

Approach for the Detection of Early Carious Lesions Based on Intraoral Photographs Using YOLOv7 and Faster R-CNN

William Huertas, Bachelor¹, Kevin Artica, Bachelor², José Luis Castillo-Sequera, Doctor³, Lenis Wong, Doctor⁴
^{1,2,4}Universidad Peruana de Ciencias Aplicadas, Perú, u201825600@upc.edu.pe, u20201a203@upc.edu.pe,
pcsilewo@upc.edu.pe
³Universidad de Alcalá, España, jluis.castillo@uah.es

Abstract— Tooth decay is a global challenge due to lack of dental care and excessive sugar consumption. These generate expensive dental treatments and affect quality of life, self-esteem, and productivity. Due to this, an approach is proposed for the detection of carious pre-lesions through dental image processing and using 2 Deep learning architectures most used in the literature: YOLOv7 and Faster R-CNN. The approach is developed in 4 phases: (i) acquisition of the dataset, (ii) development of architectures, (iii) performance evaluation and (iv) analysis of results. Both architectures focus on the use of a public dataset composed of a total of 9,327 images of Intraoral Photographs classified into 3 classes: “teeth with cavities” (0), “teeth without cavities” (1) and “teeth with amalgam” (2). A web system was built with the model that had the best performance. The results showed that the YOLOv7 architecture had better performance than Faster R-CNN, obtaining an average accuracy of 95.7% in the detection of teeth “without cavities,” “with cavities” and “with amalgam.”.

Keywords— dental cavities, carious pre-lesions, Yolov7, Faster R-CNN, dental images, Intraoral Photographs

Enfoque para la Detección de Pre-lesiones Cariotas Basado en Fotografías Intraorales Aplicando YOLOv7 y Faster R-CNN

William Huertas, Bachiller¹, Kevin Artica, Bachiller², José Luis Castillo-Sequera, Doctor³, Lenis Wong, Doctor⁴
^{1,2,4}Universidad Peruana de Ciencias Aplicadas, Perú, u201825600@upc.edu.pe, u20201a203@upc.edu.pe,
pcsilero@upc.edu.pe

³Universidad de Alcalá, España, jluis.castillo@uah.es

Abstract— *La caries dental es un desafío global debido a la falta de atención dental y el consumo excesivo de azúcares. Estas generan costosos tratamientos dentales y afectan la calidad de vida, autoestima y productividad. Debido a esto, se propone un enfoque para la detección de pre-lesiones cariosas a través del procesamiento de imágenes dentales y utilizando 2 arquitecturas de Deep learning más utilizadas en la literatura: YOLOv7 y Faster R-CNN. El enfoque se desarrolla en 4 fases: (i) adquisición de la dataset, (ii) desarrollo de arquitecturas, (iii) evaluación de rendimiento y (iv) análisis de resultados. Ambas arquitecturas se centran en el uso de un dataset público compuesto por un total de 9,327 imágenes de Fotografías Intraorales clasificadas en 3 clases: “dientes con caries” (0), “dientes sin caries” (1) y “dientes con amalgama” (2). Se construyó un sistema web con el modelo que tuvo mejor desempeño. Los resultados evidenciaron que la arquitectura YOLOv7 tuvo un mejor rendimiento que Faster R-CNN, obteniendo una exactitud promedio de 95.7% en la detección de dientes “sin caries,” “con caries” y “con amalgama”.*

Keywords— *caries dentales, pre-lesiones cariosas, Yolov7, Faster R-CNN, imágenes dentales, Fotografías Intraorales*

I. INTRODUCCIÓN

Un estudio reciente publicado por la Organización Mundial de la Salud ha puesto de manifiesto el creciente y alarmante problema de las caries dentales en la población mundial, especialmente en países de ingresos bajos y medios [1]. Esta situación es especialmente preocupante debido a las múltiples complicaciones que pueden surgir si no se abordan a tiempo, tales como pérdida de dientes, infecciones bucales y, en casos extremos, enfermedades sistémicas. Además, la salud dental deficiente tiene un impacto directo y negativo en la calidad de vida y el bienestar general [1].

