

ESCUELA DE POSGRADO Y ESTUDIOS CONTINUOS

MAESTRÍA EN INGENIERÍA DE SISTEMAS

MODELO BASADO EN DEEP LEARNING PARA DETECCIÓN
DE CARIÉS EN IMÁGENES RADIOGRÁFICAS EN UNA
CLÍNICA ESPECIALIZADA, TRUJILLO 2023

Tesis para optar el grado de **MAESTRO** en:

INGENIERÍA DE SISTEMAS CON MENCIÓN EN GERENCIA DE
SISTEMAS DE INFORMACIÓN

Autor

Bachiller Yoshiro Pizan Macedo

Asesor

Doctor Pedro Segundo Castañeda Vargas

<https://orcid.org/0000-0003-1865-1293>

Perú

2023

LÍNEA DE INVESTIGACIÓN

Tecnologías Emergentes

SUB LÍNEA DE INVESTIGACIÓN

Data Mining Machine/ Deep learning. Internet of things (IoT).
Augmented reality (AR). Smart warehousing

JURADO EVALUADOR

Jurado 1 Presidente	Dr. ALBERTO CARLOS MENDOZA DE LOS SANTOS	17434055
	Nombre y Apellidos	N.º DNI


Jurado 2	Dr. RONAL SANTOS PAREDES VARGAS	09565844
	Nombre y Apellidos	N.º DNI

Jurado 3	Mg. MIGUEL ANGEL LEÓN VILLARRUEL	09591047
	Nombre y Apellidos	N.º DNI

Informe similitud

MODELO BASADO EN DEEP LEARNING PARA DETECCIÓN DE CARIES EN IMÁGENES RADIOGRÁFICAS EN UNA CLÍNICA ESPECIALIZADA, TRUJILLO 2023

INFORME DE ORIGINALIDAD



FUENTES PRIMARIAS

1	hdl.handle.net Fuente de Internet	2%
2	Submitted to Universidad Privada del Norte Trabajo del estudiante	2%
3	repositorio.upn.edu.pe Fuente de Internet	1%
4	revistas.uis.edu.co Fuente de Internet	1%
5	repositorio.ulasalle.edu.pe Fuente de Internet	1%
6	revistasinvestigacion.unmsm.edu.pe Fuente de Internet	1%
7	Submitted to Universidad Ricardo Palma Trabajo del estudiante	1%
8	repositorio.ucv.edu.pe Fuente de Internet	1%

Resumen

El fin de la presente investigación es la elaboración de un modelo de aprendizaje profundo para la detección de carie dental en imágenes radiográficas panorámicas. Para ello, el autor empleó el framework YOLO versión 8 para la clasificación de imágenes y la creación del modelo.

Para la recopilación de datos se hizo uso de los registros de imágenes radiográficas panorámicas dentales, pertenecientes a pacientes mayores de 14 años de edad de una clínica odontológica. La ausencia y presencia de carie dental fue la característica por la que las imágenes fueron cuidadosamente etiquetadas por un especialista.

Para entrenamiento y etapa de validación, fueron empleadas 1160 imágenes; y para la fase de prueba, se emplearon 290 imágenes que no fueron empleadas en las fases previas. Con lo anterior, la detección de carie dental alcanza un 80% de precisión.

Finalmente, se puede corroborar que el grado de precisión del diagnóstico de carie basada en imágenes radiográficas mediante el uso de Deep Learning es óptimo y cercano al nivel de precisión de un especialista.

El autor espera que el presente trabajo pueda contribuir con más investigaciones para clasificar imágenes radiográficas dentales que buscan detectar problemas de carie y que son llevados a cabo en consultorios odontológicos, generando de esta manera un medio de soporte para las decisiones de los casos clínicos de los pacientes.

Abstract

The aim of this research is the development of a deep learning model for the detection of dental caries in panoramic radiographic images. For this purpose, the author used the YOLO v8 framework for image classification and model creation.

For data collection, use was made of the records of dental panoramic radiographic images belonging to patients over 14 years of age from a dental clinic. The absence and presence of dental caries was the characteristic for which the images were carefully labeled by a specialist.

For the training and validation stage, 1160 images were used; and for the test phase, 290 images that were not used in the previous phases were used. With the above, the detection of dental caries reached 70% accuracy.

The result corroborates that the level of accuracy of caries diagnosis based on radiographic images using Deep Learning is optimal in addition to close to the level of accuracy of a specialist.

The author hopes that the present work can contribute to further research to classify dental radiographic images that seek to detect caries problems and that are carried out in dental offices, thus generating a means of support for decisions on patients' clinical cases.

Dedicatoria y Agradecimientos

Dedico este proyecto a mi amada esposa, por ser mi fuerza y motivación constante en esta travesía académica. Tu confianza en mí ha sido mi mayor impulso para realizarlo. A mis queridos padres, por su amor incondicional y apoyo inquebrantable. Su guía ha sido fundamental para alcanzar este logro.

Agradezco sinceramente a todas las personas e instituciones que han contribuido de manera significativa en la realización de esta tesis, en especial a mi asesor, el Dr. Pedro Castañeda Vargas, cuya orientación experta y constante apoyo fueron fundamentales.

Yoshiro Pizán Macedo

Tabla de contenidos

LÍNEA Y SUB LÍNEA DE INVESTIGACIÓN	¡Error! Marcador no definido.
JURADO EVALUADOR	iii
Informe similitud	iv
Resumen	v
Abstract.....	vi
Dedicatoria y Agradecimientos	vii
Tabla de contenidos	viii
Índice de tablas y figuras.....	x
I. INTRODUCCIÓN.....	1
I.1 Realidad problemática.....	1
I.2 Pregunta de investigación	3
I.2.1 Pregunta general	3
I.2.2 Preguntas específicas	3
I.3 Objetivos de la investigación	4
I.3.1 Objetivo general	4
I.3.2 Objetivos específicos	4
I.4 Justificación de la investigación.....	5
I.5 Alcance de la investigación.....	5
II. MARCO TEÓRICO.....	6
II.1 Antecedentes	6
II.1.1 Antecedentes internacionales	6
II.1.2 Antecedentes nacionales.....	9
II.2 Bases teóricas.....	9
II.3 Marco conceptual (terminología)	13
III. HIPÓTESIS.....	14
III.1 Declaración de hipótesis.....	14
III.1.1 Hipótesis general	14
III.1.2 Hipótesis específicas.....	14

III.2	Operacionalización de variables	15
IV.	DESCRIPCIÓN DE MÉTODOS Y ANÁLISIS	16
IV.1	Tipo de investigación.....	16
IV.2	Nivel de investigación.....	16
IV.3	Diseño de investigación.....	16
IV.4	Método de investigación	17
IV.5	Población.....	17
IV.6	Muestra.....	17
IV.7	Técnicas de recolección de datos	18
IV.7.1	Técnica.....	18
IV.7.2	Instrumento.....	18
IV.8	Presentación de resultados	18
V.	RESULTADOS	23
VI.	DISCUSIÓN, CONCLUSIONES y RECOMENDACIONES.....	35
VI.1	Discusión	35
VI.2	Conclusiones	40
VI.3	Recomendaciones	41
	Lista de referencias	42
	Apéndice	45

Índice de tablas y figuras

Tabla 1. Matriz de confusión	23
Tabla 2. Operacionalización de la variable Aplicación de Deep Learning basada en imágenes radiográficas	26
Tabla 3. Dataset para los lotes 1 y 2.	36
Tabla 4. Análisis de rendimiento en el lote de imágenes 1.	36
Tabla 5. Análisis de rendimiento en el lote de imágenes 2.	36
Tabla 6. Frecuencias de la detección de caries por parte del odontólogo especialista.	38
Tabla 7. Frecuencias de la detección de caries por parte del modelo de Deep Learning propuesto	39
Tabla 8. Frecuencias de la detección de caries por parte del especialista y del modelo de Deep Learning	40
Tabla 9. Coincidencias en la detección de caries por parte del especialista y del modelo de Deep Learning	42
Tabla 10. Prueba z para la diferencia de los promedios de dos poblaciones pareadas aplicada al estudio	43
Tabla 11. Indicadores Precision, Recall y F1.	44
Tabla 12. Efecto del modelo basado en Deep Learning para la detección de caries en imágenes radiográficas en una clínica especializada, Trujillo 2023.	45
Figura 1. Inteligencia artificial, aprendizaje automático y aprendizaje profundo (Chollet, 2018)	20
Figura 2. Esquema general de una red neuronal de múltiples capas (Kelleher, 2019)	21
Figura 3. Esquema general de la investigación	27
Figura 4. Imágenes radiográficas dentales seleccionadas para el proceso de entrenamiento	30
Figura 5. Comando para entrenar el modelo de Deep Learning	32
Figura 6. Comando para validar el modelo de Deep Learning	33
Figura 7. Clasificación de placas radiográficas	35

Figura 8. Frecuencias de la detección de caries por parte del odontólogo especialista.	38
Figura 9. Frecuencias de la detección de caries por parte del modelo de Deep Learning propuesto.	40
Figura 10. Porcentajes comparados de la detección de caries por el especialista y el modelo de Deep Learning	41
Figura 11. Coincidencias en la detección de caries por parte del especialista y del modelo de Deep Learning	42
Figura 12. Fórmulas para el cálculo de la prueba estadística z.	42

I. INTRODUCCIÓN

I.1 Realidad problemática

Los trastornos de salud bucodental afectan a cerca de 3500 millones de personas en todo el mundo, siendo la caries en dientes permanentes el trastorno más frecuente, el cual afecta a más de 2000 millones de personas, según las estimaciones publicadas en el estudio sobre la carga mundial de morbilidad 2019 (*Global Burden of Disease Study, 2019*). (Organización Mundial de la Salud, 2022)

La caries dental es una enfermedad crónica y multifactorial que afecta los tejidos duros de los dientes, como el esmalte, la dentina y, en casos avanzados, la pulpa dental. Se caracteriza por la desmineralización y destrucción progresiva de los tejidos dentales, causada principalmente por la acción de los ácidos producidos por las bacterias presentes en la placa dental. La caries dental es una de las enfermedades más comunes a nivel mundial y puede provocar dolor, sensibilidad, mal aliento y pérdida de la función masticatoria (Fejerskov, 2015).

Según un Estudio Epidemiológico realizado en el Perú, en los años 2001-2002, la prevalencia de caries dental es de 90,4%. (Zanabria, 2018, pág. 66)

Dada la alta demanda de atención odontológica por esta enfermedad bucal, muchas personas acuden a los consultorios y el proceso de atención puede tomar más tiempo; desde encontrar una cita disponible o el incremento del mismo en sala de espera, lo cual hace el proceso de atención más lento.

Debido a este problema surge la necesidad de utilizar herramientas que permitan agilizar el proceso de atención para esta enfermedad de alta incidencia a nivel mundial.

El Machine Learning (ML), conocido en español como aprendizaje de máquina, es una disciplina de la ciencia de la computación y una rama de la inteligencia artificial que tiene por objetivo desarrollar sistemas que aprenden automáticamente, reconocen patrones y predicen comportamientos, a partir de conjuntos de datos. Dentro de las herramientas más importantes del ML se encuentran las redes neuronales

artificiales, conocidas en inglés como artificial neural networks (ANNs), y el aprendizaje profundo, conocido en inglés como deep learning (DL). Las ANNs son un modelo de un algoritmo computacional inspirado en las redes neuronales biológicas. Son una poderosa herramienta que tiene la habilidad para aprender y generalizar, permitiendo reconocer patrones, predecir comportamientos y tomar decisiones. El DL toma los fundamentos teóricos de las redes neuronales clásicas, pero emplea una gran cantidad de neuronas y capas escondidas, junto con nuevos modelos y paradigmas de entrenamiento. (Sarmiento-Ramos, 2020)

Las redes neuronales convolucionales o convolutional neural network (Conv-Net o CNNs) son una clase de redes neuronales multicapa feedforward especialmente diseñadas para el reconocimiento y clasificación de imágenes. (Llamas, 2018)

Los ordenadores perciben las imágenes de diferente forma a los humanos, para estos una imagen consiste en un vector bidimensional con los valores relativos a los píxeles. Contando con un canal para imágenes en escala de grises o tres para el color (RGB).

Las ANNs y el DL permiten apoyar a los profesionales de la salud con: análisis más rápidos de grandes conjuntos de datos e información médica de hospitales e instituciones de salud, mejoras en los protocolos de diagnóstico y pronóstico de enfermedades, aumentando la velocidad y reduciendo los errores médicos, diseño de terapias personalizadas más eficientes y mejoras en el bienestar humano. (Sarmiento-Ramos, 2020)

En los últimos años se ha evidenciado un crecimiento exponencial en la publicación de artículos sobre la aplicación de la IA en las diferentes especialidades odontológicas. Esto demuestra la implementación de esta tecnología, sobre todo en el diagnóstico de lesiones utilizando diferentes tipos de imágenes, principalmente radiológicas, que se utilizan para determinar las condiciones de salud de los tejidos duros.

