura 1, se presentan imágenes de "mucosa escamosa cervical normal, displasia escamosa de bajo grado (CIN I) y displasia escamosa de alto grado (CIN III)" (Agoff et al, 2003), cada una etiquetada con tinciones específicas para resaltar la morfología celular y los marcadores p16INK4a y Ki-67, empleados en el diagnóstico del cáncer cervical y sus lesiones precursoras.




ILUSTRACIÓN 1 MARCADORES UTILIZADOS EN EL DIAGNÓSTICO DEL CÁNCER CERVICAL Y SUS LESIONES PRECURSORAS. TOMADO DE AGOFF ET AL. (2003)

Estas imágenes ayudan a ilustrar las diferencias en la expresión de estas proteínas en diferentes etapas de la enfermedad cervical.

Por otro lado, se conoce el Sistema Bethesda (TBS), establecido en 2014. En el artículo escrito por Pangarkar (2022), se destaca un marco estandarizado para informar los resultados de las pruebas citológicas. Este sistema ofrece una terminología específica para la presentación de informes, junto con directrices claras para el tratamiento de las lesiones cervicales, lo que facilita la interpretación y la comunicación entre los profesionales de la salud. Se centra en identificar anomalías celulares, como células escamosas atípicas y glandulares atípicas, para evaluar el riesgo de neoplasia cervical.

El TBS 2014 se compone de cinco elementos principales en un informe de prueba de Papanicolaou: tipo de muestra, idoneidad, categoría general, interpretación y pruebas complementarias. Proporciona pautas detalladas para informar sobre diversos hallazgos, como células escamosas atípicas, células glandulares atípicas, anomalías de las células epiteliales y otras neoplasias malignas, entre otros. En entornos, donde los programas de detección de Papanicolaou no están disponibles y se hacen pruebas en pacientes sintomáticos en departamentos ambulatorios de hospitales públicos y privados, el TBS es crucial para detectar y tratar lesiones cervicales, además de otras afecciones ginecológicas comunes.

En el contexto de las aplicaciones clínicas de la prueba de VPH para la detección del cáncer de cuello uterino El artículo de Arbyn et al. (2012) proporciona una visión general de las aplicaciones clínicas de la prueba de detección del virus del papiloma humano (VPH) en el contexto de la prevención del cáncer de cuello uterino. Se destacan tres aplicaciones clínicas principales de la prueba de VPH. Primero, en el triaje de mujeres con anomalías citológicas equívocas o de bajo grado, se encontró evidencia consistente que indica que el uso del VPH como método de triaje, especialmente con el ensayo “Hybrid Capture® 2”, es más preciso (mayor sensibilidad, similar especificidad) que la citología repetida para seleccionar a las mujeres con resultados equívocos en la citología de Papanicolaou.

Segundo, en la predicción del resultado terapéutico después del tratamiento de lesiones de neoplasia intraepitelial cervical (CIN), los estudios muestran que, “Las pruebas de VPH son más sensibles y tan específicas como la citología en la predicción de la cura o la recurrencia de lesiones de CIN después del tratamiento” (Arbyn et al, 2012).

Tercero, en cuanto al tamizaje primario para el cáncer de cuello uterino y pre-cáncer, el tamizaje primario con VPH detecta más casos de CIN2, CIN3 o cáncer en comparación con la citología, pero con una especificidad ligeramente menor. La combinación de VPH y citología proporciona una ganancia pequeña en sensibilidad a expensas de una pérdida considerable en especificidad.

Los resultados del estudio de Arbyn et al. (2012) respaldan la importancia de implementar estrategias innovadoras para aumentar la participación en el cribado del cáncer cervical en poblaciones subexaminadas. En este contexto, el estudio de Castle et al. (2010) proporciona evidencia adicional de que ofrecer la autotoma con prueba de VPH puede ser una intervención aceptable y efectiva para aumentar la participación en el cribado del cáncer

cervical entre las mujeres subexaminadas del Delta de Mississippi. Los hallazgos de Castle et al. sugieren que la autotoma con prueba de VPH podría complementar los programas de citología convencional para llegar a estas poblaciones subexaminadas de manera más efectiva.

Anormalidades en células epiteliales.

Para comprender las anomalías en las células epiteliales del cuello uterino se debe tener en cuenta los lineamientos y directrices para el manejo de muestras detectadas con cáncer cervical y de igual manera el conocimiento de la infección por VPH

El estudio hecho por Wright et al. (2007) destaca la importancia de la clasificación de anomalías en células epiteliales cervicales, según las directrices de consenso de 2006. En este consenso se clasifican las anomalías en las células epiteliales cervicales, se dividen en:

- ASC-US (células escamosas atípicas de significado indeterminado): Este término se utiliza cuando se observan células escamosas que muestran anomalías, pero no lo suficientemente definidas como para ser clasificadas como LSIL o HSIL. Se considera un hallazgo de citología cervical indeterminado.
- LSIL (lesiones escamosas intraepiteliales de bajo grado): Se refiere a la presencia de anomalías celulares leves, como células con características sugestivas de infección por VPH o cambios celulares leves. Aunque pueden indicar una infección por VPH, generalmente no representan un riesgo inmediato de cáncer invasivo.




ILUSTRACIÓN 2 MUESTRA CITOLOGÍA LSIL. TOMADO DE PHOULADY & MOUTON. (2018)

- HSIL (lesiones escamosas intraepiteliales de alto grado): Indica anomalías celulares más significativas, con cambios celulares que sugieren una alta probabilidad de

progresión a cáncer invasivo si no se tratan. Se consideran lesiones precancerosas y requieren una evaluación y manejo más urgentes.




ILUSTRACIÓN 3 MUESTRA CITOLOGÍA HSIL. TOMADO DE PHOULADY & MOUTON. (2018)

- AGC (células glandulares atípicas): Este término se utiliza cuando se observan células glandulares anormales en la muestra de citología cervical. Puede indicar la presencia de anomalías en el tejido glandular del cuello uterino o del útero, lo que puede requerir evaluación adicional para descartar neoplasias malignas.

El avance del conocimiento sobre el cáncer cervical ha implicado cambios en la nomenclatura a lo largo del tiempo. Una de las terminologías más recientes y significativas, abordada por Schiffman y Wentzensen (2013), es la Terminología Escamosa Anogenital Inferior (LAST), la cual se basa en la tinción de p16 para el triaje de lesiones CIN2. Esta terminología reconoce la heterogeneidad de las lesiones CIN2 y su potencial de regresión, permitiendo distinguir entre aquellas con mayor riesgo de progresión a cáncer y las que tienen más probabilidades de regresar espontáneamente.

Este enfoque refinado en la terminología y el diagnóstico refleja una comprensión más profunda de la biología de las lesiones precursoras del cáncer cervical, lo que mejora la gestión clínica de estas lesiones y ofrece mejores resultados para las pacientes mediante la identificación precisa de las lesiones que requieren tratamiento inmediato y las que pueden ser seguidas con vigilancia activa.

Lesiones premalignas y celular.

Es esencial comprender que la detección temprana y precisa de las lesiones premalignas es crucial para la prevención y el manejo efectivo del cáncer cervical.

El estudio de Sankaranarayanan et al. (2009) es relevante para las lesiones premalignas del cuello uterino, como la neoplasia intraepitelial cervical (CIN), que son etapas tempranas en el desarrollo del cáncer cervical. Estas lesiones son cambios anormales en las células del cuello uterino con el potencial de convertirse en cáncer si no se tratan. El estudio implementó diferentes métodos de detección, como la prueba de VPH, la citología y la inspección visual con ácido acético (VIA), para identificar lesiones premalignas en mujeres de alto riesgo en India.

Los resultados revelaron que la detección temprana y el tratamiento de las lesiones premalignas, especialmente mediante la prueba de VPH, estaban asociados con una reducción significativa en la incidencia de cánceres cervicales avanzados. Esto sugiere que identificar y tratar las lesiones premalignas puede prevenir la progresión a cáncer cervical invasivo. El estudio proporciona evidencia crucial sobre la eficacia de los programas de detección en la reducción del riesgo de desarrollar cáncer cervical al abordar las lesiones premalignas antes de que se vuelvan cancerosas.

Por otro lado, el estudio ATHENA, realizado por Castle et al. (2011), comparó dos pruebas de detección cervical en mujeres mayores de 25 años: la prueba de detección de VPH cobas y la citología líquida. Descubrieron que la prueba de VPH cobas fue más sensible que la citología líquida para encontrar lesiones cervicales precancerosas de grado 3 o peor. Sin embargo, al combinar la citología líquida con la prueba de VPH, se mejoró la capacidad para detectar estas lesiones, aunque esto también aumentó el número de resultados positivos, es decir, se detectaron más casos, algunos de los cuales podrían no ser significativos. Además, encontraron que detectar ciertos tipos de VPH junto con ciertos resultados de citología fue especialmente útil para identificar estas lesiones precancerosas en mujeres con VPH positivo.

En conclusión, el estudio ATHENA mostró que la prueba de VPH es más efectiva que la citología líquida para detectar lesiones cervicales precancerosas. Además, sugiere que mejorar los métodos de detección de VPH podría ayudar a prevenir el cáncer cervical al identificar y tratar las lesiones precancerosas antes de que se desarrollen en cáncer.

IA (Inteligencia Artificial).

La IA es un campo de la informática que tiene como objetivo crear sistemas que puedan realizar tareas que requieren la intervención humana. Estos sistemas aprenden de datos, reconocen patrones, toman decisiones y resuelven problemas específicos. En pocas palabras, la IA tiene como objetivo imitar la inteligencia humana utilizando algoritmos y datos.

Existen diferentes trabajos durante los últimos años sobre la definición, usos y enfoques de la inteligencia artificial que pueden ser tomados como referencia, pero el libro más importante y aquel en que se basan académicos de la inteligencia artificial es “Inteligencia Artificial: Un

enfoque moderno” de Stuart J. Russell y Peter Norvig, el cual sienta las bases para el entendimiento de esta tecnología.