En este contexto, un informe del Ministerio de Salud de Chile ha corroborado la creciente preocupación en torno a las caries dentales, enfatizando la urgencia de intervenciones efectivas [2]. La situación es aún más alarmante en Perú, donde el Ministerio de Salud (Minsa) ha advertido que 90,4% de las personas sufren de caries. Este problema se ve exacerbado por el acceso limitado a servicios de atención dental de calidad y representa un serio problema de salud pública global. [3].

Frente al creciente desafío de las caries dentales, diversos estudios han propuesto modelos innovadores. Modelos como YOLOv5-x [4] y YOLOv7[5] han emergido para identificar patologías y caries en radiografías dentales, enfocándose en patrones específicos para lograr diagnósticos precisos. Paralelamente, CariesFG [6] y U-Net [7] buscan optimizar la clasificación y segmentación de caries en distintas radiografías, con el objetivo de predecir con exactitud las áreas afectadas y la severidad de las caries. No obstante, a pesar de estos avances, persiste una brecha en la detección

temprana de pre-lesiones cariosas mediante aprendizaje profundo, ya que muchos estudios priorizan caries ya establecidas.

Por ello, este estudio propone dos modelos de Deep Learning basados en YOLOv7 y Faster R-CNN para detectar de manera temprana y precisa las pre-lesiones cariosas. El objetivo principal es proporcionar a los odontólogos una herramienta eficaz para un diagnóstico preciso e intervenciones oportunas. La propuesta se articula en cinco fases esenciales: (i) adquisición de la dataset, (ii) desarrollo de arquitecturas, (iii) evaluación de rendimiento, (iv) análisis de modelos y (v) construcción del sistema.

Este artículo sigue la siguiente estructura. En la sección 2 se presenta la revisión de la literatura. Se explica la propuesta en la sección 3 basado en 4 fases: En la sección 4 se realiza la discusión del estudio. Finalmente, en la sección 5 se esbozan las conclusiones y posibles direcciones futuras de investigación en este campo.

II. TRABAJOS RELACIONADOS

En la literatura se han propuesto diversos enfoques centrados en detectar y clasificar patologías dentales mediante técnicas de Inteligencia Artificial, como: YOLOv5-x [4], YOLOv7 [5], CariesFG [6], U-Net [7], CariesNet [8], PaXNet [9] y Faster R-CNN [10] (Tabla 2). Estas técnicas han sido desarrolladas con diversos propósitos (Tabla 1): (i) "detectar" patologías específicas en radiografías dentales, (ii) "mejorar la clasificación" de caries dentales, (iii) "segmentar" y diferenciar áreas específicas de la imagen para un diagnóstico más preciso, (iv) combinar estrategias de aprendizaje profundo y transferencia de conocimiento para "detecciones eficientes", y (v) detectar dientes temporales en radiografías panorámicas. Las investigaciones han empleado distintos conjuntos de datos, desde imágenes de radiografías periapicales [5], ortopantomografías [9], hasta imágenes panorámicas orales [8] y, más recientemente, imágenes de radiografías panorámicas para detectar dientes temporales [10]. Aunque la mayoría ha utilizado imágenes propias de sus estudios, es evidente que hay una variabilidad en la precisión y eficacia de cada técnica propuesta.

Respecto a investigaciones específicas sobre "detección de patologías" en radiografías dentales, en [4] se empleó YOLOv5-x para identificar exposiciones patológicas de la pulpa en 3.461 radiografías periapicales, alcanzando una precisión del 94,00%. Por otro lado, se utilizó YOLOv7 [5] para detectar periodontitis y caries dentales en 1525 imágenes de rayos X periapicales, logrando una precisión del 94,94%. Es notable que, a pesar de la variedad de enfoques y técnicas, hay una consistente búsqueda de precisión y mejora en las

herramientas de diagnóstico para la salud dental a través de la Inteligencia Artificial.

Con respecto al objetivo de "mejorar la clasificación" de caries dentales, varios trabajos han explorado métodos avanzados para aumentar la precisión en la identificación de diversas formas y grados de caries. CariesFG [6] se basa en, una técnica que ha demostrado ser especialmente útil para una clasificación detallada de caries en imágenes de rayos X dentales, reportando una precisión de 93,00% en su análisis de 1.000 imágenes. De manera similar, U-Net [7], conocida por su capacidad en la clasificación de caries, logrando identificarlas con un 88,00% de precisión en un conjunto de 7696 ortopantomografías.