Es fundamental realizar un diagnóstico temprano de la caries dental para que así se eviten aplicar tratamientos invasivos en los pacientes.

El éxito de todo tratamiento radica en el correcto diagnóstico, identificando la presencia o no de lesiones periapicales ya que todo esto contribuirá en

la reducción del nivel de dificultad del tratamiento (Mallishery S, 2020) con la aplicación de DNN para agilizar el tiempo que demora en diagnosticar el nivel de dificultad de un tratamiento endodóntico y su correcta derivación con el especialista.

En este escenario, el Deep Learning basado en imágenes radiográficas puede ser utilizado para mejorar los procesos de las consultas odontológicas, desde los protocolos de atención, así como en la eficiencia de la entrega de un diagnóstico de caries y plan de tratamiento.

I.2 Pregunta de investigación

I.2.1 Pregunta general

¿Cuál es el nivel de precisión del diagnóstico de caries basada en imágenes radiográficas mediante el uso de Deep Learning en una clínica especializada de la ciudad de Trujillo, en el año 2023?

I.2.2 Preguntas específicas

- ¿Se deben clasificar placas radiográficas dentales para detectar patrones de caries en una clínica especializada de la ciudad de Trujillo, en el año 2023?
- ¿Qué framework de deep learning se empleará en el diagnóstico de caries en una clínica especializada de la ciudad de Trujillo, en el año 2023?
- ¿Se deben realizar pruebas al modelo de Deep Learning para mejorar su precisión de diagnóstico de caries?
- ¿Se debe describir el nivel de precisión del diagnóstico de caries basada en imágenes radiográficas mediante el uso de un modelo basado en Deep Learning en una clínica especializada de la ciudad de Trujillo, en el año 2023?

- ¿Se debe realizar un comparativo entre el diagnóstico de caries basada en imágenes radiográficas mediante el uso de deep learning y mediante el análisis de un especialista en una clínica especializada de la ciudad de Trujillo, en el año 2023?

I.3 Objetivos de la investigación

I.3.1 Objetivo general

Determinar el nivel de precisión del diagnóstico de caries basada en imágenes radiográficas mediante el uso de deep learning en una clínica especializada de la ciudad de Trujillo, en el año 2023.

I.3.2 Objetivos específicos

1. Clasificar placas radiográficas dentales para detectar patrones de caries en una clínica especializada de la ciudad de Trujillo, en el año 2023.
2. Seleccionar el framework de deep learning a emplear en el diagnóstico de caries en una clínica especializada de la ciudad de Trujillo, en el año 2023.
3. Realizar pruebas al modelo de deep learning para mejorar su precisión para el diagnóstico de caries.
4. Describir el nivel de precisión del diagnóstico de caries basada en imágenes radiográficas mediante el uso de un modelo basado en Deep Learning en una clínica especializada de la ciudad de Trujillo, en el año 2023.
5. Realizar un comparativo entre el diagnóstico de caries basada en imágenes radiográficas mediante el uso de deep learning y mediante el análisis de un especialista en una clínica especializada de la ciudad de Trujillo, en el año 2023.

I.4 Justificación de la investigación

La presente investigación se justifica a nivel económico ya que proporciona una ayuda en la rapidez del diagnóstico de caries, sin la necesidad de que se contrate un especialista para poner en funcionamiento el modelo. Eso implica un ahorro en gastos de contrataciones.

Operativamente, proporciona ventajas porque reduce el tiempo de consulta y; permite invertir más el tiempo y trabajo en atenciones clínicas a los especialistas.

Académicamente, brinda la oportunidad de aplicar lo aprendido referente a manejo de información relacionada con Deep Learning. Es un método innovador que puede ser llevado al campo médico, proporcionando ayuda en los procesos y al alcance de los profesionales de la salud.

I.5 Alcance de la investigación

El alcance de esta investigación se enfoca en el desarrollo de un modelo de deep learning utilizando el framework YOLO versión 8 para la clasificación de caries en imágenes radiográficas panorámicas dentales. El estudio se basará en un conjunto de datos de imágenes radiográficas proporcionadas por un centro odontológico, que incluirán radiografías panorámicas de pacientes con diferentes grados de caries.

El modelo se implementará utilizando la arquitectura YOLO versión 8, que utiliza redes neuronales convolucionales profundas y técnicas avanzadas de detección y clasificación de objetos. Se realizará un entrenamiento supervisado del modelo utilizando un conjunto de datos debidamente clasificados en base a la característica de presencia o ausencia de caries. Se llevará a cabo un proceso de preprocesamiento de imágenes para normalizar, y mejorar la calidad de las imágenes radiográficas.

El objetivo principal es desarrollar un modelo de deep learning preciso y confiable que pueda clasificar las imágenes radiográficas panorámicas con alta precisión. El modelo se entrenará y evaluará utilizando métricas de evaluación, como precisión, para medir su rendimiento.

Sin embargo, este estudio no abordará la clasificación y segmentación de caries ni de otros tipos de patologías dentales ni análisis de otras modalidades de imágenes dentales. El enfoque estará específicamente en la clasificación de caries en imágenes radiográficas panorámicas utilizando el framework YOLO versión 8.

Es importante tener en cuenta que este estudio se centrará exclusivamente en la clasificación de caries en imágenes radiográficas panorámicas dentales utilizando el framework YOLO versión 8. No se abordarán estudios de detección ni segmentación, ni otros aspectos clínicos relacionados con el diagnóstico o el tratamiento de caries. Además, el conjunto de datos utilizado se limitará a imágenes proporcionadas por una fuente específica.

La investigación también considerará las limitaciones éticas y legales asociadas con el uso de datos de pacientes, asegurando la privacidad y la confidencialidad de la información.

Este estudio tiene como objetivo contribuir al campo de la odontología digital y proporcionar una herramienta de apoyo para los profesionales de la salud dental en la clasificación automatizada de caries dentales en imágenes radiográficas panorámicas utilizando el framework YOLO versión 8.

II. MARCO TEÓRICO

II.1 Antecedentes

II.1.1 Antecedentes internacionales

Entre los principales antecedentes se cuentan con:

Las redes neuronales convolucionales profundas (CNN) son definidas como un área nueva dentro de la investigación en medicina, que crece de forma rápida y entrega grandes resultados al momento de predecir y diagnosticar casos en las áreas de patología y de radiología (Jae-Hong Lee, 2018). En esta investigación se emplearon 3000 imágenes radiográficas periapicales divididos en dos grupos: entrenamiento y validación

(2400 imágenes) y el grupo de prueba (600 imágenes). El pre entrenamiento se llevó a cabo con GoogleNet Inception v3. La precisión para el diagnóstico, además de la sensibilidad y la especificidad, los valores predictivos positivo y negativo, el ROC y AUC, fueron calculados para el rendimiento diagnóstico y la capacidad de detección del algoritmo. Este estudio destacó que la arquitectura CNN profunda para diagnóstico y detección de carie tiene gran utilidad. Se concluye que el algoritmo proporcionó un rendimiento considerablemente bueno en la detección empleando radiografías periapicales (Jae-Hong Lee, 2018).

Además, existen investigaciones del empleo de CNN en otras áreas médicas. Por ejemplo, según (Chanampe, et al., 2019), los autores utilizaron técnicas de Aprendizaje Profundo para la clasificación de lesiones mamarias. El modelo que desarrollaron analizando imágenes con Redes Neuronales Convolucionales Profundas (CNN), fue precisa en un 62% empleando la base de datos libre llamada mini-MIAS, la cual se encuentra expuesta en internet. Sugieren emplear otras arquitecturas y utilizar datasets más grandes o múltiples fuentes de datos en próximos trabajos, para mejorar la precisión.

De acuerdo a (Lee, Sang-il, Junik, Sumi, & Shin, 2021), se plantea el uso de CNN para procesar imágenes radiográficas de tipo aleta de mordida (bitewing radiographs). Se emplearon dos modelos utilizando U-Net: el U-Net para segmentación de caries (U-CS) y el U-Net para segmentación de estructura (U-SS). Fueron empleadas 304 radiografías de aleta de mordida para el entrenamiento del modelo y 50 para la evaluación del rendimiento. Se logró una precisión del 63% en la detección temprana de caries. Se concluye que el modelo de deep learning puede ser una herramienta de mucha ayuda para los médicos, para el diagnóstico con mayor precisión de carie dental.

También, según (Luya Lian, 2021) tuvo como objetivo utilizar métodos de Deep Learning para detección de lesiones de caries y clasificarlas según su extensión en imágenes radiológicas panorámicas y comparar los resultados con dentistas expertos. Un total de 1160 radiografías panorámicas fueron evaluadas por 3 expertos. Se emplearon 2 datasets: uno para entrenamiento y validación en el cual se emplearon 1071 radiografías y otro dataset para pruebas, con un total de 89 radiografías. Se emplearon redes neuronales convolucionales tales como nnU-Net para detectar caries, y DenseNet121 para clasificar las lesiones de acuerdo a su severidad. Se concluyó que, en detección y clasificación de lesiones de caries en imágenes radiográficas panorámicas, el rendimiento del deep learning fue muy similar al de los expertos dentistas.

De manera similar, en (Xiaoyi Zang, 2022), los autores resaltan que actualmente el empleo de CNN para analizar imágenes médicas es muy amplio dados los últimos avances en estomatología. Se crea un modelo de aprendizaje profundo para detectar y reconocer carie dental mediante imágenes endoscópicas. Se emplearon 194 imágenes sin caries, 1059 imágenes de caries en molares y premolares permanentes para construir un modelo de clasificación y segmentación de caries en imágenes endoscópicas de pacientes. Se empleó el modelo DeepLabv3+ para la segmentación de caries. Se concluyó que el emplear un modelo de DL ayuda a monitorear la caries y fomentar su diagnóstico temprano para su tratamiento.

Finalmente, según (Kühnisch, Meyer, Hesenius, & Hickel, 2022), llevaron a cabo una investigación para detección de lesiones de caries en imágenes fotográficas empleando redes neuronales convolucionales. Fueron empleadas 2417 fotografías anónimas de dientes permanentes. Se emplearon las técnicas de aumento de imágenes y Transfer Learning. La validación de datos se realizó seleccionando el 25%, 50%, 75% y el 100% de las imágenes disponibles. Para el análisis estadístico emplearon cálculos de la

sensibilidad y especificidad. La investigación concluye que es posible lograr más de un 90% de acierto en detección de caries para fotografías de dientes únicos.

II.1.2 Antecedentes nacionales

Para tener un panorama más amplio, según (Cacñahuaray-Martínez, 2021), se evidencia el empleo de IA en las diferentes especialidades de la odontología. Se consultaron diferentes repositorios de datos tales como Medline/PubMed, Scopus y Web of Science en el período 2017-2021. Fueron encontrados 321 artículos del tema, de los cuales 62 evidenciaron la aplicación de IA en 6 especialidades odontológicas: medicina y patología oral, implantología, periodoncia, en la odontología forense, diagnóstico/cariología/endodoncia y ortodoncia (Cacñahuaray-Martínez, 2021). Esto demuestra que el empleo de IA en las diversas ramas odontológicas viene en crecimiento y demostrando resultados prometedores, mostrando precisiones equivalentes a los especialistas odontólogos que están capacitados y, además, en algunos casos, ha superado los errores cometidos por humanos.

II.2 Bases teóricas

Diagnóstico de caries

El diagnóstico de la caries dental es un procedimiento realizado con mucha frecuencia por los odontólogos en la práctica clínica. Anteriormente, el método de diagnóstico sólo se basaba en la observación clínica. En los últimos años, los requerimientos para mejorar la sensibilidad y rapidez de la detección de caries han permitido el desarrollo de diversos métodos para el diagnóstico. La tecnología es aliada principal de estos cambios. (Carrillo Sanchez, 2018)

Deep Learning

El deep learning o aprendizaje profundo en español, es el subcampo de la IA cuyo objetivo es la creación de complejos modelos de redes

neuronales con capacidad de decidir de forma puntual y exacta basadas en el análisis de datos. El aprendizaje profundo es esencialmente adecuado en contextos donde los datos son complejos y donde hay grandes volúmenes de datos disponibles (Goodfellow, 2016).


Adicionalmente, (Chollet, 2018) indica que el término “profundo” hace referencia al concepto de utilizar sucesivas capas. La profundidad del modelo dependerá de la cantidad de capas de la misma. Otros nombres adecuados para el deep learning serían: aprendizaje de representaciones en capas, o también el aprendizaje de representaciones jerárquicas. En la actualidad implica a decenas y a veces hasta cientos de capas una a continuación de otra, de representaciones y todos aprenden de forma automática, a partir de la exposición a los datos de entrenamiento.

Inteligencia artificial.

