



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE HIDALGO

INSTITUTO DE CIENCIAS DE LA SALUD
MAESTRÍA EN CIENCIAS BIOMÉDICAS Y DE LA SALUD

TESIS

PROTOTIPO DE SISTEMA INTELIGENTE BASADO EN IA PARA LA DETECCIÓN DE ENFERMEDADES INFLAMATORIAS DEL PERIODONTO (INFLAMPERIODONT-IA)

Para obtener el grado de
Maestro en Ciencias Biomédicas y de la Salud

PRESENTA

Ing. Sergio David Pintado Brito

Director (a)

Dra. Jeannett Alejandra Izquierdo Vega

Codirector (a)

Dra. Rocío Ortega Palacios

Comité Tutorial

M en C Alelí Julieta Izquierdo Vega

Dr. Manuel Sánchez Gutiérrez

Dr. Eduardo Osiris Madrigal Santillán

Pachuca de Soto, Hidalgo, septiembre, 2025



Universidad Autónoma del Estado de Hidalgo

Instituto de Ciencias de la Salud

School of Medical Sciences

Área Académica de Medicina

Department of Medicine

01/08/2025

Asunto: Autorización de impresión

Mtra. Ojuky del Rocío Islas Maldonado
Directora de Administración Escolar
Presente.

El Comité Tutorial de la **TESIS** del programa educativo de posgrado titulada **“Prototipo de Sistema Inteligente Basado en IA Para la Detección de Enfermedades Inflamatorias del Periodonto (Inflamperiodont-IA)”**, realizado por el sustentante **Sergio Pintado Brito**, con número de cuenta 303402 perteneciente al programa de **Maestría en Ciencias Biomédicas y de la Salud**, una vez que ha revisado, analizado y evaluado el documento recepcional de acuerdo a lo estipulado en el Artículo 110 del Reglamento de Estudios de Posgrado, tiene a bien extender la presente:

AUTORIZACIÓN DE IMPRESIÓN

Por lo que la sustentante deberá cumplir los requisitos del Reglamento de Estudios de Posgrado y con lo establecido en el proceso de grado vigente.

Atentamente

“Amor, Orden y Progreso”

Pachuca, Hidalgo a 01 de agosto del 2025

El Comité Tutorial


Dra. Jeannett Alejandra Izquierdo Vega
Directora


Dra. Rocío Ortega Palacios
Codirectora


Dr. Manuel Sánchez Gutiérrez
Miembro del comité


M en C. Alelí Julieta Izquierdo Vega
Miembro del comité


Dr. Eduardo Osiris Madrigal Santillán
Miembro del comité

Circuito ex-Hacienda la Concepción s/n Carretera
Pachuca Actopan, San Agustín Tlaxiaca, Hidalgo,
México. C.P.42168

Teléfono: 52(771)7172000 Ext. 41556 y 41557

medicina@uaeh.edu.mx

“Amor, Orden y Progreso”



2025



uaeh.edu.mx

Agradecimientos

Durante el desarrollo de estos estudios, se contó con el apoyo de una beca de manutención otorgada por la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI), con el número de CVU 1309956.

Durante este trabajo se realizó una estancia en la Universidad Politécnica de Pachuca (UPP) para el desarrollo del prototipo a cargo de la Dra. Rocío Ortega Palacios a quien le agradezco su guía y el permitirme trabajar en sus instalaciones en el área académica de Ingeniería Biomédica.

Deseo expresar mi agradecimiento a la Universidad Autónoma del Estado de Hidalgo por ofrecerme la oportunidad de cursar el posgrado en la Maestría en Ciencias Biomédicas y de la Salud y por facilitarme el uso de sus instalaciones, especialmente el laboratorio de Toxicología, adscrito al Área Académica de Medicina en donde estuve a cargo de la Dra. Jeannett Izquierdo Vega.