La inteligencia artificial (IA) se define como un campo de la informática que se enfoca en el estudio y desarrollo de sistemas y algoritmos que pueden percibir su entorno, aprender de él y tomar decisiones para maximizar sus posibilidades de alcanzar sus objetivos (Russell & Norvig, 2010). Estos sistemas intentan imitar la capacidad humana de pensamiento y razonamiento mediante el uso de modelos y algoritmos computacionales.

La IA está teniendo un impacto significativo en el mundo en diversas áreas. Por ejemplo, en la industria automotriz, se están desarrollando vehículos autónomos que utilizan IA para conducir de manera segura y eficiente. En el sector financiero, se están utilizando algoritmos de IA para predecir tendencias del mercado y tomar decisiones de inversión. En el ámbito del entretenimiento, la IA se utiliza para recomendar películas, música y contenido personalizado a los usuarios.

En el campo de la medicina, la IA está cambiando la forma de diagnosticar y tratar las enfermedades. Por ejemplo, en la detección del cáncer, los sistemas de inteligencia artificial pueden analizar imágenes médicas, como rayos X o tomografías computarizadas, para identificar signos de enfermedades con mayor precisión que los médicos humanos. La IA también puede ayudar a personalizar los tratamientos médicos en función de las características individuales de cada paciente para aumentar la eficacia y reducir los efectos secundarios.

Según Andy Hock, vicepresidente de producto de Cerebras, una empresa especializada en inteligencia artificial, la IA tiene diversas aplicaciones, como asistir a los investigadores en la creación de terapias farmacéuticas innovadoras, mejorar la comprensión de los registros médicos electrónicos y anticipar los resultados de salud de tratamientos específicos. (Hock A, 2024).

Visión Computacional y detección de patrones en imágenes.

Dentro de la inteligencia artificial existen varias ramas, pero la rama encargada de analizar los patrones provenientes de las imágenes se llama visión computacional. La visión computacional, capacita a las máquinas para extraer información valiosa de imágenes y videos, permitiéndoles "ver" y comprender su entorno de manera similar a la visión humana. (IBM, s.f.)

Es necesario brindarle suficiente información al algoritmo para que este pueda comprender el contexto de las imágenes y detecte patrones incluso más rápido que los humanos, esta capacidad de análisis rápido y preciso supera las limitaciones humanas y tiene amplias aplicaciones en la industria y la tecnología modernas.

La visión computacional es una amplia rama de la inteligencia artificial, por ello utiliza diferentes conceptos transversales y relevantes para el desarrollo de proyectos con visión artificial.

Redes Neuronales Convolucionales (CNN).

Las Redes Neuronales Convolucionales (CNN) son redes neuronales profundas diseñadas específicamente para procesar imágenes. Según Szeliski (2010), las redes neuronales convolucionales (CNN) han mostrado un gran rendimiento en labores de visión computacional, tales como la clasificación de imágenes, la detección de objetos y la segmentación semántica.

El funcionamiento de una CNN se asemeja al funcionamiento del sistema visual humano. La red está compuesta por múltiples capas, incluyendo capas convolucionales, de agrupación (pooling) y completamente conectadas. En la capa convolucional, la red aplica filtros convolucionales a la imagen de entrada para extraer características importantes, como bordes, texturas y patrones. Luego, en las capas de agrupación, se reduce la dimensionalidad de las características para mantener la información relevante y reducir el costo computacional. Finalmente, en las capas completamente conectadas, la red realiza la clasificación o regresión final basada en las características extraídas.

Las CNN revolucionaron la visión por computadora por su capacidad para aprender automáticamente características relevantes de las imágenes, lo que las hace muy eficientes y precisas en varias aplicaciones, actualmente se está trabajando en las fast-CNN para potenciar este sector.

Aprendizaje Profundo (Deep Learning DL).

El aprendizaje profundo, también conocido como redes neuronales profundas, es una rama del aprendizaje automático que utiliza redes neuronales con múltiples capas para aprender representaciones de datos de alto nivel. Según Szeliski (2010), el progreso en la visión por computadora y otras áreas de la inteligencia artificial se ha visto impulsado significativamente por el DL, gracias a su habilidad para aprender de manera automática características complejas de los datos.

El funcionamiento del aprendizaje profundo implica el entrenamiento de una red neuronal con múltiples capas de procesamiento, como redes neuronales convolucionales (CNN) o redes neuronales recurrentes (RNN). Durante el entrenamiento, la red aprende a representar los datos de manera jerárquica, identificando características simples en las capas inferiores y características más abstractas y complejas en las capas superiores.

El aprendizaje profundo ha demostrado ser altamente efectivo en una variedad de tareas, incluyendo el reconocimiento de voz, el procesamiento del lenguaje natural, la visión por computadora y más. Su capacidad para aprender automáticamente a partir de grandes volúmenes de datos ha llevado a avances significativos en la IA y la tecnología en general.

Segmentación de Imágenes.

La segmentación de imágenes es el proceso de dividir una imagen en partes significativas o segmentos. Según Szeliski (2010), la segmentación de imágenes es una tarea fundamental en la visión por computadora y juega un papel crucial en aplicaciones como la detección de objetos, la segmentación semántica y el análisis de imágenes médicas.

El funcionamiento de la segmentación de imágenes implica la aplicación de algoritmos y técnicas para identificar regiones de interés en una imagen y asignarles una etiqueta o clase correspondiente. Esto puede implicar el uso de métodos de agrupación (clustering), bordes, umbrales, regiones y más para distinguir entre diferentes partes de una imagen.

La segmentación de imágenes es una tarea desafiante debido a la variabilidad en la apariencia y la complejidad de las imágenes. Sin embargo, es fundamental para muchas aplicaciones de visión por computadora y ha sido objeto de una investigación extensa en la comunidad científica. Las técnicas de segmentación de imágenes se utilizan en una amplia gama de aplicaciones, desde la medicina hasta la robótica, y son un componente clave en muchos sistemas de IA y visión por computadora.

El desarrollo de la visión computacional ha revolucionado el análisis de imágenes médicas, mejorando la precisión y automatizando procesos diagnósticos y terapéuticos. No obstante, este avance conlleva desafíos éticos y de seguridad, como la protección de la privacidad del paciente y posibles interpretaciones incorrectas. Es esencial adherirse a estándares éticos y protocolos de seguridad rigurosos en el desarrollo y la implementación de sistemas de detección de imágenes médicas.

Avances en la medicina usando IA.

Durante los últimos años gracias al auge de la inteligencia artificial, ha habido distintas investigaciones en el área de la medicina utilizando Deep learning y redes convolucionales para la mejora de diagnósticos médicos.

A continuación, se describen diferentes trabajos relacionados con el proyecto, que guían para el nuevo planteamiento y enfoque que este proyecto brinda.

En el libro “CNN-IKOA: convolutional neural network with improved Kepler optimization algorithm for image segmentation: experimental validation and numerical exploration”, se plantea una solución al diagnóstico del covid-19 u otras enfermedades pulmonares en pacientes únicamente con la radiografía del tórax. Con un método complejo de Deep learning y planteando una alternativa a algoritmos existentes que tardan en converger y perfeccionarse.

Según Mohamed Abdel-Basset y compañía, este estudio propone una técnica alternativa de segmentación de imágenes utilizando una versión mejorada del algoritmo de optimización de

Kepler (IKOA), con el objetivo de mejorar la segmentación de imágenes de radiografías de tórax (CXR) en diferentes niveles de umbral. (Abdel-Basset, M., Mohamed, R., Alrashdi, I. et al 2024)

Los resultados experimentales muestran que IKOA supera a todos los algoritmos comparados. Además, se utilizan las imágenes de CXR segmentadas con IKOA para entrenar un nuevo modelo de red neuronal convolucional (CNN) llamado CNN-IKOA. (Abdel-Basset, M., Mohamed, R., Alrashdi, I. et al 2024)

La efectividad de CNN-IKOA se evalúa utilizando cinco indicadores de rendimiento, mostrando resultados destacados para las imágenes segmentadas en T-12, donde alcanza un 94,88% de precisión global, un 96,57% de especificidad, un 95,40% de precisión y un 95,40% de recall (Abdel-Basset, M., Mohamed, R., Alrashdi, I. et al 2024).

En segundo lugar, se ha investigado la manera de diagnosticar el cáncer a través de algoritmos de inteligencia artificial, sin embargo, no es posible, hasta la fecha detectar cualquier tipo de cáncer debido a particularidades de cada cáncer y procedimientos distintos.

Francesco curia desarrolló una investigación, en la que incluye la descripción de un sistema de soporte de decisiones clínicas enfocadas en el cáncer cervicouterino, basándose en un clasificador binario, logró ajustar el modelo en un 94% de precisión y factores de riesgo relacionados con el cáncer cervicouterino.

Este estudio concluyó que, a pesar de la complejidad del cáncer cervicouterino, los algoritmos avanzados de aprendizaje automático para abordar el problema del cáncer cervical, logrando resultados prometedores en la investigación clínica respaldada por inteligencia artificial. Los resultados muestran la construcción de un clasificador con alta precisión y se emplean herramientas de Aprendizaje Automático Explicable para comprender y analizar las predicciones del modelo. Esto permite a los profesionales de la salud interpretar las decisiones del algoritmo y tomar medidas precisas en el diagnóstico y tratamiento del cáncer cervical. (Curia, F, 2021)

Existen otros estudios que relacionan otros tipos de cáncer y su posible diagnóstico utilizando inteligencia artificial, entre los cuales están la detección de cáncer de mama, cáncer de piel o cáncer de estómago.

Durante la 14^{va} conferencia de avances en computación, control y telecomunicaciones de 2023, un grupo de estudiantes de diferentes programas de pregrado de ingeniería, presentaron la base de un proyecto mayor que se enfoca en la detección del cáncer de piel a través del uso de redes convolucionales, centrándose en la detección de melanomas siguiendo ciertos patrones.

Sin embargo, ellos se basaron en el artículo científico “Melanoma Detection by analysis of clinical images using convolutional neural network”, el cual muestra una viabilidad en la detección de melanomas usando CNN.