La "segmentación" y la diferenciación de áreas específicas en imágenes son esenciales para un diagnóstico dental más detallado. CariesNet [8], aborda esta necesidad y se centra en la segmentación precisa de lesiones cariosas en diferentes etapas, utilizando 1159 imágenes panorámicas orales y alcanzando una precisión del 93,61%. Estos esfuerzos muestran el valor de segmentar meticulosamente áreas de interés para mejorar la calidad del diagnóstico.

Algunos estudios han buscado la combinación de aprendizaje profundo y transferencia de conocimiento para realizar "detecciones eficientes". PaXNet [9] se destaca por su combinación de aprendizaje de transferencia y clasificación basada en cápsulas para optimizar la detección de caries. En su análisis de 470 imágenes panorámicas, reportaron una precisión del 86,05%, demostrando cómo la incorporación de técnicas previamente establecidas puede mejorar la detección en el ámbito dental.

Finalmente, con respecto al propósito (v) de "detectar dientes temporales en radiografías panorámicas", un estudio reciente [10] utilizó el modelo Faster R-CNN Inception v2 (COCO) para lograr una precisión de 98,04% en la detección de dientes temporales. Este estudio es un ejemplo de cómo la Inteligencia Artificial se puede utilizar para mejorar la detección de dientes temporales en radiografías panorámicas. La detección temprana de dientes temporales puede ayudar a los dentistas a proporcionar un tratamiento adecuado.

TABLA I. TIPO DE FINALIDADES EN LA DETECCIÓN DE CARIES

Purposes	References
Detectar patologías en radiografías dentales	[4], [5]
Mejorar la clasificación de caries dentales	[6], [7]
Segmentar y diferenciar áreas específicas de la imagen	[8]
Detecciones eficientes con aprendizaje profundo combinado	[9]
Detectar Dientes Temporales en Radiografías Panorámicas	[10]

TABLA II. TÉCNICAS APLICADAS EN SOLUCIONES DE DETECCIÓN DE CARIES

Techniques	Classes	Dataset	Type of Images	ACC (%)	Ref
YOLOv5-x	5	3.461	Radiografías periapicales	94.00	[4]
YOLOv7	5	1525	Rayos X periapicales	94.94	[5]
CariesFG	2 y 6	1.000	Rayos dentales	93.00	[6]

U-Net		9	7696	Ortopantomografías	88.00	[7]
CariesNet		9	1159	Panorámicas orales	93.61	[8]
PaXNet		9	470	Panorámicas de rayos X	86.05	[9]
Faster R-CNN		9	421	Panorámicas de niños	98.04	[10]

III. ENFOQUE PROPUESTO

En esta sección, se presenta el modelo de Deep Learning para la detección temprana de pre-lesiones cariosas utilizando las arquitecturas YOLOv7 y Faster R-CNN. El modelo se realiza en tres fases: (i) adquisición de la dataset, (ii) desarrollo de arquitecturas, (iii) evaluación de rendimiento y (iv) análisis de resultados (Fig. 1).

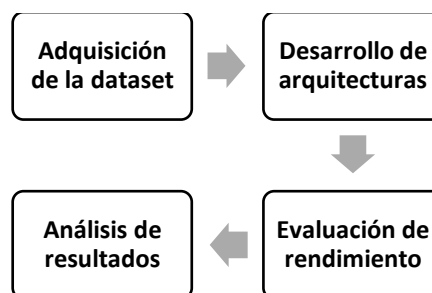


Fig. 1. Conceptualización del enfoque propuesto

A. Adquisición del dataset

A partir del conjunto de datos Tooth Cavities Detection, desarrollado por "project-vgzb" [11], se puede entrenar los modelos de detección de caries dentales. El conjunto de datos es de acceso gratuito y se puede descargar desde el sitio web de Roboflow Universe. Asimismo, se compone de 9,327 imágenes de fotografías intraorales de las cuales 3,373 tienen caries, 3,036 sin caries y 2,918 tienen amalgama. Las imágenes fueron etiquetadas por expertos en odontología, lo que garantiza la precisión del conjunto de datos. Estas imágenes representan las subcategorías de afecciones dentales: (0) dientes con caries, (1) dientes sin caries y (2) dientes con amalgama (Table III).