Es adaptar máquinas con poder computacional para simular la inteligencia de los humanos. También hace referencia a cualquier computadora que recibe entrenamientos relacionados con la manera de procesar de la mente humana, su forma de aprender y la manera en la que soluciona ciertos problemas (Frankenfield, 2023).

Por otro lado, (Chollet, 2018) nos muestra en la figura 1, los campos relacionados con la inteligencia artificial y la dependencia entre ellas:

Figura 1. Inteligencia artificial, aprendizaje automático y aprendizaje profundo (Chollet, 2018)




En cuanto a las ramas de la inteligencia artificial, (Ponce Cruz, 2010) las define en 3 grandes grupos:

- Lógica difusa, que procesa la información con valores 0 (falso) y 1(verdadero).
- Redes neuronales artificiales, que serán explicados más a detalle posteriormente.
- Algoritmos genéticos, los cuales se definen como métodos adaptativos que pueden utilizarse para la resolución de casos de optimización. Su estructura es similar a la teoría biológica de la evolución y se basa en la supervivencia del más adaptado.

Una RNA está constituida por el sistema de procesamiento computacional caracterizándose por la presencia de una o más capas intermedias ocultas (“intermediate hidden layers” en inglés). Al igual que en la naturaleza, cada capa intermedia oculta de neuronas está conectada con cada una de las neuronas en la capa anterior a modo que exista “sinapsis” entre ellas. (Choy, 2018). La siguiente imagen es una representación de una red neuronal conformada por muchas capas. (Kelleher, 2019)

Figura 2. Esquema general de una red neuronal de múltiples capas (Kelleher, 2019)



Redes Neuronales Convolucionales

Las redes neuronales convolucionales (CNNs) - conocidas como convolution neural networks en inglés - fueron desarrolladas con el propósito de abordar el reconocimiento de imágenes, y fueron inicialmente aplicadas al desafío de reconocer dígitos escritos a mano. El principal objetivo detrás del diseño de las CNNs era crear una red en la que las neuronas en las capas iniciales fueran capaces de extraer características visuales locales, mientras que las neuronas en capas posteriores combinarían estas características para formar características de mayor nivel (Kelleher, 2019).

Las redes neuronales convolucionales (CNNs) se basan en la corteza visual del cerebro, que es responsable de procesar la información visual. La corteza visual cuenta con diferentes especializaciones que le permiten procesar eficientemente los datos visuales. En esta área, existen numerosas células receptoras que detectan la luz en regiones superpuestas del campo visual. Estas células receptoras son sometidas a una operación de convolución, lo que significa que todas procesan su entrada de manera similar (Hearty, 2016).

Métricas de evaluación de Algoritmos

Existen métricas para evaluar algoritmos de aprendizaje automático (G. Shobha, 2018) según la tarea específica del algoritmo:

Matriz de Confusión: Es un cuadro que permite visualizar y comprender el desempeño de un modelo al comparar las predicciones que realiza con las clases reales de un conjunto de datos. El número de predicciones positivas y negativas que el modelo predice correctamente se denomina True Positive (TP) y True Negative (TN) respectivamente. Las predicciones mal clasificadas se conocen como False Positive (FP) y False Negative (FN). La Tabla 1 muestra la distribución de valores en la matriz.

Tabla 1. Matriz de confusión

	Predicción	
	Positive	Negative
True	TP	FN
False	FP	FN

Accuracy: Es la proporción de predicciones correctas realizadas por el algoritmo entre todas las predicciones realizadas.

$$accuracy = \frac{\text{predicciones correctas}}{\text{total predicciones}}$$

Precisión: Es la proporción de predicciones correctas realizadas por el algoritmo de todas las predicciones que fueron positivas.

$$precision = \frac{TP}{TP + FP}$$

Recall: La recuperación es la proporción de predicciones correctas realizadas por el algoritmo entre todos los casos positivos reales.

$$recall = \frac{TP}{TP + FN}$$

F1 score: La puntuación F1 es una medida de precisión que tiene en cuenta tanto la precisión como la recuperación.

$$F1\ score = 2 * \frac{precision * recall}{precision + recall}$$

II.3 Marco conceptual (terminología)

YOLO (You Only Look Once): Es un algoritmo de detección de objetos en tiempo real que utiliza una única pasada de una red neuronal convolucional para detectar y clasificar objetos en una imagen.

Clasificación de objetos: Se refiere al proceso clasificar objetos específicos en una imagen. En el contexto de las imágenes radiográficas, esto implica identificar la característica carie dental.

Conjunto de datos de entrenamiento: Es un conjunto de imágenes previamente etiquetadas que se utiliza para entrenar el modelo de YOLO. Estas imágenes contienen anotaciones que indican la ubicación y la clase de los objetos presentes en la imagen.

Conjunto de datos de prueba: Es un conjunto de imágenes que se utiliza para evaluar el rendimiento del modelo entrenado. Estas imágenes no se utilizan durante el entrenamiento y se utilizan para medir la precisión y la eficacia del modelo de YOLO.

Predicción: Es el resultado obtenido por el modelo entrenado de YOLO, que indica las clases de los objetos detectados en una imagen de entrada.

Umbral de confianza: Es un valor predefinido que se utiliza para filtrar las detecciones con una confianza inferior a un umbral específico. Las detecciones con una confianza por debajo del umbral no se consideran como detecciones válidas.

Precisión: Es una métrica que indica la proporción de detecciones correctas realizadas por el modelo en comparación con el total de detecciones realizadas.

III. HIPÓTESIS

III.1 Declaración de hipótesis

III.1.1 Hipótesis general

Ho: El nivel de precisión del diagnóstico de caries basada en imágenes radiográficas mediante el uso de Deep Learning es óptimo en una clínica especializada de la ciudad de Trujillo, en el año 2023.

III.1.2 Hipótesis específicas

Hi: El nivel de precisión del diagnóstico de caries basada en imágenes radiográficas mediante el uso de Deep Learning no es óptimo en una clínica especializada de la ciudad de Trujillo, en el año 2023.

III.2 Operacionalización de variables

Tabla 2. Operacionalización de la variable Aplicación de Deep Learning basada en imágenes radiográficas

Variable	Definición conceptual	Definición operacional	Dimensiones	Definiciones dimensionales	Indicador	Nivel de medición	Unidad de medida	Valor	Tipo de Variable
Variable Independiente: Modelo basado en Deep Learning	El modelo basado en deep learning se refiere a un enfoque de inteligencia artificial que utiliza una arquitectura de redes neuronales profundas para aprender representaciones de alto nivel a partir de datos de entrada. Estas redes neuronales profundas están compuestas por múltiples capas de unidades de procesamiento que se organizan de manera jerárquica, lo que permite al modelo aprender características complejas y realizar tareas de forma automática. (Nguyen, 2020)	Sistema computacional desarrollado utilizando técnicas de deep learning que consiste en una red neuronal profunda entrenada con un conjunto de datos radiográficos de caries dental. El modelo opera extrayendo características relevantes de las imágenes radiográficas y utilizando algoritmos de aprendizaje profundo para detectar y clasificar automáticamente la presencia de caries dental en las imágenes. (Smith, 2019)	Arquitectura	Estructura y diseño empleado para la construcción de una red neuronal profunda.	Número de capas convolucionales	Ordinal	Unidad	Número	Cualitativo
			Algoritmo del modelo de Deep Learning	Operaciones y procedimientos empleados para entrenar y ajustar el aprendizaje de un modelo de red neuronal profunda	Tamaño de batch	Ordinal	Unidad	Número	Cualitativo
					Número de épocas	Ordinal	Unidad	Número	Cualitativo
					Precisión	Ordinal	Porcentaje	0%-100%	Cualitativo
Variable Dependiente: Efectividad en la detección de carie dental	La efectividad en la detección de caries se refiere a la capacidad de un método o técnica para identificar de manera precisa y confiable la presencia de caries dental. Es una medida de la precisión y la fiabilidad del método utilizado (Pretty, 2017)	Capacidad del modelo basado en deep learning para identificar correctamente la presencia de caries en imágenes radiográficas. La efectividad se mide utilizando métricas de evaluación, como la sensibilidad, la especificidad y la precisión, que se calculan comparando los resultados del modelo con las anotaciones de caries realizadas por expertos radiólogos o dentistas en las mismas imágenes radiográficas. (Gulshan, 2016)	Revocación	La proporción de casos positivos reales que el modelo logra recordar en sus predicciones	Revocación	Ordinal	Porcentaje	0%-100%	Cualitativo
			Medida F	Evaluación del rendimiento del modelo combinando precisión y revocación	Medida F	Ordinal	Porcentaje	0%-100%	Cualitativo

IV. DESCRIPCIÓN DE MÉTODOS Y ANÁLISIS

IV.1 Tipo de investigación

La investigación es aplicada, debido a que busca resolver problemas (Hernández Sampieri & Mendoza Torres, 2018). Se usa teorías ya existentes y con ese sustento teórico se busca dar solución al problema de detección de caries con la creación del modelo de Deep Learning.


IV.2 Nivel de investigación

El estudio es de enfoque cuantitativo explicativo, debido a que en el proceso de investigación se realizan las mediciones numéricas en forma de recolección de datos y análisis. Sampieri et al. (2018).

IV.3 Diseño de investigación

Experimental de nivel Pre Experimental, debido a que existió alteración en la variable independiente: modelo basado en Deep Learning para observar su efecto sobre la variable dependiente: efectividad en la detección de caries dental y evaluar si existe una relación causal entre ambas. Los preexperimentos se llaman así porque su grado de control es mínimo (Hernández Sampieri & Mendoza Torres, 2018).

Figura 3. Esquema general de la investigación



X: Variable independiente.

O₁: Medición pre-experimental de la variable independiente.

O₂: Medición post-experimental de la variable independiente.

d: distancia entre las observaciones.

IV.4 Método de investigación

El método es hipotético-deductivo que es un enfoque sistemático de investigación que involucra la formulación de hipótesis, la deducción de predicciones y la recopilación de datos para comprobar o refutar estas predicciones (Sampieri, Collado, & Lucio, 2018).

IV.5 Población

Población o universo:

Las radiografías dentales panorámicas, obtenidas en una clínica de Trujillo, que ascienden a un total de 290 imágenes.

Población de estudio:

Las radiografías panorámicas que satisfagan los requisitos de selección.

Requisitos de selección:

Requisitos de Inclusión:

- Radiografía panorámica de pacientes con dentición permanente.
- Radiografía panorámica que presente al menos una pieza dentaria.
- Radiografía panorámica de pacientes de 14 años de edad a más.

Requisitos de Exclusión

- Radiografía panorámica de pacientes sin piezas dentales.
- Radiografía panorámica de pacientes con dentición temporal.
- Radiografía panorámica de pacientes con dentición mixta.
- Radiografía panorámica donde se detecte presencia de prótesis total completa

IV.6 Muestra

Unidad de análisis:

Cada una de las 290 radiografías panorámicas dentales, de los pacientes que fueron atendidos en la clínica especializada de Trujillo, 2023.

Unidad de muestreo:

Cada una de las fichas que recolectaron los datos de las radiografías maxilofaciales los pacientes en donde se consignaron los datos de número de dientes y número de dientes cariados.

Muestreo:

Se empleó un método de muestreo intencional no aleatorio, lo cual permitió la participación de todos los casos y su selección se basó en la proximidad y la accesibilidad al investigador de manera conveniente, muestra que asciende a 290 imágenes radiográficas panorámicas. (Otzen & Manterola, 2017).

IV.7 Técnicas de recolección de datos

IV.7.1 Técnica

Lista de cotejos fueron utilizadas, debido a que con este método de recolección de datos es posible obtener una abundante cantidad de datos.

IV.7.2 Instrumento

Se utilizó un Instrumento (Anexo 1).

IV.8 Presentación de resultados

Para esta investigación, después de ejecutar el modelo desarrollado, se generaron los resultados empleando tablas y gráficos, además de la descripción de cada una de ellas. Asimismo, se presentan estadísticas de la fase de prueba ejecutada, la cual determina el nivel de precisión alcanzado.

A continuación, se presenta el método propuesto:

1. Obtención de las imágenes radiográficas panorámicas:

Figura 4. Imágenes radiográficas dentales seleccionadas para el proceso de entrenamiento



2. Pre-Procesamiento de las imágenes:

- Transformación de la imagen de color a una representación en escala de grises.
- Eliminación de ruido.
- Empleo de data augmentation para contar con un dataset más amplio.
- Separar las imágenes en dos carpetas de acuerdo a la característica a clasificar: Con caries y Sin caries.
- Creación de las carpetas entrenamiento(train) y validación(val). A cada se le asigna una cantidad de imágenes del dataset anteriormente mencionado en la proporción: entrenamiento (70%) y validación (30%), creando las carpetas [con caries] y [sin caries].