El artículo sugiere integrar un sistema de aprendizaje profundo en un servidor con una unidad de procesamiento gráfico (GPU) para detectar lesiones de melanoma. Se emplean imágenes clínicas, no dermatoscópicas, en este sistema propuesto, el cual podría ser una herramienta útil para asistir a los dermatólogos en el diagnóstico precoz del cáncer de piel. (E Nasr-Esfahani, et al 2016)

En el sistema propuesto, las imágenes clínicas de entrada, que podrían contener efectos de iluminación y ruido, son procesadas para reducir estos efectos. Posteriormente, las imágenes mejoradas alimentando una red neuronal convolucional (CNN) pre-entrenada. El clasificador de CNN, entrenado con un gran número de muestras de entrenamiento, distingue entre casos de melanoma y benignos. Los resultados experimentales muestran que el método propuesto es superior en precisión diagnóstica en comparación con los métodos más avanzados. (E Nasr-Esfahani, et al 2016)

En un segundo texto, se ahonda en diferentes alternativas de inteligencia artificial y machine learning para la detección del cáncer de mama, integrantes de la IEEE investigaron diferentes métodos no probados, pero si investigados y propuestos para la detección del cáncer de mama.

Se estableció una base de datos estandarizada que contiene publicaciones fundamentales para revisiones metodológicas. El objetivo principal de esta revisión es evaluar mejor la efectividad del Deep learning en las aplicaciones del cáncer de mama. La investigación sigue tres etapas principales: recopilación de datos, análisis de datos y resumen de los resultados iniciales. Los resultados destacan la precisión como la métrica predominante y completa utilizada en la evaluación de las herramientas de DL en diversas aplicaciones de cáncer de mama.

Se ha concluido que las redes neuronales convolucionales (CNN) tienen una utilidad generalizada, superando notablemente a otros métodos de Deep Learning. Por otro lado, el trabajo en equipo colaborativo y el empleo de técnicas avanzadas de Deep Learning ofrecen un rendimiento óptimo. (Ardabili, S, et. Al 2023).

Finalmente, el texto “A Systematic Review on Detection of Gastric Cancer in Endoscopic Imaging System in Artificial Intelligence Applications”, investiga la posibilidad de uso del DL en la detección del cáncer de estómago.

Gracias a los avances actuales en esta tecnología, es posible concluir que el sector de la medicina se va a ver afectado positivamente por la inclusión de diferentes algoritmos de DL, en especial aquel que detecte el cáncer de estómago (Pooja, K., et al 2024)). Sin embargo, el texto no muestra una investigación exhaustiva ni un prototipo, es basado en opiniones y evidencia de avances científicos.

Pero este tipo de trabajos muestra que existe la posibilidad de revolucionar la medicina y optimizar los procesos actuales mediante la aplicación de algoritmos de inteligencia artificial y Deep Learning.

Mejores prácticas de IA.

La industria tecnológica cambia en seguridad y privacidad, por la cantidad de actividades que pueden vulnerar los datos y exponer información sensible, por lo que hay que mencionar estándares y mejores prácticas en el desarrollo de estos proyectos.

La ética y la seguridad son consideraciones fundamentales en el desarrollo y aplicación de la inteligencia artificial (IA). Russell y Norvig (2010) advierten sobre la importancia de incorporar principios éticos en el diseño de sistemas de IA para garantizar que sus acciones sean moralmente responsables y socialmente aceptables. Es crucial que los desarrolladores de IA consideren los posibles impactos negativos de sus sistemas en la sociedad y tomen medidas para mitigar cualquier riesgo potencial.

En cuanto a la seguridad, los autores señalan la necesidad de implementar buenas prácticas de seguridad cibernética para proteger los sistemas de IA contra amenazas externas, como ataques de hackers o manipulación maliciosa de datos. Esto incluye el uso de técnicas de cifrado robustas, la autenticación de usuarios y la vigilancia constante de posibles vulnerabilidades. Además, Russell y Norvig enfatizan la importancia de la transparencia y la rendición de cuentas en el desarrollo y despliegue de sistemas de IA, permitiendo una supervisión adecuada y la identificación rápida de cualquier problema ético o de seguridad que pueda surgir.

Papagiannidis y compañía en su texto “Toward AI Governance: Identifying Best Practices and Potential Barriers and Outcomes”, examinan las actividades subyacentes de la gobernanza de la inteligencia artificial (IA) en organizaciones, centrándose en las dimensiones estructurales, relacionales y procedimentales de la misma. A través de un análisis de casos múltiples de tres organizaciones con experiencia en IA.

se identificaron actividades relevantes y desafíos enfrentados durante las implementaciones de IA, destacando la necesidad de abordar preocupaciones a nivel personal y organizativo. Se destaca la importancia de la gobernanza de IA para impulsar la innovación digital, resaltando el papel de la IA en la transformación de operaciones empresariales mediante análisis de información imparcial y basada en evidencia, aunque se reconoce la necesidad de comprender las emociones humanas para mejorar la emulación del razonamiento humano por parte de la IA. (Papagiannidis, E., Enholm, I.M., Dremel, C. et al, 2023)

Tomando en cuenta lo anterior, es posible concluir que, en el ámbito de la medicina, las buenas prácticas en torno a la inteligencia artificial (IA) son esenciales para garantizar su seguridad, eficacia y ética. Esto implica la transparencia de los sistemas de IA, asegurando que puedan justificar sus decisiones y detectar posibles sesgos. Además, se requiere una validación rigurosa y regulación adecuada de los algoritmos para garantizar su precisión y cumplimiento con los estándares éticos y de privacidad de los datos. La colaboración interdisciplinaria entre médicos, científicos de datos y otros profesionales de la salud también

es fundamental para desarrollar soluciones efectivas y éticas, mientras que la evaluación continua y la mejora garantizan que los sistemas de IA se mantengan actualizados y adaptables a las necesidades clínicas cambiantes.

ANÁLISIS DE ALTERNATIVAS.

Dentro de un ambiente académico pueden existir diversas restricciones al acceso de la información o a equipos necesarios para el desarrollo del proyecto, por ello se plantean las siguientes alternativas:

Alternativa 1 - Uso de base de datos disponible con datos limitados.

Debido a la escasez de bases de datos abiertas y accesibles que contengan imágenes médicas suficientes y de calidad, esta alternativa propone utilizar las bases de datos libres disponibles, aunque contengan una cantidad limitada de imágenes de muestras. Estas bases de datos, aunque reducidas, pueden ser valiosas para la construcción y entrenamiento inicial del modelo de inteligencia artificial.

Entre las ventajas, destaca la accesibilidad, ya que estas bases de datos están disponibles sin costo y legalmente, lo que permite comenzar a trabajar de inmediato sin problemas legales ni esperas. Sin embargo, entre las desventajas se encuentra la limitación en la cantidad de datos, lo cual puede afectar la capacidad del modelo para generalizar y reconocer patrones en datos nuevos. Además, la variedad insuficiente y la posible variabilidad en la calidad de las imágenes pueden reducir la efectividad y precisión del modelo.

Alternativa 2 - Uso de características clínicas en lugar de imágenes.

Ante la dificultad para consolidar imágenes médicas debido a restricciones en el acceso a sistemas de almacenamiento de datos e imágenes médicas, una alternativa viable es enfocarse en el análisis de características clínicas de las muestras y los pacientes. Esto implica utilizar datos como síntomas, colores presentes en las muestras, la forma, el tamaño, la presencia de anomalías nucleares y la organización tisular, hábitos de salud y otros factores relevantes para la predicción del cáncer cervicouterino. Mediante técnicas de minería de datos y aprendizaje automático, se puede desarrollar un modelo que emplee estas características para realizar diagnósticos con un enfoque más centrado en los datos clínicos disponibles en lugar de imágenes.

Alternativa 3 - Simulación de datos o uso de conjuntos de datos disponibles.

Si no hay acceso directo a imágenes médicas o no una cantidad considerable de estas, una alternativa es recurrir a la simulación de datos. Se podría generar un conjunto de datos sintéticos que representen características similares a las muestras reales de cáncer cervicouterino, lo cual permitiría entrenar y evaluar los modelos de inteligencia artificial. Asimismo, se podrían aprovechar conjuntos de datos abiertos de imágenes médicas disponibles en repositorios públicos, aunque estos podrían no estar específicamente

enfocados en el cáncer cervicouterino, requerirían adaptación y validación de cito-histólogos para su uso en el proyecto.

Alternativa 4 – Desarrollo del modelo mediante datos clínicos y anamnesis de pacientes.

En caso de no contar con equipos de captura de imágenes de muestras podría ser utilizar datos clínicos y anamnesis para la detección del cáncer cervicouterino. En lugar de depender exclusivamente de imágenes citohistológicas, se podrían recopilar datos detallados sobre el historial médico del paciente, incluidos antecedentes familiares de cáncer cervicouterino, historial de infección por Virus del papiloma humano (VPH), resultados de pruebas de Papanicolaou anteriores y síntomas presentes. Estos datos podrían combinarse con factores de riesgo conocidos, como la edad y otros determinantes socioeconómicos, para desarrollar modelos predictivos basados en algoritmos de aprendizaje automático. Estos modelos podrían ayudar a identificar patrones y correlaciones entre los datos clínicos y la presencia de cáncer cervicouterino, lo que permitiría realizar diagnósticos tempranos y precisos sin la necesidad de imágenes citohistológicas.

ANALISIS DE RESTRICCIONES.

Restricciones Técnicas.

- Se requiere hardware con potencia de procesamiento adecuada para ejecutar algoritmos de inteligencia artificial (IA) complejos en tiempo real, como procesadores multi-core y suficiente memoria RAM (al menos 16GB).
- Es necesario contar con almacenamiento suficiente, preferiblemente unidades de estado sólido (SSD) de alta capacidad, para manejar grandes volúmenes de datos de imágenes médicas y modelos de IA.
- Se deben utilizar herramientas y frameworks adecuados de IA, como TensorFlow o PyTorch, para el desarrollo y despliegue de algoritmos de aprendizaje automático. Ya que estas herramientas son ampliamente reconocidas en la comunidad de IA por su eficacia, funcionalidad y soporte, y son las más recomendables para implementar esta solución.
- Se requiere una conectividad confiable para integrar el sistema con dispositivos médicos y acceder a recursos en la nube. La falta de disponibilidad de conexión puede afectar significativamente el funcionamiento del sistema y su capacidad para acceder a datos críticos o realizar procesamiento en tiempo real.