TABLA III. CANTIDAD DE IMÁGENES DEL DATASET POR CLASE

Id	Clase	Cantidad
0	Con Caries	3,373
1	Sin Caries	3,036
2	Con Amalgama	2,918

La Fig. 2 muestra los 3 tipos de imágenes según las afecciones dentales: con caries (Fig. 2a), sin caries (Fig. 2b) y con amalgama (Fig. 2c) [11].



(a)



(b)



(c)

Fig. 2. Tipo de imágenes del dataset: con caries (a), sin caries (b) y con amalgama (c) [11]

B. Desarrollo de arquitecturas

En la fase de desarrollo de arquitecturas, se seleccionaron con criterio dos modelos especializados, YOLOv7 y Faster R-CNN, para abordar con precisión la detección temprana de las pre-lesiones cariosas. Esta elección se fundamentó en la robustez y eficacia demostrada por ambos modelos en estudios previos relacionados con la detección de patologías dentales.

1) *YOLOv7*: Para este modelo se optó por utilizar Google Colab, aprovechando las capacidades computacionales en la nube y las bibliotecas de TensorFlow para facilitar la implementación eficiente del modelo. Este entorno proporciona recursos escalables y colaborativos que son esenciales para el entrenamiento de modelos de aprendizaje profundo. En cambio, Faster R-CNN se desarrolló en un entorno local, aprovechando la potencia de cómputo propio. Este enfoque permitió tener un mayor control sobre los recursos y la configuración del entorno, lo que puede ser beneficioso para el desarrollo de este modelo, que es más complejo y requiere más recursos que YOLOv7.

YOLOv7 es un destacado modelo de detección de objetos ha demostrado su eficacia en la identificación precisa de caries dentales en radiografías. En la implementación de YOLOv7, la secuencia de fases se inicia con el preprocesamiento de las imágenes del conjunto de datos, normalizándolas y redimensionándolas para adaptarse a las exigencias del modelo. Posteriormente, en la fase de optimización de arquitecturas, se ajustan parámetros cruciales como el tamaño de las cuadrículas y la tasa de aprendizaje para mejorar la capacidad de detección. La fase de desarrollo de arquitecturas implica la construcción meticulosa del modelo YOLOv7 utilizando TensorFlow. A continuación, en la etapa de entrenamiento, el modelo se nutre del conjunto de datos "Tooth Cavities Detection" [11] para aprender a identificar pre-lesiones cariosas. Finalmente, en la fase de evaluación de rendimiento, se analizan los resultados obtenidos, asegurando la eficacia y precisión en la detección.

En la implementación específica de YOLOv7, los parámetros clave incluyen un tamaño de cuadrículas de (416, 416) y una tasa de aprendizaje de 0.001. Este conjunto de configuraciones permite una adaptación efectiva del modelo a

las características específicas de las radiografías dentales, mejorando así la precisión de la detección.

TABLA IV. YOLOV7 PARÁMETROS

Parámetro	Valor
Tamaño de Cuadrículas	(416,416)
Tasa de Aprendizaje	0.001

Después de ajustar estos parámetros, la implementación de YOLOv7 logra una detección precisa de caries dentales. Esta implementación se visualiza en la Fig. 3.