3. Entrenamiento del modelo.

4. Validación del modelo.

5. Calibración del modelo: además de emplear el método de cross-validation

6. Prueba del modelo con imágenes que no fueron empleados anteriormente.

A continuación, la descripción del método propuesto:

1. Se obtuvieron 705 radiografías panorámicas digitales en formato BMP, proporcionado por un centro radiológico.
2. Pre Procesamiento de las imágenes:
 - Conversión de las imágenes a escala de grises con Open CV. (ver anexo 2)
 - Eliminación de ruido a la imagen a través del Filtrado Gaussiano. (ver anexo 3)
 - Empleo de la técnica de data augmentation para tener un dataset más amplio. Esta técnica consiste en aplicar transformaciones sobre la imagen original a fin de obtener nuevas imágenes. No existe un límite teórico específico para el número máximo de imágenes generadas, ya que dependerá de las transformaciones utilizadas y los parámetros que se apliquen en cada caso, pero se tendrá que evitar un aumento excesivo en el tamaño del dataset y mantener la diversidad y calidad de las imágenes generadas (Shorten, 2019). Además, es preciso indicar que es necesario tener en consideración la disposición de recursos hardware para el proceso, ya que para grandes volúmenes de datos será necesario asegurar el correcto desarrollo de la técnica. Para este estudio, de las 705 radiografías originales, se obtuvieron 455 nuevas radiografías con esta técnica. (ver anexo 4)
 - Separar las imágenes en dos carpetas: con_caries y sin_caries: la carpeta con_caries, contenía 576 imágenes y la carpeta sin_caries contenía 584 imágenes (ver anexo 5)
 - Creación de las carpetas entrenamiento(train) y validación(val): La carpeta train contenía un total de 812 imágenes, distribuidas en 393 imágenes con caries (almacenadas en la sub carpeta con_caries) y 419 imágenes sin caries (almacenadas en la sub carpeta sin_caries). La carpeta val contenía 183 imágenes dentro de la sub carpeta con_caries y 165 imágenes en la subcarpeta sin_caries. (ver anexo 6).

3. Entrenamiento del modelo: Para el entrenamiento del modelo se utilizó el entorno de Google Colab y el framework YOLO versión 8 para la tarea de clasificación de objetos: (ver anexo 7)

Figura 5. Comando para entrenar el modelo de Deep Learning

```
[ ] !yolo task=classify mode=train data="/content/gdrive/MyDrive/05062023/datasets/" epochs=15 batch=8 plots=True
```

`!yolo`: Este comando indica que se está utilizando el framework YOLO (You Only Look Once) para ejecutar una tarea específica.

`task=classify`: Especifica que la tarea que se va a realizar es la clasificación de objetos. Esto significa que el modelo se entrenará para reconocer y clasificar diferentes categorías de objetos presentes en las imágenes.

`mode=train`: Indica que el modo de funcionamiento del comando es entrenamiento. Esto implica que el modelo se entrenará utilizando un conjunto de datos anotados.

`data="/content/gdrive/MyDrive/tesis/datasets"`: Especifica la ruta o directorio donde se halla el dataset empleado para entrenar el modelo.

`epochs=15`: Indica el número de epochs o iteraciones completas que se realizarán durante el entrenamiento del modelo. Cada epoch representa una pasada completa a través de todos los datos de entrenamiento.

`batch=8`: Define el tamaño del lote (batch size) utilizado durante el entrenamiento. El tamaño del lote determina cuántas imágenes se utilizan a la vez para calcular los gradientes y actualizar los pesos del modelo.

`plots=True`: Esta opción indica que se generarán gráficos o gráficas durante el proceso de entrenamiento, lo cual puede ayudar a

visualizar el progreso y el rendimiento del modelo durante las diferentes épocas.

En cada iteración de las épocas en la fase de entrenamiento se calcula el error del modelo. En el anexo 7 se observa la sección “loss” que representa las discrepancias entre las predicciones del modelo y las etiquetas reales de los datos de entrenamiento. El objetivo del entrenamiento es minimizar esta pérdida, lo cual implica ajustar los pesos y parámetros del modelo para que las predicciones sean más acertadas.

4. Validación del modelo: Para el entrenamiento del modelo también se utilizó el entorno de Google Colab y el framework YOLO versión 8 para la tarea de clasificación de objetos: (ver anexo 8)

Figura 6. Comando para validar el modelo de Deep Learning

```
!yolo task=classify mode=val model="runs/classify/{train_name}/weights/best.pt" data="/content/gdrive/MyDrive/05062023/datasets/"  
  
Ultralytics YOLOv8.0.114 Python-3.10.11 torch-2.0.1+cu118 CPU  
YOLOv8n-c1s summary (fused): 73 layers, 1437442 parameters, 0 gradients  
classes top1_acc top5_acc: 100% 1/1 [00:00<00:00, 2.38it/s]  
all 0.7 1  
Speed: 0.0ms preprocess, 19.1ms inference, 0.0ms loss, 0.0ms postprocess per image  
Results saved to runs/classify/val
```

!yolo: Este comando indica que se está utilizando el framework YOLO (You Only Look Once) para ejecutar una tarea específica.

task=classify: Especifica que la tarea que se va a realizar es la clasificación de objetos. Esto implica que el modelo se utilizará para reconocer y clasificar diferentes categorías de objetos presentes en las imágenes.

mode=val: Indica que el modo de funcionamiento del comando es validación. Esto implica que el modelo entrenado se utilizará para realizar la evaluación en un conjunto de datos de validación independiente.

model="runs/classify/{train_name}/weights/best.pt": Especifica la ruta y el nombre del archivo del modelo que se utilizará para la validación. La ruta dada es relativa a la carpeta "runs" y utiliza una variable llamada "{train_name}" para representar el nombre del entrenamiento específico. "weights/best.pt" indica que se utilizará el archivo de pesos con el mejor rendimiento obtenido durante el entrenamiento.

data="/content/gdrive/MyDrive/tesis/datasets/": Especifica la ruta o directorio donde se encuentra el conjunto de datos utilizado para la validación del modelo.

5. Prueba del modelo con nuevas imágenes: Se emplearon 290 nuevas imágenes radiográficas para el proceso de testing (ver anexo 9).

V. RESULTADOS

Luego de la ejecución del presente trabajo de investigación, se obtuvieron los siguientes resultados:

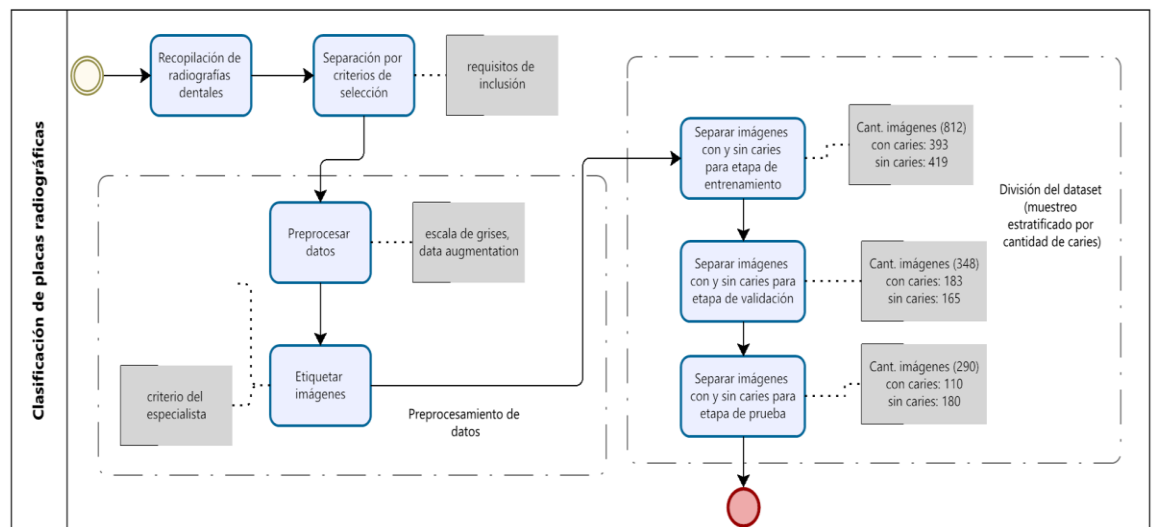
IV.1. Clasificación de placas radiográficas dentales

Para detectar patrones de caries, se procedió a realizar lo siguiente:

- Recopilación y preparación de datos: Se reunió un conjunto de imágenes radiográficas dentales que contenían ejemplos tanto de dientes sanos como de dientes con caries. Con la ayuda de un especialista, se procedió a separar manualmente las imágenes para indicar la presencia o ausencia de caries, logrando organizar dichas imágenes en dos carpetas: una conteniendo las imágenes con caries y la otra carpeta, conteniendo las imágenes que no tenían caries, según el criterio del especialista. Una vez clasificado todo el dataset, se dividió en conjuntos de entrenamiento, validación y prueba aplicando la técnica de muestreo estratificado según la cantidad de caries encontrada en cada imagen, para obtener conjuntos más homogéneos y obtener resultados más precisos (Lohr, 2019). Se empleó la técnica de data augmentation para poder tener un dataset más

robusto, con lo cual, se logró tener la distribución de imágenes radiográficas que se muestran en el anexo 6.

Figura 7. Clasificación de placas radiográficas



IV.2. Selección del framework de Deep Learning YOLO para el diagnóstico de caries

(Cacñahuaray-Martínez, 2021) muestra una revisión de la literatura referente a la aplicación de la inteligencia artificial dentro del campo odontológico, entre las cuales se pueden encontrar diversas investigaciones que emplean el framework YOLO en sus diferentes versiones, demostrando resultados prometedores. (Prakash & Babitha, 2023) realizaron un comparativo entre las arquitecturas RCNN y YOLO en segmentación dental y detección de caries en imágenes de rayos X, evaluando el rendimiento de cada uno con las métricas precisión, recall y F1-score. Se emplearon dos lotes de imágenes, tal y como lo muestra la tabla 3.

Tabla 3. Dataset para los lotes 1 y 2.

	Número total de imágenes – 1000	
	Lote 1 (80-20)	Lote 2 (70-30)
Nro. Imágenes Entrenamiento	800	700
Nro. Imágenes Prueba	200	300

Las tablas 4 y 5 muestran el análisis de rendimiento de ambas arquitecturas.

Tabla 4. Análisis de rendimiento en el lote de imágenes 1.

Modelos/Métricas	Accuracy	Precisión	Recall	F1-Score
Faster R-CNN	0.75	0.89	0.84	0.85
YOLO	0.88	0.94	0.86	0.92

Tabla 5. Análisis de rendimiento en el lote de imágenes 2.

Modelos/Métricas	Accuracy	Precisión	Recall	F1-Score
Faster R-CNN	0.73	0.73	0.82	0.77
YOLO	0.83	0.80	0.92	0.85

Dicho estudio confirma que ambas arquitecturas podrían ayudar significativamente a los profesionales clínicos en la detección de caries. En el artículo (Córdova, y otros, 2022), los resultados experimentales demuestran que los detectores de imágenes basados en la arquitectura YOLO son prometedores para la detección de objetos, con buenos rendimientos en precisión de detección, tiempo de procesamiento y

consumo de memoria, comparado con otras arquitecturas como Faster RCNN, Mask, RCNN, EfficientDet y RetinaNet.

Basado en la literatura anterior, donde se evidencia su efectividad frente a otras arquitecturas y su empleo en investigaciones en el área odontológica, en la presente investigación se creó el modelo de Deep Learning para la detección de caries en imágenes radiográficas con el framework YOLO en su versión 8, cuyo enfoque se basa en una red neuronal convolucional (CNN) que se entrena para detectar y clasificar objetos en una imagen. Este framework tiene grandes beneficios al momento de crear modelos basados en deep learning, como la detección de múltiples objetos en una sola pasada de la red, lo cual lo diferencia de enfoques más tradicionales que requieren pasar la imagen varias veces. Es simple y su personalización es muy sencilla para las tareas de detección, segmentación y clasificación de objetos en imágenes.

IV.3. Realizar el entrenamiento al modelo de Deep Learning para mejorar su precisión

En la fase de entrenamiento del modelo de Deep Learning, se emplearon un total de 812 imágenes, tal y como lo muestra el anexo 6, etiquetadas y separadas de acuerdo a la etiqueta caries. Se empleó la tarea de clasificación y el modo train de YOLO. Se entrenó el modelo a 15 épocas en bloques de 8, logrando picos de hasta 90% de precisión.