Restricciones Normativas.

La necesidad de cumplir con las regulaciones colombianas, como la Ley Estatutaria 1581 de 2012 y las resoluciones 1995 de 1999 y 2019, impone restricciones importantes para la realización del proyecto:

- **Cumplimiento Legal Obligatorio:** El proyecto debe cumplir estrictamente con la Ley Estatutaria 1581 de 2012, que regula el tratamiento de datos personales en Colombia. Esto implica que los datos médicos recopilados, incluidas las imágenes de células cancerígenas y la información asociada, debe manejarse según los principios y requisitos establecidos por esta ley.
- **Medidas de Seguridad Específicas:** La resolución 1995 de 1999 establece medidas específicas de seguridad y procedimientos para proteger la confidencialidad, integridad y disponibilidad de la historia clínica de los pacientes en el sector médico colombiano. Esta medida podría limitar el proyecto al no poder proporcionarnos las imágenes celulares requeridas por tratamientos de confidencialidad.

Restricciones Sociales.

Una restricción social significativa que podría afectar el proyecto es la percepción y preocupación de que la implementación de la IA en el diagnóstico médico pueda amenazar los empleos de los profesionales de la salud. Esta preocupación podría surgir debido a la creencia de que la IA podría reemplazar el trabajo humano en la interpretación de imágenes médicas y el diagnóstico de enfermedades como el cáncer cervicouterino.

Las influencias sociales y las percepciones culturales pueden generar resistencia hacia la adopción de soluciones basadas en IA en el ámbito médico. Los profesionales de la salud podrían sentirse amenazados por la idea de que la IA podría suplantar sus roles y responsabilidades, generando temores sobre la pérdida de empleos o la reducción de la necesidad de intervención humana en el proceso de diagnóstico.

Esta percepción negativa podría afectar la aceptación y la adopción del sistema basado en IA que se propone desarrollar para el diagnóstico del cáncer cervicouterino. Podría generar resistencia por parte de los profesionales de la salud y los pacientes, obstaculizando la implementación exitosa de la tecnología.

Para abordar esta restricción social, es esencial implementar estrategias de comunicación efectivas sobre los beneficios complementarios de la IA en el campo médico. Es importante destacar que la IA está diseñada para mejorar la eficiencia, precisión del diagnóstico y apoyar a los médicos en su labor, permitiendo que los profesionales de la salud se centren en tareas más complejas y especializadas, como el desarrollo de tratamientos personalizados y la atención directa a los pacientes.

Restricciones Ambientales.

Colombia está experimentando una crisis ambiental debido al bajo nivel de agua en embalses y represas esenciales para el suministro de agua y energía a varias ciudades. Como medida

preventiva debido al fenómeno del Niño, Colombia ha suspendido el suministro de energía a Ecuador, que ahora está implementando cortes de energía durante 10 horas. Si no mejora la situación de los embalses y represas, podríamos enfrentar cortes de energía en nuestro propio país para conservar el agua. Esto afectaría directamente el desarrollo del proyecto, ya que necesitamos energía para el funcionamiento adecuado de los equipos de desarrollo

Restricciones adicionales.

Capacidades y Conocimientos Técnicos.

Las habilidades y conocimientos técnicos actuales de los implicados en el proyecto en inteligencia artificial, procesamiento de imágenes y programación. Puede que se requiera capacitación adicional en áreas específicas para realizar el proyecto de manera efectiva.

Limitaciones de Tiempo y Disponibilidad.

Las limitaciones de tiempo y disponibilidad del experto médico podrían afectar la creación y desarrollo del proyecto. Ya que directamente nos apoyará en la construcción y verificación del correcto funcionamiento de la IA. Es esencial considerar la agenda y disponibilidad de los expertos médicos que puedan asesorar en la construcción del proyecto, lo cual podría influir en la planificación y ejecución de las actividades.

METODOLOGÍA PARA LA SELECCION Y DESARRROLLO DE LA SOLUCIÓN.

A partir del análisis, la alternativa 1 se acopla a las limitaciones y se elige para el desarrollo del proyecto.

Recolección y Preparación de Datos: Se realizará una búsqueda exhaustiva en la literatura científica y repositorios públicos para identificar bases de datos abiertas con imágenes citológicas relevantes. Una vez identificadas, se procederá a la limpieza y normalización de las imágenes para asegurar la calidad y consistencia de los datos. Además, las imágenes serán anotadas y clasificadas según el sistema Bethesda 2014, con la colaboración de expertos en citología para garantizar la precisión.

Por otra parte, El modelo de inteligencia artificial se diseñará utilizando técnicas de aprendizaje supervisado, como redes neuronales convolucionales (CNN). Las imágenes depuradas y clasificadas se utilizarán para entrenar el modelo. La evaluación del modelo se realizará utilizando métricas como precisión, sensibilidad y especificidad, comparando los resultados con diagnósticos realizados por citólogos expertos y ajustando el modelo según sea necesario.

Una vez entrenado, el modelo será sometido a pruebas exhaustivas en un entorno real para validar su eficacia. Finalmente, se documentará todo el proceso de desarrollo, entrenamiento e implementación.

Aceptación Actual de la Solución.

La solución basada en IA es cada vez más aceptada en la comunidad médica y científica debido a su capacidad para mejorar la precisión y eficiencia de los diagnósticos. Investigaciones recientes han demostrado su efectividad, lo que refuerza la confianza en estas tecnologías como herramientas complementarias valiosas para los profesionales de la salud.

Cambios Implicados por la Solución.

La implementación de esta solución implicará cambios tecnológicos, como la integración de nuevas herramientas de software y hardware; operacionales, adaptando los flujos de trabajo clínicos para incluir sistemas automatizados; formativos, capacitando al personal de salud en el uso y la interpretación de los resultados de IA; y regulatorios, asegurando el cumplimiento de normativas de seguridad y privacidad de datos.

Recursos Implicados en la Solución.

Los recursos necesarios incluyen:

- Humanos: Personal técnico especializado en IA, citólogos para anotación y validación, y personal médico para la integración y uso del sistema.
- Económicos: Inversión en tecnología, capacitación del personal y posibles colaboraciones con instituciones de investigación.
- Materiales: Acceso a bases de datos de imágenes citológicas y sistemas de almacenamiento seguros.
- Tiempo: Desarrollo, entrenamiento, evaluación y validación del modelo, así como la adaptación de flujos de trabajo.

Implicaciones de las Soluciones.

Las implicaciones incluyen:

- Mejora en la Calidad del Diagnóstico: Mayor precisión y rapidez en la detección de anomalías, mejorando los resultados para los pacientes.
- Reducción de la Carga de Trabajo: Automatización del proceso de diagnóstico, permitiendo a los citólogos centrarse en casos más complejos.

- **Desafíos Éticos y Regulatorios:** Garantizar la privacidad y seguridad de los datos, cumpliendo con normativas vigentes y enfrentando posibles reticencias del personal y pacientes hacia la tecnología.

OFERTA DE VALOR

Costo Actual del Análisis de Muestras Oncológicas.

En Colombia, el costo del servicio de citología varía entre \$14,000 y \$20,000 COP. El análisis de una muestra oncológica de células cervicales depende del laboratorio y la tecnología empleada. El pago a los profesionales oscila entre \$2,900 y \$3,300 COP por muestra. Este costo cubre el análisis manual realizado por citólogos, el uso de equipos y reactivos, y el tiempo requerido para procesar y evaluar cada muestra.

Ventajas de la IA.

Reducción de Costos.

La automatización del análisis mediante IA puede reducir significativamente los costos operativos, al disminuir la dependencia de análisis manual intensivo en tiempo y recursos humanos. Se estima que la implementación de un sistema de IA podría reducir el costo por muestra en un 30-50%.

Mayor Precisión y Consistencia.

Los sistemas de IA han demostrado ayuda gracias a su capacidad de precisión al detectar anomalías celulares, reduciendo el margen de error humano y mejorando la consistencia de los diagnósticos.

Rapidez en el Diagnóstico.

La IA puede analizar y procesar grandes volúmenes de muestras en un tiempo significativamente menor que el análisis manual, permitiendo una detección más rápida y oportuna.

Escalabilidad.

La IA puede escalar fácilmente para manejar un mayor volumen de muestras sin comprometer la calidad del análisis, esencial para las EPS al manejar grandes cantidades de pacientes.

Mejora en la Calidad del Servicio.

La alta precisión y rapidez del diagnóstico mejorarán los resultados clínicos, aumentando la satisfacción del paciente y la calidad del servicio prestado.

Aumento de la Capacidad Diagnóstica.

Con la IA, las EPS podrán manejar un mayor volumen de muestras sin la necesidad de incrementar proporcionalmente el personal de laboratorio, facilitando la gestión de picos de demanda.

Eficiencia y Sostenibilidad.

La adopción de tecnologías avanzadas y sostenibles contribuye al posicionamiento de las EPS como líderes en innovación y eficiencia en el sector salud.

Liberación de Recursos Humanos.

La automatización permite que los citólogos se enfoquen en casos más complejos y en la atención directa al paciente, mejorando la eficiencia del personal de salud.

ANÁLISIS DE COSTOS Y MODELO DE NEGOCIO

Costos de Desarrollo del Proyecto (versión inicial).

Salarios.

- Número de Desarrolladores: 2
- Salario Mensual por Desarrollador: \$0 COP
- Duración del Proyecto: 1 mes
- Costo Total de Salarios: 0

Costo de Energía.

- Consumo Energético Diario por Equipo de Desarrollo: aprox. 1 kWh (para los dos equipos combinados)
- Costo por kWh en Colombia: \$737.6 COP
- Número de Equipos: 2
- Horas de Desarrollo Diarias: 4 horas
- Duración del Proyecto: 1 mes

- Costo Total de Energía: $1 \text{ kWh} \times \$737.6 \times 4 \text{ horas} \times 30 \text{ días} = \$88,512 \text{ COP}$

Otros Gastos (Hardware, Software, Licencias, etc.).

- Costo Aproximado Total: \$0 se usaron licencias de código abierto

Costos Totales de Desarrollo.