Para el desarrollo con YOLOv7 se siguieron varios pasos esenciales. Inicialmente, se configuró el entorno de trabajo necesario, comenzando por montar el Google Drive dentro del entorno de Google Colab para asegurar el acceso a los archivos necesarios (paso 1). Seguidamente, se procedió a clonar el repositorio de YOLOv7 desde GitHub, lo que permitió obtener los archivos fuente del modelo de detección de objetos (paso 2). Posteriormente, se llevó a cabo la instalación de las dependencias críticas para el proyecto, utilizando el gestor de paquetes pip, lo que incluyó las librerías requeridas en el archivo requirements.txt y la herramienta Roboflow (paso 3). Con las dependencias en su lugar, se utilizó Roboflow para descargar el conjunto de datos específico para la detección de cavidades, preparando así el terreno para el entrenamiento del modelo (paso 4). El siguiente paso fue configurar y ejecutar el entrenamiento del modelo utilizando los pesos preentrenados de YOLOv7. Se establecieron parámetros clave como el tamaño del lote y el número de épocas en el comando de entrenamiento (paso 5). Una vez entrenado el modelo, se procedió a aplicarlo en la detección de cavidades en imágenes de prueba, donde se realizaron inferencias para identificar las áreas de interés (paso 6). Finalmente, se visualizaron las imágenes resultantes, permitiendo evaluar la precisión de las predicciones del modelo sobre las imágenes dentales.

2) *Faster R-CNN*: Un modelo avanzado de detección de objetos, se presenta como una herramienta eficaz para tareas de detección en imágenes médicas. La implementación de Faster RCNN comienza con la configuración de parámetros clave. En la etapa de preparación de datos, se procesa el conjunto de datos médicos para adaptarse al modelo. Posteriormente, en la fase de ajuste de arquitecturas, se optimizan elementos como el tamaño de los filtros y las capas específicas del modelo Faster RCNN para imágenes médicas. La fase de desarrollo se lleva a cabo en el entorno de Google Colab, aprovechando la capacidad de la GPU para un entrenamiento eficiente.

Durante el entrenamiento, el modelo se alimenta con datos médicos específicos para mejorar su capacidad de detección en entornos clínicos. La evaluación del rendimiento asegura que Faster RCNN cumpla con los estándares de precisión necesarios para aplicaciones médicas.

Los parámetros cruciales en la implementación de Faster RCNN incluyen la selección del modelo base, como 'faster_rcnn_inception_v2', y ajustes en el tamaño del lote y el número de pasos de entrenamiento. Estas configuraciones permiten que Faster RCNN se especialice en la detección precisa de objetos en imágenes médicas.



Fig. 3. Pasos del entrenamiento de YOLOv7

TABLA V. FASTER R-CNN PARÁMETROS

Parámetro	Valor
Modelo Base	'faster_rcnn_inception_v2'
Tamaño de Lote	12
Número de Pasos	10,000

Luego de ajustar estos parámetros, la implementación de Faster R-CNN logra una detección precisa de caries dentales. El desarrollo de este modelo se visualiza en la Fig. 4.

Para el desarrollo con el modelo Faster R-CNN se implementó un flujo de trabajo estructurado en varios pasos clave. El proceso comenzó con la preparación del entorno de desarrollo local. Se instalaron las librerías esenciales como TensorFlow, Pillow y lxml, configurando así el sistema para el manejo de imágenes y el procesamiento de modelos de aprendizaje profundo (paso 1). A continuación, se obtuvo el conjunto de datos necesario para el entrenamiento y evaluación del modelo. Se utilizó el comando curl para descargar y descomprimir los datos desde Roboflow, una plataforma especializada en proporcionar conjuntos de datos para visión por computadora. Luego, se convirtieron las anotaciones a un formato adecuado para TensorFlow mediante un script de generación de TFRecord (paso 2). El siguiente paso fue adaptar el modelo para las necesidades específicas del proyecto. Se editó el archivo de configuración pipeline.config del modelo, actualizando parámetros críticos como el número de clases, la ruta al modelo preentrenado, y las rutas a los archivos de entrenamiento y validación. Este

ajuste fino aseguró que el modelo pudiera aprender a partir de los datos proporcionados (paso 3). Una vez configurado, se procedió al entrenamiento del modelo. Se ejecutó el script principal de TensorFlow que orquesta el proceso de aprendizaje, registrando meticulosamente los detalles del entrenamiento para su revisión y ajuste (paso 4). Después del entrenamiento, se realizó la exportación del modelo entrenado, preparándolo para realizar inferencias. Se utilizó el script de exportación de TensorFlow, generando así una versión del modelo lista para detectar características en nuevas imágenes (paso 5). Finalmente, el modelo fue puesto en práctica, procesando imágenes dentales y generando predicciones visuales que indican la presencia de las cavidades dentales