En la fase de validación se busca la inferencia del modelo (Chollet, 2018, pág. 345), para lo cual se realiza una supervisión de la fase de entrenamiento, realizando ajustes al modelo a través de los hiperparámetros del mismo, para lo cual se selecciona el archivo best.pt, el cual contiene los mejores pesos de la red neuronal recolectados durante el entrenamiento (Rath, 2022), con lo cual se logró una precisión del 70% para el modelo desarrollado en la presente investigación. Dicho resultado, se encuentra dentro del rango de precisión obtenido en investigaciones previas como la de (Bayraktar & Ayan, 2021) en la cual se obtuvo una precisión del 80% y valores predictivos positivos de 70%. Dicho estudio concluye en que los parámetros evaluados presentan resultados prometedores en detección de caries. En (Prakash & Babitha, 2023) en

cuya investigación se evidencia que se obtuvo una precisión del 89% y 73% en ambos grupos de estudio, confirman que el modelo podría ayudar significativamente a los médicos odontólogos en la detección de caries en situaciones clínicas. De manera similar, en (Lee S, 2021), se realizó un estudio empleando Deep Learning para detección de caries en radiografías bitewing, obteniendo una precisión del 63.29% y un recall de 65.02%, con lo cual concluyeron que el modelo puede ayudar a los especialistas a diagnosticar caries de manera más precisa. Por lo tanto, el 70% de precisión obtenido durante el entrenamiento del modelo en esta investigación, se presenta como un resultado prometedor dentro de la detección de caries y que puede ayudar a los médicos especialistas al momento de preparar su diagnóstico.

IV.4. Nivel de precisión del diagnóstico de caries mediante el uso del modelo basado en Deep Learning

Para la fase de prueba del modelo, se emplearon 290 imágenes que no fueron parte de los procesos ni de entrenamiento ni de validación, de las cuales 110 fueron etiquetados con caries y 180 fueron etiquetados sin caries, logrando los siguientes resultados:

La clasificación de las imágenes fue realizada bajo el criterio del odontólogo especialista.

La tabla 6 nos muestra la cantidad de imágenes en las cuales el especialista detectó la presencia o ausencia de caries dental. El especialista detectó 110 imágenes con caries, lo que equivale a 37.9% y 180 imágenes sin caries, lo que equivale a un 62.1%.


La figura 8 nos muestra la distribución porcentual en base a la detección del especialista.

Tabla 6. Frecuencias de la detección de caries por parte del odontólogo especialista.

	Frecuencia	
Caries	a	Porcentaje

No	180	62.1%
Si	110	37.9%
Total	290	100.0%

Figura 8. Frecuencias de la detección de caries por parte del odontólogo especialista.



En contraste con lo anterior, mediante el uso del modelo de Deep Learning para la detección de caries en las mismas imágenes radiográficas, se obtuvieron los siguientes resultados:



La tabla 7 muestra la frecuencia y el porcentaje de pacientes con y sin caries en la muestra de 290 imágenes empleadas en la fase de prueba. En la columna "Caries" se indica si cada paciente tiene caries o no. En la siguiente columna, "Frecuencia", se muestra el número de pacientes en cada categoría. En este caso, hay 202 pacientes sin caries y 88 pacientes con caries.

La columna "Porcentaje" indica el porcentaje de pacientes en cada categoría con respecto al total. Según los datos, para el modelo de Deep Learning, el 69.7% de los pacientes no tienen caries, mientras que el 30.3% sí tienen caries.

Tabla 7. Frecuencias de la detección de caries por parte del modelo de Deep Learning propuesto

Caries	Frecuencia	
	a	Porcentaje
No	202	69.7%
Si	88	30.3%
Total	290	100.0%

Figura 9. Frecuencias de la detección de caries por parte del modelo de Deep Learning propuesto.



IV.5. Comparativa del diagnóstico de caries entre el uso del modelo de Deep Learning y el análisis de un especialista

Al tener los resultados tanto del especialista como del modelo de Deep Learning para la detección de caries en las imágenes radiográficas, se procedió a realizar la comparativa para medir el grado de similitud entre ambas. De un total de 290 imágenes, el especialista detectó 180 imágenes sin caries y el modelo de Deep Learning detectó 202. En el caso de imágenes con caries, el especialista detectó 110 imágenes con esta característica, mientras que el modelo detectó 88 imágenes. La tabla 8

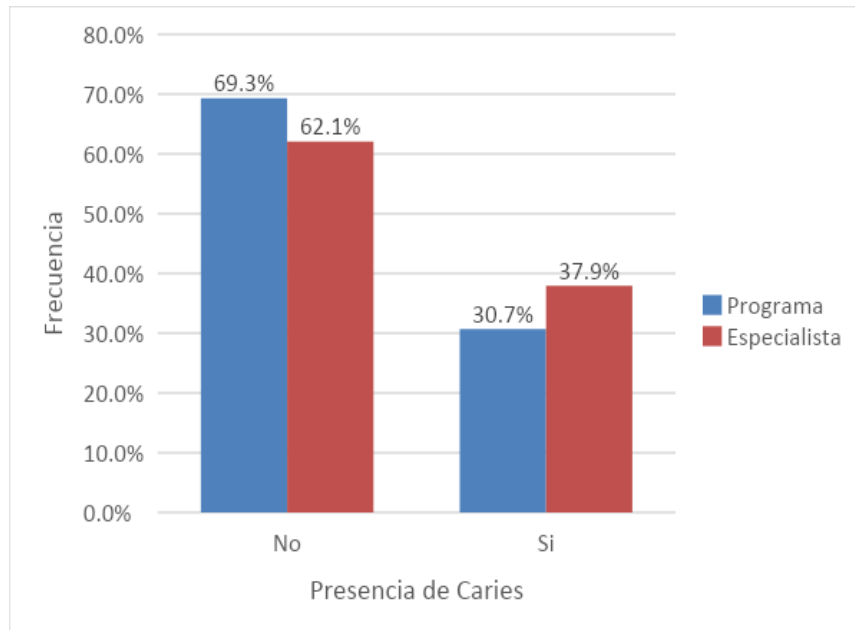
nos muestra comparativa de la cantidad de imágenes en las cuales el especialista y el modelo detectaron la presencia o ausencia de caries dental.

Tabla 8. Frecuencias de la detección de caries por parte del especialista y del modelo de Deep Learning

	Frecuencias		Frecuencias	
	Programa	Especialista	Programa	Especialista
0	202	180	69.7%	62.1%
1	88	110	30.3%	37.9%
Total	290	290	100.0%	100.0%

En la figura 10 vemos la distribución porcentual en base a la comparativa de detección de caries, tanto del especialista como del modelo. A nivel porcentual, la detección de caries por el especialista representa un 37.9% del total de imágenes, mientras que el modelo detectó un 30.7% del total.

Figura 10. Porcentajes comparados de la detección de caries por el especialista y el modelo de Deep Learning




Podemos notar, gracias a la tabla 9, el nivel de precisión del modelo de Deep Learning al ser contrastado con la detección del especialista. Existe un 80% de similitud en el nivel de detección de caries en imágenes radiográficas.

Tabla 9. Coincidencias en la detección de caries por parte del especialista y del modelo de Deep Learning

Coincidencias	Frecuencia	Porcentaje
Si	232	80.0%
No	58	20.0%
Total	290	100.0%

La figura 11 nos muestra la distribución porcentual de coincidencias en la detección de caries entre el modelo de Deep Learning y el odontólogo especialista.

Figura 11. Coincidencias en la detección de caries por parte del especialista y del modelo de Deep Learning



La figura 12 muestra las fórmulas aplicadas a la presente investigación. Se aplicó la prueba z para la diferencia de promedios de dos poblaciones pareadas dado que se mide la misma variable bajo dos condiciones distintas y considerando el tamaño de la muestra que son 290 imágenes radiográficas.

Figura 12. Fórmulas para el cálculo de la prueba estadística z.

Hipótesis

$$H_0: \mu_1 = \mu_2$$

$$H_1: \mu_1 \neq \mu_2$$

La tabla 10 nos muestra la prueba z para la diferencia de promedios aplicada al estudio, la cual indica que el valor encontrado se encuentra dentro del rango de No rechazo de la H_0 .

Tabla 10. Prueba z para la diferencia de los promedios de dos poblaciones pareadas aplicada al estudio

Medidas	Programa	Especialista
Promedio	0.307	0.379
Varianza	0.213	0.236
Desviación Estándar	0.462	0.486
n	290	290

Z prueba	-1.839
----------	--------

Nivel de confianza (α)	95%
$\alpha/2$	97.5%
Z $\alpha/2$	1.960

Para evaluar el rendimiento del modelo de clasificación basado en deep learning, existen métricas que nos proporcionan información valiosa sobre la calidad de las detecciones.

La primera métrica es la precisión, la cual mide la fracción de las detecciones que fueron correctas respecto al número total de detecciones realizadas.

Otra métrica, es recall o sensibilidad, la cual mide la proporción de verdaderos positivos entre el número total de ejemplos positivos. Un alto recall indica que el modelo logra detectar una gran proporción de las características reales

presentes en las imágenes, lo que es importante para minimizar los falsos negativos y garantizar que no se pasen por alto las características importantes. La última métrica, es el F1-Score, la cual representa la proporción de ejemplos positivos correctamente detectados entre todos los ejemplos positivos presentes en los datos.

La tabla 11 nos muestra los valores obtenidos de las métricas precisión, recall y F1-score para medir el rendimiento de nuestro modelo.

Tabla 11. Indicadores Precision, Recall y F1.

Actual Positivo (TP)	Actual Negativo (FP)	Predicción Positiva (TN)	Predicción Negativa (FN)
70	18	162	40
Precisión	TP / (TP + FP)		80%
Recall	TP / (TP + FN)		64%
F1-Score	2 * ((Precisión * Recall) / (Precisión + Recall))		71%

En contraste con lo anterior, en la tabla 12, se observa que el p valor es menor a 0.05, lo que indica que el modelo basado en Deep Learning tiene un efecto positivo en la detección de caries en imágenes radiográficas en una clínica especializada, Trujillo 2023.

Tabla 12. Efecto del modelo basado en Deep Learning para la detección de caries en imágenes radiográficas en una clínica especializada, Trujillo 2023.

	Diferencias emparejadas				95% de intervalo de confianza de la diferencia		t	gl	Sig. (bilateral)
	Media	Desv. Desviación	Desv. Error promedio	Inferior	Superior				
Pre test - Post test	18.257	12.503	2.113	-22.552	-13.962	-8.639	290	0.000	

Por lo tanto, el nivel de precisión del diagnóstico de caries basada en imágenes radiográficas mediante el uso de Deep Learning tiene resultados prometedores dentro de la detección de caries en imágenes radiográficas.

VI. DISCUSIÓN, CONCLUSIONES y RECOMENDACIONES

VI.1 Discusión

Clasificar placas radiográficas dentales para detectar patrones de caries en una clínica especializada de la ciudad de Trujillo, en el año 2023.

Para la presente investigación se contó con el apoyo de un especialista para poder etiquetar el conjunto de datos. La clasificación fue realizada a las 1160 imágenes radiográficas para las fases de entrenamiento y validación, y luego 290 imágenes para la fase de prueba. Es muy importante resaltar el criterio que pueda emplear el especialista y este dependerá de muchos factores, incluyendo su experiencia clínica, habilidad de observación, el entrenamiento en diagnóstico y el uso de herramientas y tecnologías de apoyo (Amaechi, 2019). Además, la detección de caries puede ser un desafío debido a que a menudo se desarrollan en lugares difíciles de visualizar a simple vista. También, es importante considerar las marcadas diferencias que puede haber entre los distintos tipos de radiografías dentales, como las panorámicas y las bitewing. Las radiografías de tipo bitewing ofrecen una visión más detallada y clara, por centrarse en una región determinada y abarcar poca cantidad de dientes, lo que permitirá detectar con mayor facilidad la presencia o ausencia de caries. En cambio, las radiografías panorámicas muestran la totalidad de dientes, lo cual muchas veces no permite al especialista identificar las enfermedades con facilidad, sin embargo, son las más solicitadas por todos los centros odontológicos y especialistas. Es importante destacar que tanto el estudio de (Lee, Sang-il, Junik, Sumi, & Shin, 2021), como esta investigación demuestran el potencial de las técnicas de aprendizaje profundo en el campo de la detección de caries

dental empleando imágenes radiográficas. Sin embargo, existen diferencias en cuanto a enfoque (segmentación versus clasificación), tamaño del conjunto de datos y el tipo de radiografía (bitewing versus panorámica) lo que finalmente puede influir en los resultados obtenidos.

Seleccionar el algoritmo a emplear en el diagnóstico de caries en una clínica especializada de la ciudad de Trujillo, en el año 2023.

Para poder crear un modelo basado en Deep Learning se puede hacer uso de diversas bibliotecas y frameworks que facilitan y agilizan su desarrollo e implementación. En esta investigación se empleó el framework de Deep Learning llamado YOLO en su versión 8, que entre los beneficios que otorga, está su enfoque de detección única, lo que permite que el modelo realice la detección en una sola pasada a través de la imagen, en lugar de pasar por múltiples etapas de detección, lo que lo hace más rápido y eficiente. Otra ventaja es que puede detectar y clasificar múltiples objetos en una sola imagen, incluso si pertenecen a diferentes clases, lo que lo hace adecuado para tareas de detección de objetos en escenas complejas. Dado que para la presente investigación se contaba con recursos de hardware limitados, un punto importante fue la optimización de rendimiento de los mismos y se requería un framework que permitiera aprovecharlos eficientemente. En comparación con (Jae-Hong Lee, 2018), donde emplean la arquitectura GoogleNet en la que emplea diferentes tamaños de filtros convolucionales y capas de reducción de dimensionalidad para capturar características a diferentes escalas lo cual puede hacer el proceso más lento en términos de tiempo de inferencia, en esta investigación se emplea YOLO que realiza la clasificación en una sola pasada a la imagen, lo cual lo hace más eficiente en tiempo de ejecución.