- Salarios de los Creadores: \$0 COP
- Energía: \$88,512 COP
- Otros Gastos: \$0
- Costo Total de Desarrollo: \$88,512 COP

Costos de Desarrollo del Proyecto (escalado a futuro).

Salarios:

- Número de Desarrolladores: 5
- Salario Mensual por Desarrollador: \$6,000,000 COP
- Duración del Proyecto: 6 meses
- Costo Total de Salarios: $5 \times \$6,000,000 \times 6 = \$180,000,000 \text{ COP}$

Costo de Energía:

- Consumo Energético Diario por Servidor: 20 kWh
- Costo por kWh en Colombia: \$737.6 COP
- Número de Servidores: 4

- Duración del Proyecto: 6 meses
- Costo Total de Energía: $20 \text{ kWh} \times \$737.6 \times 4 \times 30 \text{ días} \times 6 \text{ meses} = \$10,621,440 \text{ COP}$

Otros Gastos (Hardware, Software, Licencias, etc.):

- Precio de cada Servidor: \$10,000,000 COP
- Número de Servidores: 4
- Costo Total de los Servidores: $4 \times \$10,000,000 = \$40,000,000 \text{ COP}$
- Licencias de Software:
 - Sistema Operativo (por servidor): $\$1,500,000 \text{ COP} \times 4 \text{ servidores} = \$6,000,000 \text{ COP}$
 - Herramientas de IA y Frameworks: \$3,000,000 COP
 - Servicios en la Nube (suplementarios): \$1,000,000 COP
- Otros Gastos (Hardware adicional, etc.): \$5,000,000 COP
- Costo Aproximado Total de Otros Gastos: $\$40,000,000 \text{ (servidores)} + \$6,000,000 \text{ (sistema operativo)} + \$3,000,000 \text{ (herramientas de IA)} + \$1,000,000 \text{ (servicios en la nube)} + \$5,000,000 \text{ (otros)} = \$55,000,000 \text{ COP}$

Costos Totales de Desarrollo:

- Salarios de los Creadores: \$180,000,000 COP
- Energía: \$10,621,440 COP
- Otros Gastos: \$55,000,000 COP
- Costo Total de Desarrollo: $\$180,000,000 + \$10,621,440 + \$55,000,000 = \$245,621,440 \text{ COP}$

Modelo de negocio.

El modelo de negocio se centra en ofrecer a las EPS colombianas una solución completa para la detección de anomalías de las células cervicales mediante inteligencia artificial.

Comenzamos con una tarifa única de instalación, seguida de una suscripción mensual que cubre soporte continuo y actualizaciones. Además, se cobra un pequeño costo por muestra procesada. Este enfoque garantiza una implementación sin problemas, un servicio de alta calidad y un costo efectivo para las EPS.

Oferta de Valor para EPS.

- Tarifa de Instalación Inicial: \$50,000,000 COP
- Suscripción Mensual: \$5,000,000 COP
- Costo por Muestra Procesada: \$500 COP

Costo Inicial de Instalación.

- Tarifa de Instalación Inicial: \$50,000,000 COP

Costo Anual de Operación con IA.

- Suscripción Mensual: \$5,000,000 COP x 12 = \$60,000,000 COP
- Costo por Muestra Procesada: \$500 COP x 100 muestras/día x 365 días = \$18,250,000 COP
- Costo Total Anual de Operación con IA: \$60,000,000 + \$18,250,000 = \$78,250,000 COP

Comparación de Costos Anuales (sin IA vs. con IA).

- Costo Anual sin IA: \$3,300 x 100 muestras/día x 365 días = \$120,450,000 COP
- Costo Anual con IA: \$78,250,000 COP
- Ahorro Anual con IA: \$120,450,000 - \$78,250,000 = \$42,200,000

RESULTADOS Y ANÁLISIS.

El script de construcción de la inteligencia artificial fue realizado en Python. Python está diseñado para entrenar y evaluar un modelo de aprendizaje profundo utilizando imágenes para la clasificación. Emplea diversas bibliotecas para el procesamiento de imágenes, la construcción del modelo, y la visualización de los resultados, facilitando así un flujo completo desde la preparación de los datos hasta la evaluación del rendimiento del modelo.

Importación de Bibliotecas.

Se importan bibliotecas esenciales como **os** y **shutil** para la gestión de archivos, **numpy** y **pandas** para el manejo de datos, **cv2** de **OpenCV** para el procesamiento de imágenes, y **seaborn** y **matplotlib** para la visualización. Además, se utilizan componentes de **tensorflow.keras** y **sklearn** para la construcción, entrenamiento y evaluación del modelo de aprendizaje profundo.

```
In [25]: import os
import shutil
import numpy as np
import itertools
import pandas as pd
import cv2
import seaborn as sns
import matplotlib.pyplot as plt
from sklearn.metrics import confusion_matrix, classification_report, roc_curve, auc
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten, Dense, Dropout, GlobalAveragePooling2D
from tensorflow.keras.utils import to_categorical, plot_model
from tensorflow.keras.callbacks import ModelCheckpoint
from tensorflow.keras.models import load_model
from tensorflow.keras.layers import Input
from tensorflow.keras.layers import BatchNormalization
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import EarlyStopping
from tensorflow.keras.layers import Dropout
from sklearn.model_selection import train_test_split
from tensorflow.keras.applications import VGG16
```

Ilustración 4 Importación de librerías

Rutas de las Carpetas.

Se definen las rutas a las carpetas de entrenamiento, validación y datos reales. Estas rutas son esenciales para acceder a los conjuntos de datos necesarios durante el entrenamiento y la evaluación del modelo. Las imágenes están distribuidas en dos carpetas, una de entrenamiento y otra de validación, estas a su vez están divididas en tres categorías a las cuales se van a clasificar (HSIL, LSIL y NEGATIVO).

.ipynb_checkpoints	6/5/2024 6:40 PM	Carpeta de archivos	
REAL	6/2/2024 10:04 PM	Carpeta de archivos	
train	6/3/2024 12:52 PM	Carpeta de archivos	
val	6/3/2024 12:52 PM	Carpeta de archivos	
best_model.keras	6/3/2024 3:33 PM	Archivo KERAS	448,300 KB
PREDICION	6/5/2024 6:47 PM	Archivo de origen ...	23 KB
PROYECTO_GRADO	6/8/2024 6:50 PM	Archivo de origen ...	304 KB

Ilustración 5 Directorios del proyecto

Nombre	Fecha de modificación	Tipo	Tamaño
HSIL	6/3/2024 1:36 PM	Carpeta de archivos	
LSIL	6/3/2024 2:51 PM	Carpeta de archivos	
NEGATIVO	6/3/2024 3:10 PM	Carpeta de archivos	

Ilustración 6 Clasificación de imágenes

Parámetros.

Se establecen parámetros clave como la altura y el ancho de las imágenes, el tamaño del lote, y el número de épocas. Estos parámetros configuran el entorno de entrenamiento del modelo, asegurando que las imágenes sean procesadas de manera uniforme y que el entrenamiento se ejecute de manera controlada.

```
In [3]: img_height, img_width = 150, 150
        batch_size = 32
        epochs = 15
```

Ilustración 7 definición de parámetros

Preparación de Generadores de Flujo de Datos.

Se crean generadores de datos utilizando *ImageDataGenerator* de **Keras** para aplicar aumentos, cambios de color y escalado a las imágenes de entrenamiento y validación. Esto ayuda a mejorar la robustez del modelo mediante la creación de variaciones de las imágenes de entrada.

```
In [4]: # Crear generadores de datos
train_datagen = ImageDataGenerator(
    rotation_range=20,
    width_shift_range=0.2,
    height_shift_range=0.2,
    shear_range=0.2,
    zoom_range=0.2,
    horizontal_flip=True,
    rescale=1./255 # Escalar píxeles al rango [0, 1]
)

validation_datagen = ImageDataGenerator(rescale=1./255)

# Generadores de datos
train_generator = train_datagen.flow_from_directory(
    train_dir,
    target_size=(img_height, img_width),
    batch_size=batch_size,
    class_mode='categorical',
    color_mode='grayscale' # Especificar el modo de color como blanco y negro
)

validation_generator = validation_datagen.flow_from_directory(
    val_dir,
    target_size=(img_height, img_width),
    batch_size=batch_size,
    class_mode='categorical',
    color_mode='grayscale' # Especificar el modo de color como blanco y negro
)
```

Found 955 images belonging to 3 classes.
Found 435 images belonging to 3 classes.

Ilustración 8 Generación de datos de entrenamiento y validación

Definición y Compilación del Modelo.

Se construye un modelo secuencial de **Keras** compuesto por capas de convolución, agrupamiento, aplanamiento, densas y de abandono (Dropout). Este modelo está diseñado para procesar imágenes en escala de grises y clasificar en tres categorías utilizando una capa de salida softmax.

El modelo se compila con el optimizador Adam y la función de pérdida de entropía cruzada categórica. Además, se configuran métricas de precisión para evaluar el rendimiento durante el entrenamiento.

Definición del modelo

```
In [5]: model = Sequential([
    Conv2D(64, (3, 3), activation='relu', input_shape=(img_height, img_width, 1)),
    MaxPooling2D((2, 2)),
    Conv2D(128, (3, 3), activation='relu'),
    MaxPooling2D((2, 2)),
    Conv2D(256, (3, 3), activation='relu'),
    MaxPooling2D((2, 2)),
    Flatten(),
    Dense(512, activation='relu'),
    Dropout(0.5),
    Dense(3, activation='softmax')
])
```

C:\Users\chech\anaconda3\Lib\site-packages\keras\src\layers\convolutional\base_conv.py:107: UserWarning: Do not pass an `input_shape`/`input_dim` argument to a layer. When using Sequential models, prefer using an `Input(shape)` object as the first layer in the model instead.
 super().__init__(activity_regularizer=activity_regularizer, **kwargs)

compilar el modelo

```
In [6]: model.compile(optimizer='adam',
    loss='categorical_crossentropy',
    metrics=['accuracy'])
model.summary()
```

Ilustración 9 Definición y Compilación del modelo.

Entrenamiento del Modelo.

Se configura el entrenamiento del modelo utilizando los generadores de datos, con callbacks para guardar el mejor modelo y detener el entrenamiento temprano si no hay mejora en la pérdida de validación. El entrenamiento se ejecuta durante un número especificado de épocas, evaluando el rendimiento en cada iteración.