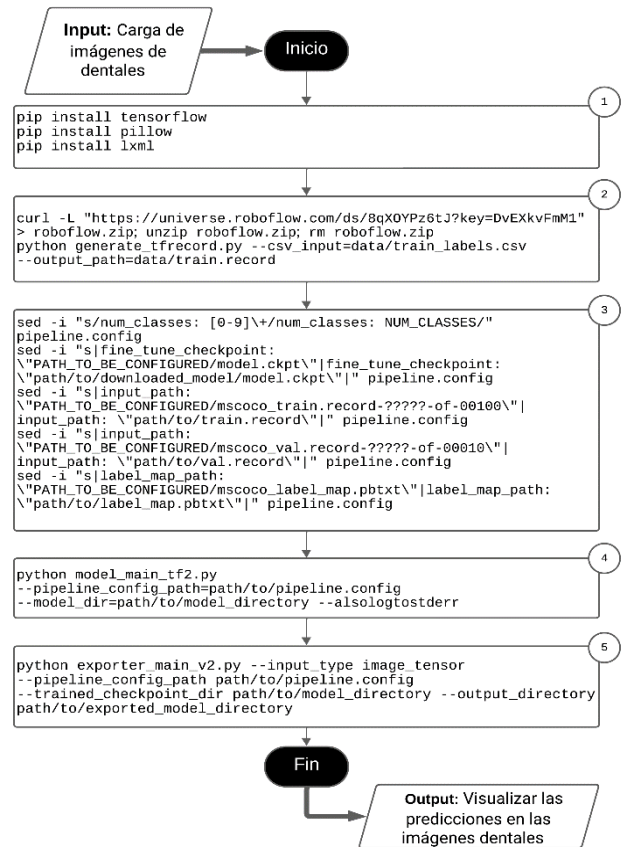


Fig. 4. Pasos del entrenamiento de Faster R-CNN

C. Evaluación de rendimiento

La evaluación de rendimiento de los modelos YOLOv7 y Faster R-CNN se llevará a cabo mediante la utilización de diversas métricas y variables que permitirán medir la efectividad y precisión de cada modelo en la detección de cariosas en imágenes dentales.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

$$F1Score = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall} \quad (3)$$

$$Precision = \frac{TP}{TP + FP} \quad (4)$$

$$mAP \alpha = \frac{1}{N} \sum_{i=1}^N AP_i \quad (5)$$

Donde:

- *TP* (True Positives): Número de casos correctamente identificados como dientes con caries.
- *TN* (True Negatives): Número de casos correctamente identificados como dientes sin caries o dientes con amalgama (si no tienen caries).
- *FP* (False Positives): Número de casos incorrectamente identificados como dientes con caries.
- *FN* (False Negatives): Número de casos incorrectamente identificados como dientes sin caries o dientes con amalgama (si tienen caries).

- Precisión*. O tasa de verdaderos negativos (tasa TN) es la proporción de verdaderos negativos que se espera que sean negativos.
- Sensibilidad*. O tasa de verdaderos positivos (tasa TP) es la proporción de verdaderos positivos predichos como positivos.
- F1 score*. Ayuda a comparar el rendimiento de los dos clasificadores, representando una medida ampliamente utilizada para el cálculo equilibrado en conjuntos de datos desequilibrados.
- Exactitud*. Expresa la eficiencia general en la detección de dientes con caries, dientes sin caries y dientes con amalgama en imágenes dentales.

Mean Average Precision. La precisión media es el promedio de la Precisión (AP) para diferentes clases o umbrales.

D. Análisis de Resultados

1) YOLOv7

Los resultados de la implementación del modelo YOLO versión 7 en la detección de distintos estados de salud dental han sido notablemente positivos.

El análisis de la curva PR (Fig. 5) para el conjunto de datos revela un desempeño consistente del modelo en todas las categorías, logrando una precisión media (mAP) de 0.957 bajo un umbral de 0.5. Específicamente, la clase asignada a los dientes con caries ha exhibido un AUC excepcionalmente alto, alcanzando un valor de 0.969.

En el análisis del ROC (Fig. 6) se muestra que el modelo YOLOv7 alcanza una precisión media de 0.91 en un nivel de confianza de 0.351 para todas las clases combinadas.