Realizar el entrenamiento al modelo de Deep Learning para mejorar la precisión de diagnóstico de caries.

La etapa de entrenamiento y validación del modelo de Deep Learning es muy importante porque se definirá la precisión que puede alcanzar el

modelo para poder clasificar nuevas imágenes. Para alcanzar la precisión del modelo de esta investigación, se probaron modificando los parámetros como son la cantidad de épocas, la cual fue fijada en un total de 15, lo que significa que, en cada una de ellas, la red neuronal vió todas las imágenes del conjunto de datos una vez. Es muy importante tener en cuenta este parámetro para evitar que el modelo se sobreajuste y no tenga buen rendimiento con nuevos datos, además de contar con los recursos de hardware necesarios para poder realizarlo sin problemas. De manera contraria, un número muy bajo de épocas generaría un subajuste, el cual no permitirá que la red neuronal aprenda lo suficiente para realizar buenas detecciones. Otro parámetro importante para el entrenamiento y la validación es la cantidad de imágenes que se emplearán, porque permitirá la representatividad del conjunto de datos, es decir, la variabilidad de las condiciones de las imágenes. Cuantas más imágenes se tengan, se puede capturar mejor esta variabilidad y el modelo podrá detectar caries en diferentes situaciones, como diferentes formas de caries, tamaños, ubicaciones. El tipo de radiografía influirá en el nivel de precisión por el nivel de detalle que pueden tener. En esta investigación se emplearon radiografías panorámicas que muestran toda la boca y no únicamente dientes. En comparación a esto, en (Lee, Sang-il, Junik, Sumi, & Shin, 2021), se plantea el uso de redes neuronales convolucionales para el procesamiento de imágenes radiográficas de aleta de mordida (bitewing radiographs). Emplearon dos modelos para segmentación de caries. Además, fueron empleadas 304 radiografías de aleta de mordida para el entrenamiento del modelo y 50 para la evaluación del rendimiento, logrando una precisión del 63% en la detección temprana de caries. Concluyen que el modelo de Deep learning puede ayudar a los médicos a diagnosticar con mayor precisión la presencia de caries dental. En contraste, en esta investigación se emplea un framework de Deep Learning para clasificación de imágenes panorámicas, empleando 1160 imágenes para entrenar y validar el modelo, y 290 para probar el modelo generado, logrando una precisión del 80% en detección de caries. Además, en esta investigación, se evidencia una similitud cercana a la

detección de caries de un experto especialista en imágenes radiográficas comparada con la del modelo de Deep Learning.

Describir el nivel de precisión del diagnóstico de caries basada en imágenes radiográficas mediante el uso de un modelo basado en Deep Learning en una clínica especializada de la ciudad de Trujillo, en el año 2023.

Para medir el nivel de precisión del modelo basado en Deep Learning se toma como referencia el diagnóstico del especialista, el cual dependerá de diversos factores como son su experiencia clínica, su habilidad y el entrenamiento previo que haya adquirido. En la tabla 4 se muestra que el especialista observó 180 imágenes radiográficas sin caries y 110 imágenes con caries. Al observar que, en las fases de entrenamiento y validación, el modelo alcanzó una precisión del 70% en comparación al diagnóstico del especialista con las imágenes de dichas fases, se procedió a evaluarlo y se contrastó con el diagnóstico del especialista. Como resultado, el modelo detectó 202 imágenes sin caries y 88 imágenes con caries. La tabla 3 muestra dicha frecuencia de detección. De manera similar, e Luya Lian, (2021) en su investigación empleó un total de 1160 radiografías panorámicas que fueron evaluadas por 3 expertos. Las imágenes fueron distribuidas en 3 datasets: entrenamiento y validación, con un total de 1071 imágenes y otro dataset de pruebas con un total de 89 imágenes radiográficas, concluyendo que el rendimiento del deep learning fue muy similar al de los expertos dentistas. De igual forma, en esta investigación, también se emplearon 1160 imágenes dentales radiográficas panorámicas para las fases de entrenamiento y validación y fueron evaluadas por 1 odontólogo especialista. Otro dataset empleado en esta investigación fue para pruebas, que consistió en 290 nuevas imágenes. También, para esta investigación, se concluye que existe un nivel de precisión similar al del experto especialista. Estos hallazgos son alentadores, ya que indican que el modelo de aprendizaje profundo es capaz de obtener resultados comparables a los de los expertos humanos en la detección y evaluación de radiografías dentales panorámicas. Lo

anterior sugiere que el empleo de técnicas de aprendizaje profundo podría ser una herramienta prometedora para mejorar la precisión en la interpretación de imágenes dentales radiográficas. Sin embargo, antes de poder ser utilizado como una herramienta de soporte para odontólogos, se requiere incrementar la precisión del modelo de tal forma que se pueda obtener resultados más parecidos a los que daría un odontólogo especialista.

Realizar un comparativo entre el diagnóstico de caries basada en imágenes radiográficas mediante el uso de Deep Learning y mediante el análisis de un especialista en una clínica especializada de la ciudad de Trujillo, en el año 2023.

Con los resultados mostrados en la tabla 6, se puede apreciar que el modelo de Deep Learning alcanza una precisión del 80% comparado con el diagnóstico del especialista con el mismo conjunto de datos. Este modelo obtuvo un rendimiento aceptable según los valores obtenidos en las métricas de la tabla 8, pero la efectividad depende mucho del entrenamiento del modelo. En las fases de entrenamiento y validación, el modelo obtuvo una precisión del 70%. Para poder mejorar este nivel de precisión sería conveniente realizar unas mejoras al modelo, para lo cual se requiere aplicar medidas, como puede ser ajustar los hiperparámetros, probando con incrementar el número de épocas o incrementar el tamaño del batch para que el modelo ajuste los pesos promediando los gradientes de error por lote de imágenes en lugar de hacerlo individualmente. Otra medida que se podría aplicar sería incrementar el tamaño del dataset con imágenes de buena calidad y debidamente etiquetadas. A diferencia del presente estudio, según Chanampe, y otros (2019) en su investigación, los autores utilizaron técnicas de aprendizaje profundo (Deep Learning) para clasificar distintos tipos de lesiones mamarias en 322 imágenes radiográficas, logrando alcanzar un nivel de precisión del 62% en la fase de entrenamiento. En contraste, en esta investigación se empleó el framework YOLO versión 8, empleando 1160 imágenes radiográficas, logrando un nivel de precisión de 70% en las fases de entrenamiento y

validación. Estos hallazgos sugieren que el uso de un conjunto de datos más grande puede tener un impacto significativo en el rendimiento del modelo de detección de caries dental utilizando el framework YOLO. El aumento en el tamaño del conjunto de datos proporcionó una mayor diversidad de ejemplos y escenarios, lo que permitió al modelo aprender y generalizar mejor las características de la caries dental.

VI.2 Conclusiones

Al término de la presente investigación, podemos concluir que se determinó un nivel de precisión del 80% del modelo de clasificación de imágenes radiográficas dentales basado en Deep Learning, con un entrenamiento orientado en la presencia o ausencia de caries, para una clínica especializada de la ciudad de Trujillo, el cual fue evaluado de acuerdo a su nivel de precisión, y evidenciado en lo siguiente:

- Se clasificaron un total de 141 imágenes radiográficas panorámicas con caries, y un total de 149 imágenes radiográficas sin caries.
- Se utilizó el framework YOLO, para la creación del modelo de detección de caries basado en clasificación de imágenes radiográficas panorámicas dentales.
- Se realizaron pruebas al modelo, empleando 290 imágenes etiquetadas en base a la presencia o ausencia de caries, las cuales no formaron parte de las etapas de entrenamiento y validación.
- Se observó un nivel de precisión del 70% para el modelo de Deep Learning con las imágenes de la fase de entrenamiento y validación.
- Al ser el odontólogo especialista nuestro observador basal, se consideró que su nivel de efectividad para la detección de caries en imágenes radiográficas es del 100%.
- Se realizó un comparativo entre el diagnóstico de caries basado en el modelo de Deep Learning y el diagnóstico de caries del especialista, mediante el cual se observó una precisión del 80% del modelo en base al diagnóstico del especialista.

VI.3 Recomendaciones

Al término de la presente investigación, se plantean las siguientes recomendaciones:

Para poder I

- Se deberían preparar un conjunto de datos de mayor tamaño, que contenga imágenes etiquetadas correctamente con las clases con y sin caries. Dicho conjunto de datos deberá tener una cantidad representativa de cada clase y la precisión de las anotaciones de las mismas requiere del apoyo de un profesional especialista.
- Se recomienda explorar otros frameworks de Deep Learning para visión por computadora para poder elegir el que mejor se adapte a la investigación. Para lograr esto, se deberán asegurar los recursos computacionales mínimos para cada caso.
- Se recomienda aumentar del número de imágenes en la etapa de test para ayudar a evaluar la generalización del modelo, es decir, su capacidad para detectar objetos correctamente en nuevas imágenes que no se utilizaron durante el entrenamiento. Al tener un conjunto de pruebas más grande y representativo para cada caso, se podría obtener una evaluación más confiable del desempeño y la precisión del modelo YOLO.
- Futuras investigaciones podrían considerar ajustar los parámetros del modelo, como la tasa de aprendizaje, el tamaño del batch y la cantidad de épocas para poder lograr una precisión más alta del modelo.
- Para evitar el sesgo del observador al clasificar las imágenes, se recomienda la participación de más de un especialista con similares niveles de experiencia para evaluar la totalidad del conjunto de datos.
- Se recomienda implementar otras tareas de visión por computadora al modelo de clasificación propuesto, tales como la detección y la segmentación para lograr ubicar con mayor nivel de precisión la caries en imágenes radiográficas.

Lista de referencias

- Akselrod-Ballin A, C. M.-Z. (2019). Predicting Breast Cancer by Applying Deep Learning to Linked Health Records and Mammograms. *Radiology*.
- Alsubai S, K. H. (2022). Ensemble deep learning for brain tumor detection. *Front Comput Neurosci*.
- Amaechi, B. T. (2019). Emerging technologies for diagnosis of dental caries: The road so far. *Journal of Applied Physics*, 241'252. doi:<https://doi.org/10.1063/1.3116632>
- Asociación Médica Mundial. (21 de marzo de 2017). Obtenido de <https://www.wma.net/es/polices-post/declaracion-de-helsinki-de-la-amm-principios-eticos-para-las-investigaciones-medicas-en-seres-humanos/>
- Bayraktar, Y., & Ayan, E. (2021). Diagnosis of interproximal caries lesions with deep convolutional neural network in digital bitewing radiographs. *Clinical Oral Investigations*(26), 623 - 632. doi:<https://link.springer.com/article/10.1007/s00784-021-04040-1>
- Cacñahuaray-Martínez, G. (2021). Aplicación de la inteligencia artificial en Odontología. *Revista Científica Odontología Sanmarquina*.
- Carrillo Sanchez, C. (2018). Recursos actuales en el diagnóstico de caries. *Revista ADM*, 334-339. Obtenido de <https://www.medigraphic.com/pdfs/COMPLETOS/adm/2018/od186.pdf#page=38>
- Chollet, F. (2018). *Deep Learning with Python*. Shelter Island, New York: Manning Publications Co. Obtenido de <https://unica.it/static/resources/cms/documents/DeepLearningWithPython.pdf>
- Choy, G. (2018). Current applications and future impact of machine learning in radiology. *Radiology*, 318-328. Obtenido de <https://doi.org/10.1148/radiol.2018171820>
- Concytec. (2018). *Concytec*. Obtenido de <https://conocimiento.concytec.gob.pe/termino/investigacion-basica/>
- Córdova, M., Pinto, A., Hellevik, C., Alaliyat, S.-A., Hameed, I., Pedrini, H., & Torres, R. (2022). Litter Detection with Deep Learning: A Comparative Study. 22. doi:<https://doi.org/10.3390/s22020548>
- Fejerskov, O. &. (2015). *Dental caries: The disease and its clinical management*. Wiley Blackwell.
- Frankenfield. (2023). *Artificial Intelligence: What It Is and How It Is Used*. Obtenido de Investopedia: <https://www.investopedia.com/terms/a/artificial-intelligence-ai.asp>
- G. Shobha, S. R. (2018). "Machine learning," in *Handbook of Statistics*. Elsevier. doi:<https://doi.org/10.1016/bs.host.2018.07.004>