Entrenamiento del modelo

```
In [7]: ## Configurar callbacks
checkpoint = ModelCheckpoint('best_model.keras', monitor='val_accuracy', save_best_only=True, mode='max')
early_stopping = EarlyStopping(monitor='val_loss', patience=5, restore_best_weights=True)

# Entrenar el modelo
history = model.fit(
    train_generator,
    epochs=epochs,
    validation_data=validation_generator,
    callbacks=[checkpoint, early_stopping]
)
```

Epoch 1/15

C:\Users\chech\anaconda3\Lib\site-packages\keras\src\trainers\data_adapters\py_dataset_adapter.py:121: UserWarning: Your `PyDataset` class should call `super().__init__(**kwargs)` in its constructor. `**kwargs` can include `workers`, `use_multiprocessing`, `max_queue_size`. Do not pass these arguments to `fit()`, as they will be ignored.
 self._warn_if_super_not_called()

30/30 — 47s 1s/step - accuracy: 0.3631 - loss: 2.0922 - val_accuracy: 0.3333 - val_loss: 1.1181

Ilustración 10 Entrenamiento del modelo

Una época es una iteración completa a través del conjunto de datos de entrenamiento. Durante una época, el modelo procesa cada ejemplo en el conjunto de datos exactamente una vez, a medida que se reprocesan las imágenes hay una mejora gradual de la precisión del modelo (Retropropagación).

Carga del Modelo y Evaluación del Modelo.

Se carga el mejor modelo guardado desde el archivo donde reposa la IA para su posterior evaluación. Esto permite utilizar el modelo con el mejor rendimiento registrado durante el entrenamiento.

El modelo cargado se utiliza para predecir las clases de las imágenes de validación. Los resultados de las predicciones se comparan con las clases reales para evaluar el rendimiento del modelo.

Se generan gráficos de las curvas de precisión y pérdida durante el entrenamiento y la validación. Estas visualizaciones ayudan a detectar problemas de sobreajuste y a evaluar la estabilidad del entrenamiento.




Ilustración 11 Precisión y pérdida del modelo

La imagen anterior muestra dos gráficos que ilustran la precisión y la pérdida del modelo durante el entrenamiento y la validación a lo largo de las épocas. En el gráfico de la izquierda, la precisión de entrenamiento (línea azul) aumenta constantemente, indicando una mejora continua del modelo en el conjunto de datos de entrenamiento, mientras que la precisión de validación (línea naranja) es más variable y menos constante, sugiriendo posible sobreajuste. En el gráfico de la derecha, la pérdida de entrenamiento (línea azul) disminuye consistentemente, señalando una reducción del error en el conjunto de entrenamiento, mientras que la pérdida de validación (línea naranja) también disminuye, pero con mayores

fluctuaciones, lo que puede indicar sobreajuste después de ciertas épocas. En conjunto, estos gráficos sugieren que el modelo está aprendiendo adecuadamente en el conjunto de entrenamiento, pero tiene problemas de generalización en el conjunto de validación, por lo que sería aconsejable ajustar los hiperparámetros o emplear técnicas adicionales para mejorar su rendimiento general.

Se construye y visualiza una matriz de confusión para analizar el rendimiento del modelo en cada clase. Además, se muestran los totales de predicciones por clase para proporcionar un contexto adicional sobre el rendimiento del modelo.

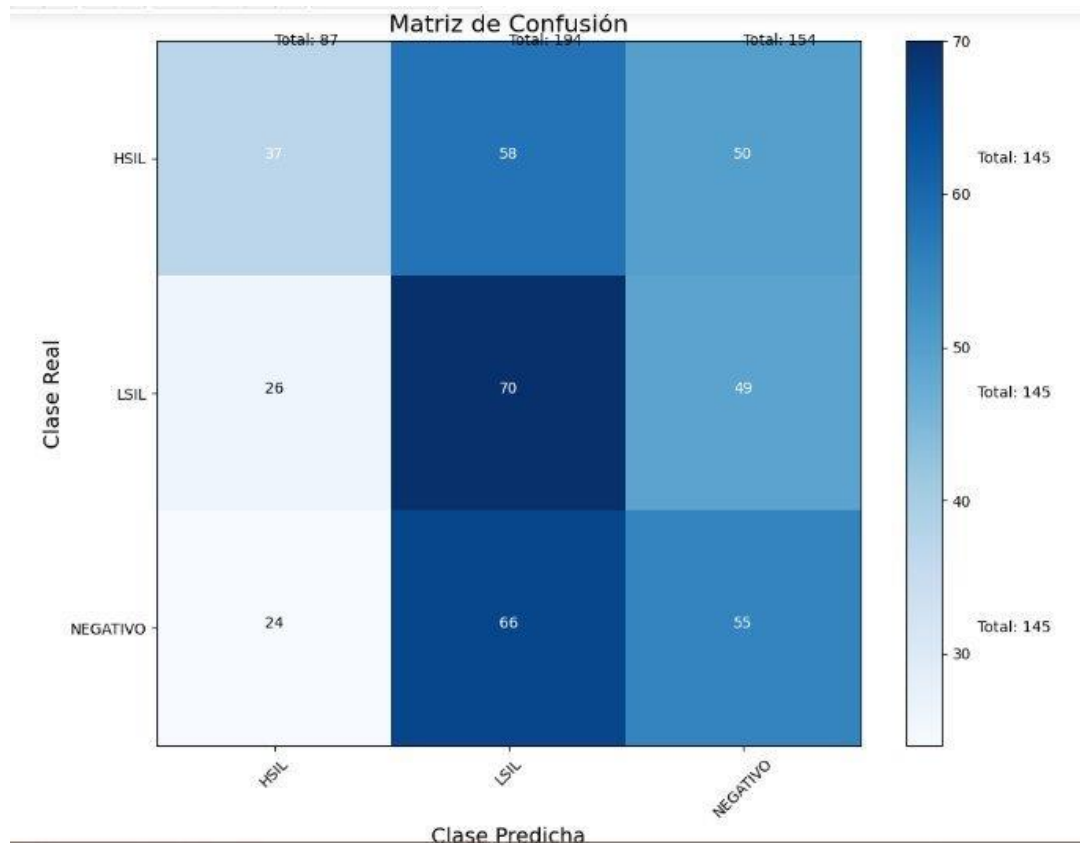


Ilustración 12 matriz de confusión del modelo

La matriz de confusión es útil para reconocer como se está clasificando cada una de las imágenes y como es la distribución de estas, se observa que, aunque la mayoría de las imágenes se predicen correctamente, la precisión no es suficiente para catalogarla como confiable.

Se genera un reporte de clasificación que incluye métricas como precisión, recall y F1-score para cada clase. Estas métricas se visualizan en un gráfico de barras para una interpretación rápida y clara del rendimiento del modelo.

Classification Report				
	precision	recall	f1-score	support
HSIL	0.43	0.26	0.32	145
LSIL	0.36	0.48	0.41	145
NEGATIVO	0.36	0.38	0.37	145
accuracy			0.37	435
macro avg	0.38	0.37	0.37	435
weighted avg	0.38	0.37	0.37	435

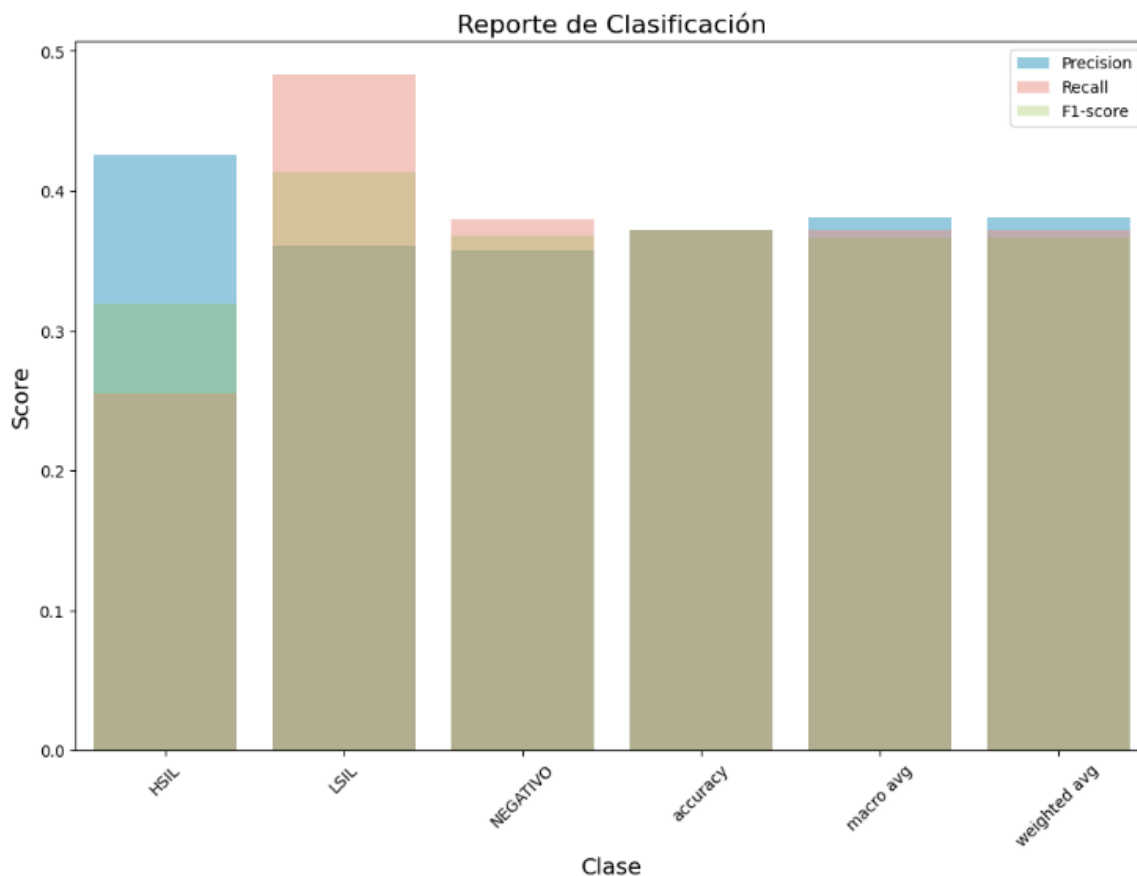


Ilustración 13 Reporte de clasificación

La imagen anterior presenta un Reporte de Clasificación y una gráfica de barras que detallan las métricas de evaluación del modelo para distintas clases.