Fig. 5. Curva PR del modelo YOLOv7




Fig. 6. Curva ROC del modelo YOLOv7

La matriz de confusión nos muestra el número de predicciones correctas e incorrectas por clase, brindando una vista detallada del rendimiento del modelo al mostrar falsos positivos, falsos negativos y predicciones correctas por clase (ver Fig. 7).




Fig. 7. Matriz de confusión del modelo YOLOv7

2) Faster R-CNN

Por otro lado, los resultados de la implementación del modelo Faster R-CNN en la detección de distintos estados de salud dental han sido alentadores. La evaluación de la curva PR (Fig. 8) para el conjunto de datos indica un rendimiento

robusto del modelo a través de las categorías, alcanzando una precisión media (mAP) de 0.906 para un umbral de 0.5. Específicamente, la clase correspondiente a dientes con caries ha demostrado una precisión alta, con un AUC de 0.937. En el análisis del ROC (Fig. 9) se observa que el modelo Faster R-CNN logra un valor máximo de 0.85 a un nivel de confianza de 0.313 para todas las clases combinadas.




Fig. 8. Curva PR del modelo Faster R-CNN




Fig. 9. Curva ROC del modelo Faster R-CNN

Asimismo, se presenta la matriz de confusión para este modelo que nos muestra el número de predicciones correctas e incorrectas por clase (Fig. 10).




Fig. 10. Matriz de confusión del modelo Faster R-CNN

IV. DISCUSIÓN

La comparación de los modelos YOLOv7 y Faster R-CNN se evaluaron en términos de precisión, *recall* y *F1 score* para las clases etiquetadas. YOLOv7 muestra los valores más altos en todas las métricas y clases: una precisión del 97.6% para la clase 0, un *recall* del 97.0% también para la clase 0, y un *F1 score* del 97.3% para la misma clase. Además, YOLOv7 tiene un valor ROC superior de 91.0% frente al 85.0% de Faster R-CNN. Estos indicadores destacan a YOLOv7 como el modelo más competente en este estudio comparativo (ver Table V).

TABLA VI. TABLA COMPARATIVA DE MODELOS

Clase	YOLOv7			Faster R-CNN		
	Precis ion	Reca ll	F1Score	Precis ion	Reca ll	F1Score
0	97.6	97.0	97.3	93.7	95.1	94.4
1	95.1	94.1	94.6	88.8	90.7	89.7
2	93.7	92.9	93.3	89.3	90.3	89.8
Acc.	95.7			90.4		

Por otro lado, cabe destacar que la mayoría de los estudios recientes se centraron en la clasificación de imágenes para la detección de caries utilizando radiografías convencionales, como en el estudio [6] que se enfocó en una base de datos más pequeña, pero que solo detectó una clase y logró una precisión muy por debajo de las demás. En términos de tamaño de muestra, los estudios con la mayor cantidad de muestras de imágenes [5] y [10], basado en radiografías convencionales y diseñado para detectar múltiples clases de lesiones dentales, alcanzaron una precisión del 95.7% y 90.6% respectivamente. El modelo CariesNet [8], aunque con una muestra significativamente menor, logró una precisión del 93.61%; sin embargo, su implementación y alta dificultad no lo sitúan como una buena alternativa (Tabla VI).

TABLA VII. MODELOS DE DETECCIÓN ORDENADOS POR PRECISIÓN

AI Models	Samples	Accuracy (%)
YOLOv7*	9327	95.7
Faster R-CNN*	9327	90.6
CariesFG [6]	1.000	66.84
U-Net [7]	7696	94.29
CariesNet [8]	1159	93.61

V. CONCLUSIONES Y TRABAJOS FUTUROS

En este estudio se analizó dos modelos avanzados para la detección temprana de pre-lesiones cariosas utilizando las arquitecturas YOLOv7 y Faster R-CNN, aplicadas a imágenes dentales. El enfoque se centró en (1) la adquisición de la base de datos de caries, (2) el desarrollo de los modelos mencionados, (3) la evaluación del desempeño y (4) análisis de resultados de ambos modelos de aprendizaje profundo.