- Goodfellow, I. (2016). *Deep Learning*. The MIT Press. Cambridge, Massachusetts. Obtenido de <https://books.google.com.pe/books?hl=es&lr=&id=omivDQAAQBAJ&oi=fnd&pg=PR5&dq=Deep+Learning.+The+MIT+Press.+Cambridge,+Massachusetts+goodfellow&ots=MNU4eptHTT&sig=DTAC6MgF5lbHclWnpoSLJQ8C1Rk#v=onepage&q=Deep%20Learning.%20The%20MIT%20Press.%20Cambridge%2C%20>
- Gulshan, V. P. (2016). Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*, 2402-2410. doi:<https://doi.org/10.1001/jama.2016.17216>
- Hearty, J. (2016). *Advanced Machine Learning with Python*. Reino Unido: Packt Publishing Ltd. Obtenido de <https://www.perlego.com/book/117718/advanced-machine-learning-with-python-pdf>
- Hernández Sampieri, R., & Mendoza Torres, C. P. (2018). *Metodología de la investigación: las rutas: cuantitativa, cualitativa y mixta*. Sede Académica La Paz: Mc Graw Hill Educación. Obtenido de <http://repositorio.uasb.edu.bo/handle/54000/1292>
- Jae-Hong Lee, D.-H. K.-N.-H. (2018). Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *Journal of Dentistry*, 106-111.
- Kelleher, J. D. (2019). *Deep Learning*. Cambridge, MA: The MIT Press. Obtenido de <https://dokumen.pub/qdownload/deep-learning-0262537559-9780262537551.html>
- Lee S, O. S. (2021). Deep learning for early dental caries detection in bitewing radiographs. *Sci Rep*. doi:<https://www.nature.com/articles/s41598-021-96368-7>
- Lohr, S. (2019). *Sampling: Design and Analysis*. Arizona: Duxbury Press. Obtenido de https://drive.uqu.edu.sa/_/maatia/files/Sampling.pdf
- Luya Lian, T. Z. (2021). Deep Learning for Caries Detection and Classification. *Diagnostics*, 11.
- Mallishery S, C. P. (2020). The precision of case difficulty and referral decisions:. *Clin Oral Inves-*, 24.
- Mondal MRH, B. S. (2021). Diagnosis of COVID-19 Using Machine Learning and Deep Learning: A Review. *Curr Med Imaging*.
- Ñaupas, H., Valdivia, M., Palacios, J., & Romero, H. (2018). *Metodología de la investigación cuantitativa, cualitativa y redacción de la tesis*. A. Gutierrez (ed.); 5a. Edición.
- Nguyen, T. T. (2020). Deep Learning: Conceptual Overview. *Journal of Big Data*, 1-23. doi:<https://doi.org/10.1186/s40537-020-00329-0>
- Otzen, T., & Manterola, C. (2017). Técnicas de Muestreo sobre una Población a Estudio. *International Journal of Morphology*, 227-232. Obtenido de <https://dx.doi.org/10.4067/S0717-95022017000100037>
- Prakash, D., & Babitha, D. (2023). Prakash, D.C., & Babitha, D. (2023). Deep Learning Approach for Detection of Dental Caries in X -Ray Images. *International Journal of Scientific*

- Development and Research (IJSDR)*. Obtenido de <https://www.ijedr.org/papers/IJEDR2306193.pdf>
- Pretty, I. A. (2017). *Oral healthcare systems and prevention of oral diseases in diverse populations*. Springer.
- Rath, S. (19 de 04 de 2022). *LearnOpenCV*. Obtenido de <https://learnopencv.com/custom-object-detection-training-using-yolov5/>
- Sampieri, R., Collado, C., & Lucio, P. (2018). *Metodología de la investigación*. Edición McGraw-Hill (Octava edi).
- Sarmiento-Ramos, J. L. (2020). Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica. *Revista UIS Ingenierías*, 1-18.
- Shorten, C. &. (2019). Data augmentation in computer vision: A survey and guide. *Journal of Big Data*. Obtenido de <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-019-0197-0>
- Smith, J. &. (2019). Deep Learning-Based Model for Dental Caries Detection in X-Ray Images. *Journal of Medical Imaging*, 1-10. doi:<https://doi.org/10.1117/1.JMI.6.3.034002>
- Xiaoyi Zang, C. L. (2022). A deep learning model using convolutional neural networks for . *Annals of Translational Medicine*, 11.

Apéndice

ANEXO N°01

Protocolo de recolección de datos

PROTOCOLO DE RECOLECCION DE DATOS

Fecha: _____ N°: _____

Ciudad: _____

DATOS GENERALES:

1. Procedencia: _____

2. Presenta Caries: Si () No ()

Presunto número de caries: _____

ANEXO N°02:

Escala de grises con Open CV

```
In [ ]: import cv2

# Cargar la imagen
image = cv2.imread("603.bmp")

# Convertir la imagen a escala de grises
gray_image = cv2.cvtColor(image, cv2.COLOR_BGR2GRAY)
```


ANEXO N°03: Filtrado Gaussiano

```
In [9]: import cv2

# Cargar La imagen
image = cv2.imread("603.bmp")

# Aplicar el filtrado Gaussiano
kernel_size = (5, 5)
sigma_x = 0
filtered_image = cv2.GaussianBlur(image, kernel_size, sigma_x)

In [ ]:
```

ANEXO N°04: Empleo de la técnica de data augmentation

```
In [ ]: #pip install Augmentor
import Augmentor
import os

folder_path = 'rx/imagenes'
p = Augmentor.Pipeline(folder_path)

p.rotate(probability=0.5, max_left_rotation=10, max_right_rotation=10)
p.flip_left_right(probability=0.5)
p.flip_top_bottom(probability=0.5)
p.random_distortion(probability=0.5, grid_width=4, grid_height=4, magnitude=1)

num_images = 308 # Número de imágenes aumentadas que deseas generar
p.sample(num_images)
```

ANEXO N°05: Separación en carpetas de acuerdo a la característica a clasificar: con_caries y sin_caries

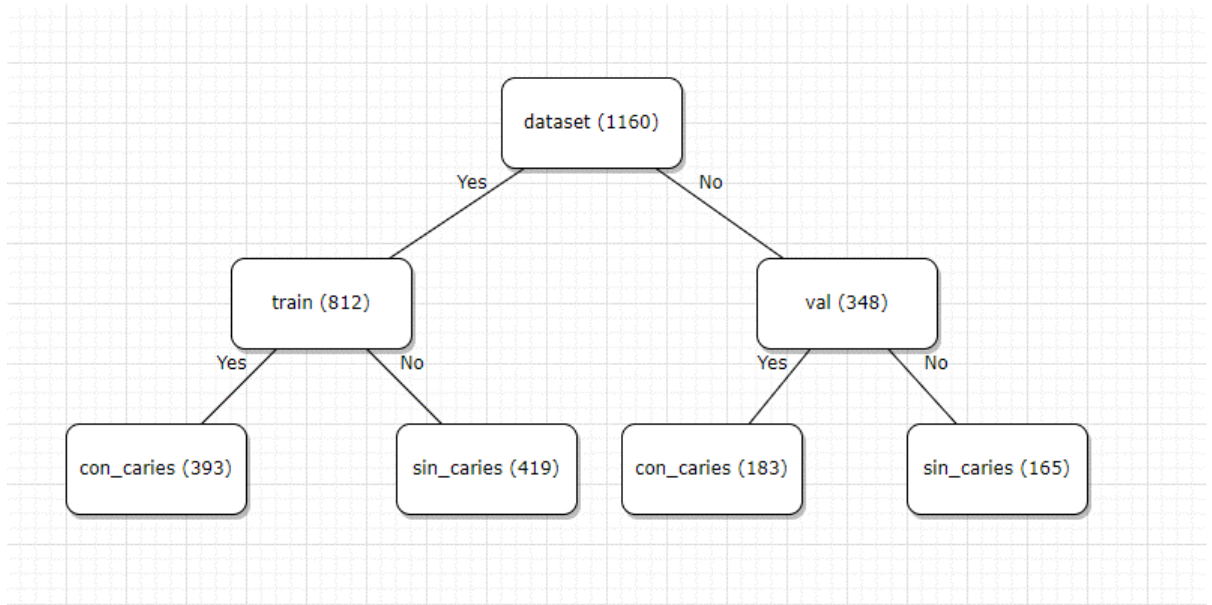
... > datasets > rx_panoramicas ▾

Tipo de archivo ▾ Personas ▾ Última modificación ▾

Nombre ↑	Propietario
con_caries	yo
sin_caries	yo

ANEXO N°06:

Creación de las carpetas train (entrenamiento) y val (validación), conteniendo las subcarpetas con_caries y sin_caries:



ANEXO N°07:

Ejecución del entrenamiento del modelo con YOLO versión 8:

```
!yolo task=classify mode=train data="/content/gdrive/MyDrive/05062023/datasets/" epochs=15 batch=8 plots=True
```

Ultralytics YOLOv8.0.114 Python-3.10.11 torch-2.0.1+cu118 CPU
yolo/engine/trainer: task=classify, mode=train, model=yolov8n-cls.pt, data=/content/gdrive/MyDrive/05062023/datasets/, epochs=15, patience=50, b
 Overriding model.yaml nc=1000 with nc=2

	from	n	params	module	arguments
0	-1	1	464	ultralytics.nn.modules.conv.Conv	[3, 16, 3, 2]
1	-1	1	4672	ultralytics.nn.modules.conv.Conv	[16, 32, 3, 2]
2	-1	1	7360	ultralytics.nn.modules.block.C2f	[32, 32, 1, True]
3	-1	1	18560	ultralytics.nn.modules.conv.Conv	[32, 64, 3, 2]
4	-1	2	49664	ultralytics.nn.modules.block.C2f	[64, 64, 2, True]
5	-1	1	73984	ultralytics.nn.modules.conv.Conv	[64, 128, 3, 2]
6	-1	2	197632	ultralytics.nn.modules.block.C2f	[128, 128, 2, True]
7	-1	1	295424	ultralytics.nn.modules.conv.Conv	[128, 256, 3, 2]
8	-1	1	460288	ultralytics.nn.modules.block.C2f	[256, 256, 1, True]
9	-1	1	332802	ultralytics.nn.modules.head.Classify	[256, 2]

YOLOv8n-cls summary: 99 layers, 1440850 parameters, 1440850 gradients
 Transferred 156/158 items from pretrained weights
TensorBoard: Start with 'tensorboard --logdir runs/classify/train2', view at <http://localhost:6006/>
augmentations: RandomResizedCrop(p=1.0, height=224, width=224, scale=(0.5, 1.0), ratio=(0.75, 1.3333333333333333), interpolation=1), Horizontal
optimizer: AdamW(lr=0.000714, momentum=0.9) with parameter groups 26 weight(decay=0.0), 27 weight(decay=0.0005), 27 bias(decay=0.0)
 Image sizes 224 train, 224 val
 Using 0 dataloader workers
 Logging results to runs/classify/train2
 Starting training for 15 epochs...

Epoch	GPU_mem	loss	Instances	Size
1/15	0G	0.07822	1	224: 100% 218/218 [43:09<00:00, 11.88s/it]
		classes top1_acc top5_acc: 100% 1/1 [00:15<00:00, 15.15s/it]		
		all 0.5 1		
2/15	0G	0.0717	1	224: 100% 218/218 [24:08<00:00, 6.65s/it]
		classes top1_acc top5_acc: 100% 1/1 [00:13<00:00, 13.52s/it]		
		all 0.5 1		
3/15	0G	0.06883	1	224: 100% 218/218 [23:50<00:00, 6.56s/it]
		classes top1_acc top5_acc: 100% 1/1 [00:13<00:00, 13.07s/it]		
		all 0.5 1		
4/15	0G	0.06591	1	224: 100% 218/218 [22:23<00:00, 6.16s/it]
		classes top1_acc top5_acc: 100% 1/1 [00:11<00:00, 11.99s/it]		
		all 0.7 1		

```
!yolo task=classify mode=train data="/content/gdrive/MyDrive/05062023/datasets/" epochs=15 batch=8 plots=True
```

```

Epoch GPU_mem  loss  Instances  Size
5/15   0G     0.06059  1          224: 100% 218/218 [23:22<00:00, 6.44s/it]
      classes top1_acc top5_acc: 100% 1/1 [00:13<00:00, 13.44s/it]
      all      0.5      1
Epoch GPU_mem  loss  Instances  Size
6/15   0G     0.06395  1          224: 100% 218/218 [22:43<00:00, 6.25s/it]
      classes top1_acc top5_acc: 100% 1/1 [00:11<00:00, 11.96s/it]
      all      0.9      1
Epoch GPU_mem  loss  Instances  Size
7/15   0G     0.0568   1          224: 100% 218/218 [23:04<00:00, 6.35s/it]
      classes top1_acc top5_acc: 100% 1/1 [00:13<00:00, 13.46s/it]
      all      0.8      1
Epoch GPU_mem  loss  Instances  Size
8/15   0G     0.05796  1          224: 100% 218/218 [23:19<00:00, 6.42s/it]
      classes top1_acc top5_acc: 100% 1/1 [00:11<00:00, 11.55s/it]
      all      0.8      1
Epoch GPU_mem  loss  Instances  Size
9/15   0G     0.05336  1          224: 100% 218/218 [22:44<00:00, 6.26s/it]
      classes top1_acc top5_acc: 100% 1/1 [00:12<00:00, 12.89s/it]
      all      0.6      1
Epoch GPU_mem  loss  Instances  Size
10/15  0G     0.05157  1          224: 100% 218/218 [22:57<00:00, 6.32s/it]
      classes top1_acc top5_acc: 100% 1/1 [00:12<00:00, 12.89s/it]
      all      0.8      1
Epoch GPU_mem  loss  Instances  Size
11/15  0G     0.05057  1          224: 100% 218/218 [21:51<00:00, 6.02s/it]
      classes top1_acc top5_acc: 100% 1/1 [00:12<00:00, 12.58s/it]
      all      0.8      1
Epoch GPU_mem  loss  Instances  Size
12/15  0G     0.04845  1          224: 100% 218/218 [22:31<00:00, 6.20s/it]
      classes top1_acc top5_acc: 100% 1/1 [00:13<00:00, 13.32s/it]
      all      0.6      1
Epoch GPU_mem  loss  Instances  Size
13/15  0G     0.0454   1          224: 100% 218/218 [23:39<00:00, 6.51s/it]
      classes top1_acc top5_acc: 100% 1/1 [00:12<00:00, 12.90s/it]
      all      0.6      1