El recall, también conocido como exhaustividad o sensibilidad, indica la proporción de verdaderos positivos entre todos los casos positivos reales, siendo crucial para evaluar la capacidad del modelo en identificar correctamente los casos positivos, minimizando los falsos negativos. Por otro lado, la exactitud (accuracy) mide la proporción de predicciones correctas sobre el total de predicciones, ofreciendo una visión general del desempeño del modelo en todas las clases. En cuanto al F1-score, este valor representa la media armónica de precisión y recall, proporcionando un equilibrio entre ambas métricas y siendo especialmente útil en casos de desbalance entre las clases, donde un alto F1-score indica un buen rendimiento general del modelo.

El reporte resalta las precisiones, recalls y F1-scores para HSIL, LSIL y NEGATIVO, mientras que las métricas globales ofrecen una visión general del rendimiento del modelo. La

gráfica de barras visualiza estas métricas por clase, facilitando la comparación entre ellas. El análisis revela que el modelo muestra un rendimiento moderado, con áreas de mejora identificadas, particularmente en la clase HSIL, donde el recall es bajo. Sugiere ajustes de hiperparámetros o técnicas de preprocesamiento para mejorar la generalización y el rendimiento global del modelo.

Se calculan y grafican las curvas ROC y el AUC para cada clase. Estas curvas permiten evaluar la capacidad del modelo para distinguir entre clases, proporcionando una visión detallada del rendimiento del modelo en términos de tasa de verdaderos positivos y falsos positivos.

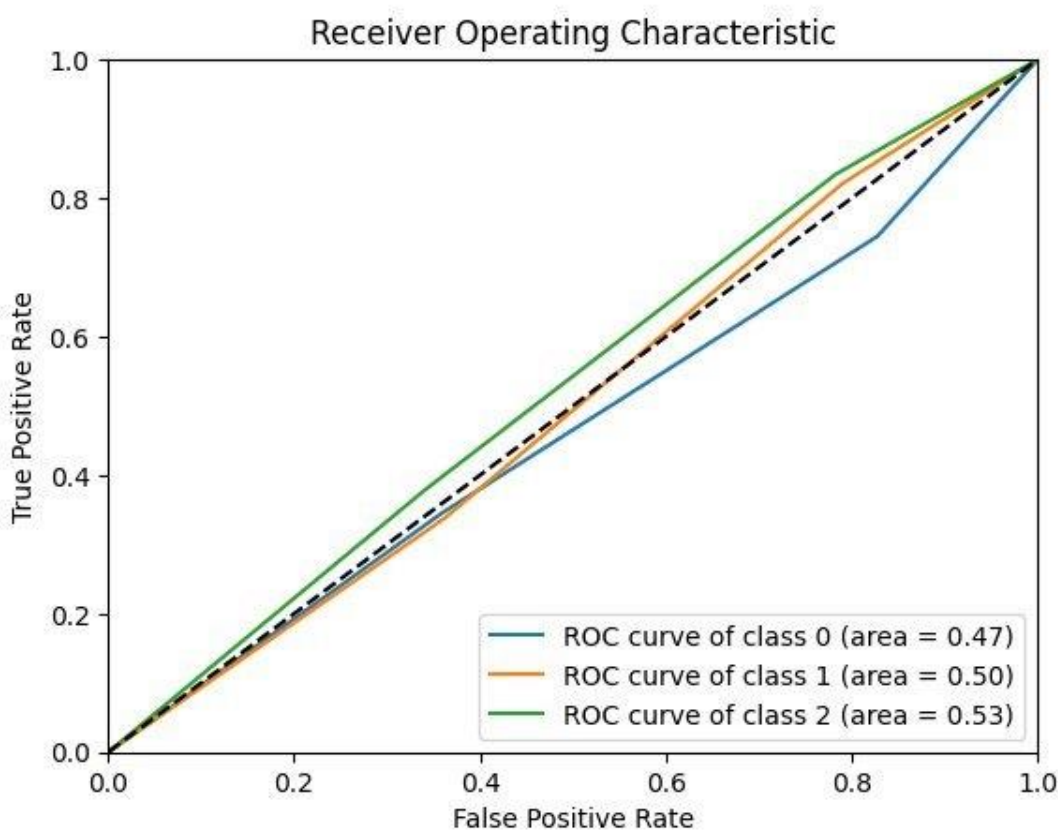


Ilustración 14 Cuerva ROC modelo

La imagen anterior exhibe las curvas ROC (Receiver Operating Characteristic) para tres clases distintas de un modelo de clasificación, acompañadas por las áreas bajo la curva (AUC, Area Under the Curve) correspondientes para cada clase. Cada curva ilustra la relación entre la tasa de verdaderos positivos (True Positive Rate, TPR) y la tasa de falsos positivos (False Positive Rate, FPR) a diversos umbrales de decisión. El análisis revela que todas las curvas están cercanas a la línea diagonal que representa un clasificador aleatorio, indicando un desempeño bajo-moderado del modelo para todas las clases, corroborado por los bajos valores de AUC. Se sugiere realizar ajustes en los hiperparámetros del modelo,

umentar la cantidad de datos de entrenamiento, aplicar técnicas de preprocesamiento adicionales o experimentar con diferentes arquitecturas de modelos para mejorar su rendimiento.

Predicción sobre imágenes fuera del conjunto de datos.

Para realizar predicciones sobre imágenes que sean integradas por los profesionales, se van a almacenar en la carpeta “REAL”, a partir de las imágenes que se encuentren en esta carpeta se van a realizar predicciones ejecutando el script “PREDICCION.IPYNB”.

```

model = load_model('best_model.keras')

# Directorio que contiene Las imágenes a predecir
directory = r'C:\Users\chech\IdeaProjects\proyecto grado\REAL'

# Obtener La Lista de archivos en el directorio
image_files = os.listdir(directory)
img_height, img_width = 150, 150
# Predecir para cada imagen en el directorio
for image_file in image_files:
    # Ruta completa de la imagen
    image_path = os.path.join(directory, image_file)

    # Cargar y preprocesar la imagen que deseas predecir
    image = cv2.imread(image_path)
    image = cv2.cvtColor(image, cv2.COLOR_BGR2GRAY) # Convertir a escala de grises
    image = cv2.resize(image, (img_height, img_width)) # Cambiar tamaño de la imagen
    image = np.expand_dims(image, axis=-1) # Agregar una dimensión adicional para que coincida con el formato de entrada
    image = image / 255.0 # Normalizar los píxeles al rango [0, 1] si es necesario

    # Realizar la predicción
    prediction = model.predict(np.array([image]))
    class_labels = {
        0: "HSIL",
        1: "LSIL",
        2: "NEGATIVO"
    }

    predicted_class = np.argmax(prediction)
    predicted_label = class_labels[predicted_class]

    # Imprimir el resultado
    print('Para la imagen', image_file, 'la clase predicha es:', predicted_label)

```

Ilustración 15 Script Predicción sobre imágenes reales

El código toma el modelo almacenado en la misma carpeta, realiza la predicción con cada imagen e imprime el resultado correspondiente junto con el nombre de la imagen que predijo.

```

1/1 _____ 0s 49ms/step
Para la imagen HSIL (6).png la clase predicha es: NEGATIVO
1/1 _____ 0s 76ms/step
Para la imagen HSIL (7).png la clase predicha es: NEGATIVO
1/1 _____ 0s 66ms/step
Para la imagen HSIL (8).png la clase predicha es: NEGATIVO
1/1 _____ 0s 65ms/step
Para la imagen HSIL (9).png la clase predicha es: NEGATIVO
1/1 _____ 0s 62ms/step
Para la imagen HSIL2 (1).png la clase predicha es: HSIL
1/1 _____ 0s 70ms/step
Para la imagen HSIL2 (10).png la clase predicha es: HSIL
1/1 _____ 0s 60ms/step
Para la imagen HSIL2 (11).png la clase predicha es: HSIL
1/1 _____ 0s 83ms/step
Para la imagen HSIL2 (12).png la clase predicha es: HSIL
1/1 _____ 0s 64ms/step
Para la imagen HSIL2 (13).png la clase predicha es: HSIL
1/1 _____ 0s 60ms/step
Para la imagen HSIL2 (14).png la clase predicha es: HSIL

```

Ilustración 16 predicción de imágenes de la carpeta "REAL"

CONCLUSIONES.

Se logró desarrollar un sistema basado en inteligencia artificial para detectar lesiones premalignas de cáncer cervical en muestras citológicas, esta solución se ha abordado mediante la creación y evaluación de un modelo de IA usando el lenguaje de programación Python. Sin embargo, a pesar de los avances logrados, el modelo aún no es lo suficientemente confiable para reemplazar el método manual debido a limitaciones en la base de datos utilizada.

Depuración de la base de datos.

Se depuró y clasificó una base de datos de imágenes citológicas. Sin embargo, la base de datos resultante no fue lo suficientemente grande ni diversa, lo que afectó negativamente la capacidad del modelo para generalizar y detectar correctamente todos los tipos de lesiones premalignas.

Diseño del modelo.

Se diseñó un modelo de aprendizaje supervisado utilizando técnicas avanzadas de visión computacional y procesamiento de imágenes. El modelo fue capaz de identificar ciertos

patrones característicos de células cancerígenas, pero la precisión general del modelo fue limitada por la calidad y cantidad de los datos de entrenamiento.

Entrenamiento del modelo.

El modelo de IA fue entrenado con la base de datos clasificada. Aunque mostró capacidad para definir y clasificar según los patrones, su rendimiento no logra clasificarse como confiable (precisión del $> 80\%$)

Evaluación del sistema.