Para validar la eficacia del modelo, se analizaron conjuntos de datos de imágenes dentales, identificando distintas métricas como “accuracy”, “recall”, “F1score” y “confidence”, para poder obtener que modelo es el que posee mayor porcentaje de identificación.

Los resultados mostraron que tanto YOLOv7 como Faster R-CNN son herramientas valiosas en el diagnóstico dental,

siendo el modelo basado en YOLOv7 el que posee una mayor exactitud al momento de detectar las caries y amalgama.

Como trabajos futuros, se implementará el sistema diagnóstico en centros dentales peruanos para validar su efectividad en diversas condiciones dentales y grupos etarios. Esta iniciativa busca enriquecer el conjunto de datos con imágenes intraorales diversas e integrar tecnologías diagnósticas avanzadas en prácticas dentales en tiempo real, mejorando así la atención al paciente y estableciendo nuevos estándares en odontología de precisión. Se espera que este despliegue estratégico avance significativamente en el campo, alineándose con la excelencia global en la atención sanitaria dental.

AGRADECIMIENTOS

Queremos expresar nuestro agradecimiento al departamento de Investigación de la Universidad Peruana de Ciencias Aplicadas, por brindarnos los recursos necesarios para llevar a cabo esta investigación a través del incentivo E-009-2024.

REFERENCIAS

- [1] World Health Organization. (2022, November 18). WHO highlights oral health neglect affecting nearly half of the world's population. Retrieved November 14, 2023, from <https://www.who.int/news/item/18-11-2022-who-highlights-oral-health-neglect-affecting-nearly-half-of-the-world-s-population>
- [2] Minsal, M. de S. (2020). ANÁLISIS DE SITUACIÓN SALUD BUCAL Prevalencia y severidad de la Patología Bucal en Chile. Recuperado de <https://www.minsal.cl/portal/url/item/9c81093d17385cafe04001011e017763.pdf>
- [3] Ministerio de Salud del Perú. La caries dental: un problema de salud pública. Lima: Ministerio de Salud del Perú; 2022. <https://www.gob.pe/institucion/minsa/noticias/45475-el-90-4-de-los-peruanos-tiene-caries-dental>
- [4] Al-Dwairi, A. S., Al-Shareef, S., Al-Swailem, A. M., Al-Zoubi, A., & Abu-Hassan, O. M. (2023). Detection of the pathological exposure of pulp using an artificial intelligence tool: A multicentric study over periapical radiographs. BMC Oral Health, 23(1), 1-11.
- [5] Li, X., Yang, S., Zhang, Y., & Kwok, Y. T. (2023). Deep Learning-Based Recognition of Periodontitis and Dental Caries in Dental X-ray Images. Bioengineering, 10(9), 531.
- [6] Liu, Y., Wang, H., Hu, J., Feng, W., & Lin, G. (2023). CariesFG: A fine-grained RGB image classification framework with attention mechanism for dental caries. Engineering Applications of Artificial Intelligence, 123, 106306.
- [7] Gardiyanoglu, E., Unsal, G., Akkaya, N., Aksoy, S., & Orhan, K. (2023). Automatic Segmentation of Teeth, Crown-Bridge Restorations, Dental Implants, Restorative Fillings, Dental Caries, Residual Roots, and Root Canal Fillings on Orthopantomographs: Convenience and Pitfalls. Diagnostics, 13(8), 1487.
- [8] Haihua Zhu, Zheng Cao, Luya Lian, Guanchen Ye, Honghao Gao, Jian Wu. CariesNet: a deep learning approach for segmentation of multi-stage caries lesion from oral panoramic X-ray image. Neural Computing and Applications. DOI: 10.1007/s00521-021-06684-2
- [9] Haghanifar, A., Molahasani, M., & Ko, S. B. (2023). PaXNet: Tooth segmentation and dental caries detection in panoramic X-ray using ensemble transfer learning and capsule classifier. Multimedia Tools and Applications, 94(1), 213-237.
- [10] Çolak, E., & Çiçek, D. (2023). Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs. Dental Press Journal of Oral Science, 16(4), e041756.
- [11] Roboflow Tooth Cavities Detection. (2023). Recuperado de <https://universe.roboflow.com/project-vgzbd/tooth-cavities-detection>