```

```

0/15      0G      0.03750      1      224: 100% 218/218 [23:13<00:00, 0.42s/it]
classes  top1_acc  top5_acc: 100% 1/1 [00:11<00:00, 11.55s/it]
all      0.8      1

Epoch   GPU_mem   loss  Instances   Size
9/15     0G        0.05336  1          224: 100% 218/218 [22:44<00:00, 6.26s/it]
classes  top1_acc  top5_acc: 100% 1/1 [00:12<00:00, 12.89s/it]
all      0.6      1

Epoch   GPU_mem   loss  Instances   Size
10/15    0G        0.05157  1          224: 100% 218/218 [22:57<00:00, 6.32s/it]
classes  top1_acc  top5_acc: 100% 1/1 [00:12<00:00, 12.89s/it]
all      0.8      1

Epoch   GPU_mem   loss  Instances   Size
11/15    0G        0.05057  1          224: 100% 218/218 [21:51<00:00, 6.02s/it]
classes  top1_acc  top5_acc: 100% 1/1 [00:12<00:00, 12.58s/it]
all      0.8      1

Epoch   GPU_mem   loss  Instances   Size
12/15    0G        0.04845  1          224: 100% 218/218 [22:31<00:00, 6.20s/it]
classes  top1_acc  top5_acc: 100% 1/1 [00:13<00:00, 13.32s/it]
all      0.6      1

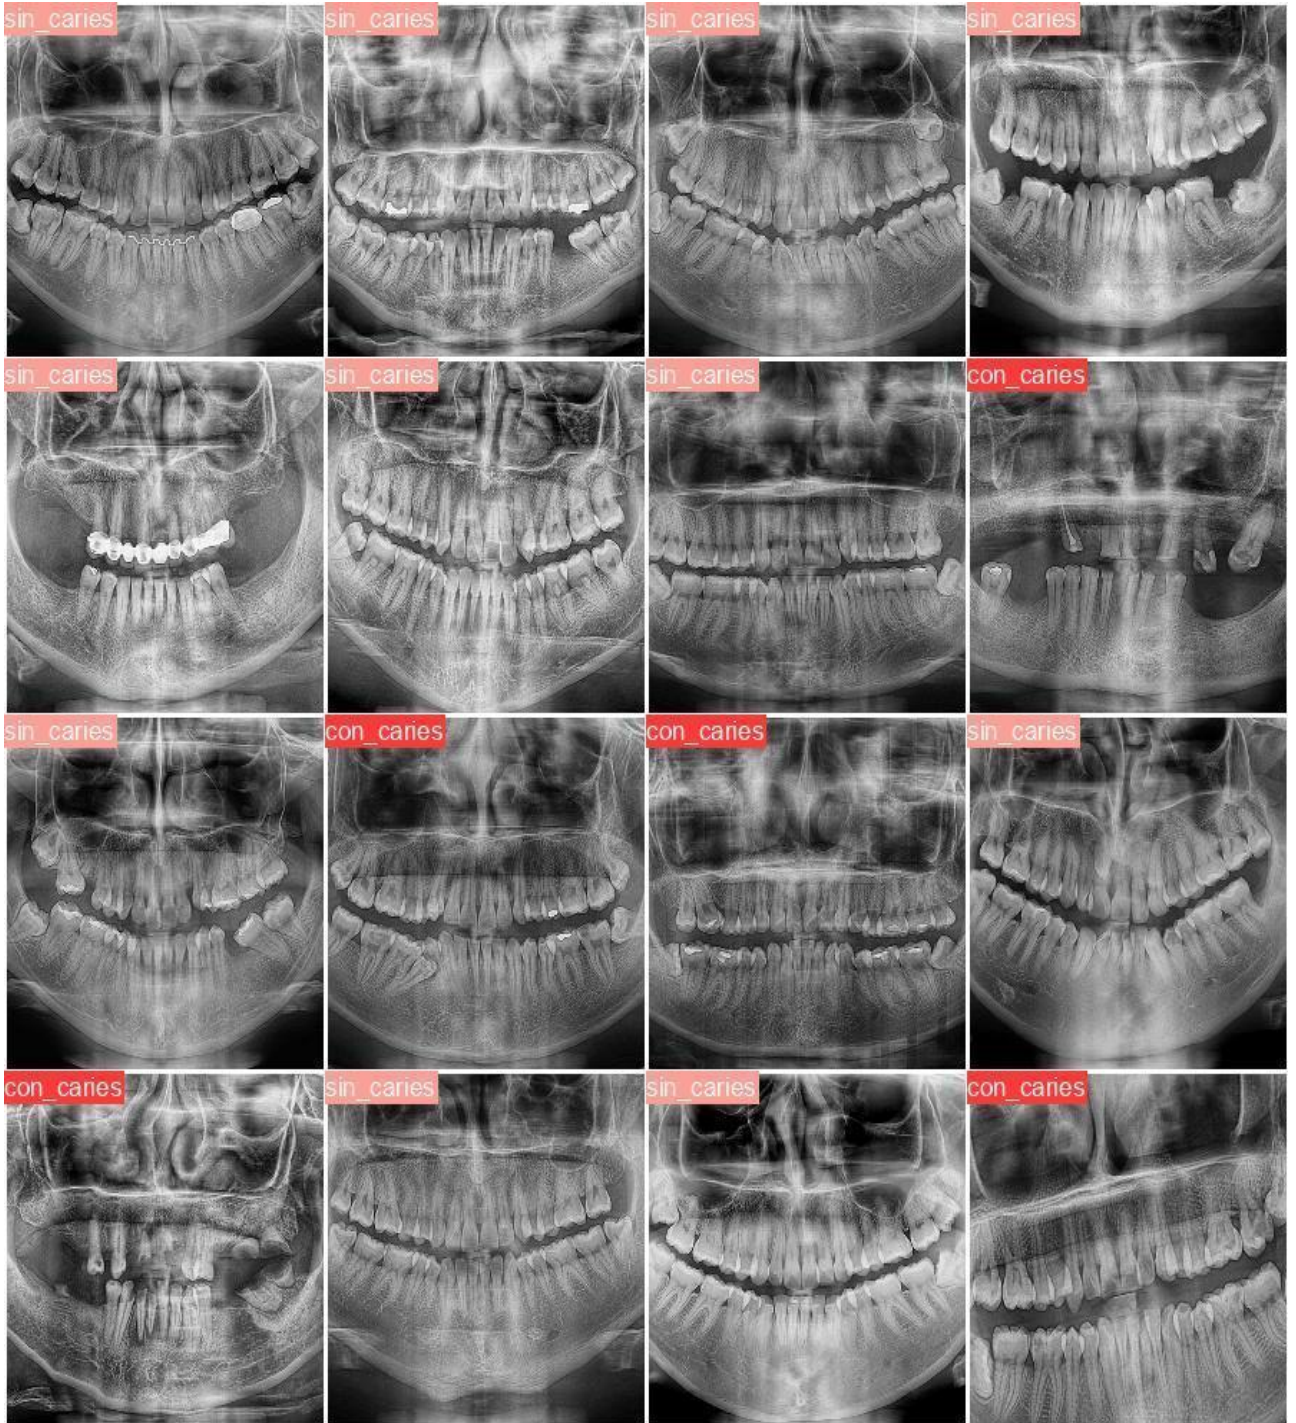
Epoch   GPU_mem   loss  Instances   Size
13/15    0G        0.0454   1          224: 100% 218/218 [23:39<00:00, 6.51s/it]
classes  top1_acc  top5_acc: 100% 1/1 [00:12<00:00, 12.90s/it]
all      0.6      1

Epoch   GPU_mem   loss  Instances   Size
14/15    0G        0.04319  1          224: 100% 218/218 [22:48<00:00, 6.28s/it]
classes  top1_acc  top5_acc: 100% 1/1 [00:12<00:00, 12.44s/it]
all      0.6      1

Epoch   GPU_mem   loss  Instances   Size
15/15    0G        0.04435  1          224: 100% 218/218 [22:29<00:00, 6.19s/it]
classes  top1_acc  top5_acc: 100% 1/1 [00:12<00:00, 12.69s/it]
all      0.7      1

15 epochs completed in 6.141 hours.
Optimizer stripped from runs/classify/train2/weights/last.pt, 3.0MB
Optimizer stripped from runs/classify/train2/weights/best.pt, 3.0MB
Results saved to runs/classify/train2

```



ANEXO N°08:

Validación del modelo

```
[ ] !yolo task=classify mode=val model="runs/classify/{train_name}/weights/best.pt" data="/content/gdrive/MyDrive/05062023/datasets/"

Ultralytics YOLOv8.0.114 Python-3.10.11 torch-2.0.1+cu118 CPU
YOLOv8n-cls summary (fused): 73 layers, 1437442 parameters, 0 gradients
      classes top1_acc top5_acc: 100% 1/1 [00:00<00:00, 2.38it/s]
        all      0.7      1
Speed: 0.0ms preprocess, 19.1ms inference, 0.0ms loss, 0.0ms postprocess per image
Results saved to runs/classify/val
```

ANEXO N°09:

Ejecución de predicciones con nuevas imágenes en Yolo versión 8:

```
[ ] !yolo task=classify mode=predict model='runs/classify/train2/weights/best.pt' conf=0.25 source="/content/gdrive/MyDrive/05062023/test/CON caries" save=True plots=True

Ultralytics YOLOv8.0.114 Python-3.10.11 torch-2.0.1+cu118 CPU
YOLOv8n-cls summary (fused): 73 layers, 1437442 parameters, 0 gradients

image 1/137 /content/gdrive/MyDrive/05062023/test/CON caries/183.bmp: 224x224 con_caries 0.93, sin_caries 0.07, 109.9ms
image 2/137 /content/gdrive/MyDrive/05062023/test/CON caries/187.bmp: 224x224 con_caries 0.67, sin_caries 0.33, 23.6ms
image 3/137 /content/gdrive/MyDrive/05062023/test/CON caries/189.bmp: 224x224 sin_caries 0.83, con_caries 0.17, 15.1ms
image 4/137 /content/gdrive/MyDrive/05062023/test/CON caries/190.bmp: 224x224 sin_caries 0.88, con_caries 0.12, 14.9ms
image 5/137 /content/gdrive/MyDrive/05062023/test/CON caries/197.bmp: 224x224 con_caries 0.66, sin_caries 0.34, 14.8ms
image 6/137 /content/gdrive/MyDrive/05062023/test/CON caries/198.bmp: 224x224 sin_caries 0.68, con_caries 0.32, 16.0ms
image 7/137 /content/gdrive/MyDrive/05062023/test/CON caries/201.bmp: 224x224 sin_caries 0.79, con_caries 0.21, 15.5ms
image 8/137 /content/gdrive/MyDrive/05062023/test/CON caries/202.bmp: 224x224 sin_caries 0.72, con_caries 0.28, 15.0ms
image 9/137 /content/gdrive/MyDrive/05062023/test/CON caries/204.bmp: 224x224 sin_caries 0.84, con_caries 0.16, 26.4ms
image 10/137 /content/gdrive/MyDrive/05062023/test/CON caries/206.bmp: 224x224 con_caries 0.92, sin_caries 0.08, 21.9ms
image 11/137 /content/gdrive/MyDrive/05062023/test/CON caries/209.bmp: 224x224 con_caries 0.60, sin_caries 0.40, 15.1ms
```