La evaluación del sistema se realizó mediante pruebas exhaustivas con un conjunto de datos independiente. Los resultados de la detección automatizada se compararon con la clasificación previamente realizada. El análisis reveló que, aunque el modelo predice correctamente en la mayoría de los casos, su precisión, sensibilidad y especificidad no son lo suficientemente altas como para ser confiables. Esto se debe principalmente a la falta de una base de datos suficientemente grande y diversa para el entrenamiento del modelo.

RECOMENDACIONES.

Para mejorar la fiabilidad y precisión del sistema de inteligencia artificial en la detección de lesiones premalignas de cáncer cervical, se recomienda ampliar y diversificar la base de datos de imágenes citológicas. Es esencial recopilar más datos representativos de diversas poblaciones y condiciones clínicas para asegurar que el modelo pueda generalizar efectivamente. Además, se deben explorar técnicas avanzadas de aumento de datos (data augmentation) y transfer learning utilizando modelos pre-entrenados en grandes conjuntos de datos médicos. Implementar una colaboración con múltiples centros médicos y laboratorios podría facilitar la obtención de un conjunto de datos más amplio y variado. Paralelamente, es crucial realizar evaluaciones continuas del modelo y ajustes iterativos basados en el feedback de citólogos expertos para mejorar la precisión, sensibilidad y especificidad del sistema.

REFERENCIAS.

- Abdel-Basset, M., Mohamed, R., Alrashdi, I. et al (2024). CNN-IKOA: convolutional neural network with improved Kepler optimization algorithm for image segmentation: experimental validation and numerical exploration. J Big Data 11, 13.

<https://doi.org/10.1186/s40537-023-00858-6>

- Agoff, S. N., Lin, P., Morihara, J., Mao, C., Kiviat, N. B., & Koutsky, L. A. (2003). p16(INK4a) expression correlates with degree of cervical neoplasia: a comparison with Ki-67 expression and detection of high-risk HPV types. *Modern pathology: an official journal of the United States and Canadian Academy of Pathology, Inc*, 16(7), 665–673. <https://doi.org/10.1097/01.MP.0000077518.78046.0C>
- Arbyn, M., Ronco, G., Anttila, A., Meijer, C. J., Poljak, M., Ogilvie, G., Koliopoulos, G., Naucler, P., Sankaranarayanan, R., & Peto, J. (2012). Evidence regarding human papillomavirus testing in secondary prevention of cervical cancer. *Vaccine*, 30 Suppl 5, F88–F99. <https://doi.org/10.1016/j.vaccine.2012.06.095>
- Arbyn, M., Weiderpass, E., Bruni, L., de Sanjosé, S., Saraiya, M., Ferlay, J., & Bray, F. (2020). Estimates of incidence and mortality of cervical cancer in 2018: a worldwide analysis. *The Lancet. Global health*, 8(2), e191–e203. [https://doi.org/10.1016/S2214-109X\(19\)30482-6](https://doi.org/10.1016/S2214-109X(19)30482-6)
- Castle, P. E., Rausa, A., Walls, T., Gravitt, P. E., Partridge, E. E., Olivo, V., Niwa, S., Morrissey, K. G., Tucker, L., Katki, H., & Scarinci, I. (2011). Comparative community outreach to increase cervical cancer screening in the Mississippi Delta. *Preventive medicine*, 52(6), 452–455. <https://doi.org/10.1016/j.ypmed.2011.03.018>
- Castle, P. E., Stoler, M. H., Wright, T. C., Jr, Sharma, A., Wright, T. L., & Behrens, C. M. (2011). Performance of carcinogenic human papillomavirus (HPV) testing and HPV16 or HPV18 genotyping for cervical cancer screening of women aged 25 years and older: a subanalysis of the ATHENA study. *The Lancet. Oncology*, 12(9), 880–890. [https://doi.org/10.1016/S1470-2045\(11\)70188-7](https://doi.org/10.1016/S1470-2045(11)70188-7)
- Chan, H. P., Hadjiiski, L. M., & Samala, R. K. (2020). Computer-aided diagnosis in the era of deep learning. *Medical physics*, 47(5), e218–e227.

- Curia, F. Cervical cancer risk prediction with robust ensemble and explainable black boxes method. *Health Technol.* 11, 875–885 (2021). <https://doi-org.bdbiblioteca.universidadean.edu.co/10.1007/s12553-021-00554-6>
- Doi K. Chapter 1. Historical overview. In: Q Li, RM Nishikawa, eds. *Computer-Aided Detection and Diagnosis in Medical Imaging*. Boca Raton, FL: Taylor & Francis Group, LLC, CRC Press; 2015: 1–17.
- Escalante González, M. (2023). Aplicación de la inteligencia artificial para la detección del cáncer de mama. *Revista Medica Sinergia*, 8(12), e1113. <https://doi.org/10.31434/rms.v8i12.1113>
- Farghaly, S. A. (Ed.). (2019). *Uterine Cervical Cancer Clinical and Therapeutic Perspectives* (1st ed. 2019.). Springer International Publishing. <https://doi.org/10.1007/978-3-030-02701-8>
- Grigsby, P. W. (Ed.). (2014). *Advances in cervical cancer management*. Future Medicine Ltd.
- Löwy, I. (2011). *A woman's disease the history of cervical cancer*. Oxford University Press.
- Mejía, M., Rubiano, A., & Alzate, M. A. (2016). Segmentación de imágenes de células cervicales y evaluación de características para detección de lesiones neoplásicas. *Ingeniare. Revista Chilena de Ingeniería*, 24(2), 274-289. <https://doi.org/10.4067/s0718-33052016000200010>
- Nasr-Esfahani E, Samavi S, Karimi N, Soroushmehr SM, Jafari MH, Ward K, Najarian K. Melanoma detection by analysis of clinical images using convolutional neural network. *Annu Int Conf IEEE Eng Med Biol Soc.* 2016 Aug; 2016:1373-1376. doi: 10.1109/EMBC.2016.7590963. PMID: 28268581.

- Pangarkar M. A. (2022). The Bethesda System for reporting cervical cytology. *CytoJournal*, 19, 28. https://doi.org/10.25259/CMAS_03_07_2021
- Papagiannidis, E., Enholm, I.M., Dremel, C. et al. Toward AI Governance: Identifying Best Practices and Potential Barriers and Outcomes. *Inf Syst Front* 25, 123–141 (2023). <https://doi-org.bdbiblioteca.universidadean.edu.co/10.1007/s10796-022-10251-y>
- Pooja, K., Kishore Kanna, R. (2024). A Systematic Review on Detection of Gastric Cancer in Endoscopic Imaging System in Artificial Intelligence Applications. In: Tiwari, S., Trivedi, M.C., Kolhe, M.L., Singh, B.K. (eds) *Advances in Data and Information Sciences. ICDIS 2023. Lecture Notes in Networks and Systems*, vol 796. Springer, Singapore. https://doi-org.bdbiblioteca.universidadean.edu.co/10.1007/978-981-99-6906-7_29
- Pymnts. (2024, 13 febrero). Cerebras: Enterprise AI Success Driven by Data, Domain Expertise and Collaboration. PYMNTS.com. <https://www.pymnts.com/news/artificial-intelligence/2024/cerebras-enterprise-ai-success-driven-by-data-domain-expertise-and-collaboration/>
- Russell, S., & Norvig, P. (2010). *Inteligencia artificial: un enfoque moderno*. Pearson Educación.
- Ryappan, J. B. Balaguru., & Lee, J. Heon. (Eds.). (2021). *Biomarkers and Biosensors for Cervical Cancer Diagnosis* (1st ed. 2021.). Springer Nature Singapore. <https://doi.org/10.1007/978-981-16-2586-2>
- Schiffman, M., & Wentzensen, N. (2013). Human papillomavirus infection and the multistage carcinogenesis of cervical cancer. *Cancer epidemiology, biomarkers & prevention: a publication of the American Association for Cancer*

Research, cosponsored by the American Society of Preventive Oncology, 22(4), 553–560. <https://doi.org/10.1158/1055-9965.EPI-12-1406>

- S. Ardabili, A. Mosavi and I. Felde, "Advances of Deep learning in Breast Cancer Modeling," 2023 IEEE 21st Jubilee International Symposium on Intelligent Systems and Informatics (SISY), Pula, Croatia, 2023, pp. 000501-000508, doi: 10.1109/SISY60376.2023.10417961.
- Szeliski, R. (2010). Computer vision: Algorithms and applications. Springer Science & Business Media.
- Sankaranarayanan, R., Nene, B. M., Shastri, S. S., Jayant, K., Muwonge, R., Budukh, A. M., Hingmire, S., Malvi, S. G., Thorat, R., Kothari, A., Chinoy, R., Kelkar, R., Kane, S., Desai, S., Keskar, V. R., Rajeshwarkar, R., Panse, N., & Dinshaw, K. A. (2009). HPV screening for cervical cancer in rural India. *The New England journal of medicine*, 360(14), 1385–1394. <https://doi.org/10.1056/NEJMoa0808516>
- What is Computer Vision? | IBM. (s. f.). <https://www.ibm.com/es-es/topics/computer-vision>
- Wright, T. C., Jr, Massad, L. S., Dunton, C. J., Spitzer, M., Wilkinson, E. J., Solomon, D., & 2006 American Society for Colposcopy and Cervical Pathology-sponsored Consensus Conference (2007). 2006 consensus guidelines for the management of women with abnormal cervical cancer screening tests. *American journal of obstetrics and gynecology*, 197(4), 346–355. <https://doi.org/10.1016/j.ajog.2007.07.047>
- Zhu, X., Yao, Q., Dai, W., Ji, L., Yao, Y., Pang, B., Turic, B., Yao, L., & Liu, Z. (2023). Cervical cancer screening aided by artificial intelligence, China/Depistage du cancer du col de l'uterus assiste par intelligence artificielle en Chine/Deteccion del cancer del cuello uterino con ayuda de la inteligencia artificial en China. *Bulletin of the World Health Organization*, 101(6), 381-. <https://doi.org/10.2471/BLT.22.289061>

- Phoulady, H. A., & Mouton, P. R. (2018, 23 noviembre). *A New Cervical Cytology Dataset for Nucleus Detection and Image Classification (Cervix93) and Methods for Cervical Nucleus Detection*. arXiv.org. <https://arxiv.org/abs/1811.09651>