A la Dra. Jeannett Alejandra Izquierdo Vega, cuyo compromiso, paciencia y conocimientos fueron fundamentales a lo largo de este proceso. Su disposición para brindar orientación en momentos clave contribuyó de manera invaluable a la calidad de esta investigación.

A la Dra. Julieta Izquierdo por su valiosa orientación, apoyo y experiencia. Al enfrentar un área fuera de mi especialidad, me sentía inicialmente desorientado, pero su compromiso y dedicación resultaron esenciales para la realización exitosa de este proyecto de investigación.

Agradezco a la Dra. Rocío Ortega Palacios, actualmente docente en la Universidad Politécnica de Pachuca (UPP) en el Área Académica de Ingeniería Biomédica, por su constante apoyo y guía a lo largo de mi trayectoria académica. Desde sus clases en la universidad hasta la culminación de este proyecto de maestría, su compromiso, dedicación y palabras de aliento han sido fundamentales para motivarme a dar lo mejor de mí.

Al Dr. Fredy Santander Baños, mi más sincero agradecimiento por su invaluable orientación en el tema central de mi tesis, la inteligencia artificial. Su tiempo, dedicación y generosidad al compartir sus conocimientos han sido esenciales para el desarrollo de este trabajo.

INDICE GENERAL	
ÍNDICE DE FIGURAS	6
ÍNDICE DE TABLAS	8
ABREVIATURAS	9
RESUMEN	10
ABSTRACT	12
INTRODUCCIÓN	14
2.1 Generalidades	16
2.1.1 Anatomía de los tejidos periodontales	16
2.1.1.1 Anatomía macroscópica	16
2.1.1.1.1 Tipos de encía	17
2.1.1.1.2 Ligamento periodontal	18
2.1.1.1.3 Cemento	18
2.1.1.1.4 Hueso alveolar	19
2.1.1.2 Anatomía microscópica	20
2.1.1.2.1 Irrigación sanguínea del periodonto	21
2.1.2 Epidemiología de las enfermedades periodontales	22
2.1.2.1 Prevalencia de las enfermedades periodontales	23
2.1.3 Gingivitis: Etapa inicial de la enfermedad periodontal	24
2.1.4 Periodontitis: Enfermedad inflamatoria crónica y multifactorial	26
2.1.4.1 Etiología	27
2.1.4.2 Clasificación	28
2.1.4.3 Factores de riesgo en la periodontitis: Una perspectiva integral.	31
2.1.4.4 Diagnóstico	33
2.1.4.4.1 Sonda periodontal	33
2.1.4.4.2 Instrumentación para el diagnóstico de la periodontitis: Tipos de sondas periodontales	35
2.1.4.4.3 Diagnóstico por tomografía computarizada	37
2.1.5 Inflamación	38

2.1.5.1	Biomarcadores en enfermedad periodontal	40
2.1.5.1.2	Metaloproteinasa-8 (MMP-8)	41
2.1.6	Importancia de desarrollos tecnológicos en el diagnóstico de enfermedades odontológicas	43
2.1.6.1	Biosensores	44
2.1.6.1.1	Biosensores salivales	45
2.1.6.1.1.1	Principio de funcionamiento	47
2.1.6.1.2	Biosensores electroquímicos	49
2.1.7	Inteligencia artificial	50
2.1.7.1	Redes neuronales	51
2.1.7.2	Deep Learning	52
2.1.7.3	Aplicación de la IA en el área médica	53
2.1.8	Procesamiento de imágenes	55
2.1.8.1	Partes de una imagen	55
2.1.8.2	Adquisición de imágenes	56
2.1.9	Redes neuronales convolucionales	57
2.1.9.1	Estructura de las redes neuronales convolucionales	58
2.2	Antecedentes del problema	61
2.2.1	Aplicación de inteligencia artificial en el área odontológica	61
2.3	Planteamiento del problema	63
III	JUSTIFICACIÓN	65
IV	HIPÓTESIS	66
V	OBJETIVOS	66
5.1	Objetivo general	66
5.2	Objetivos específicos	66
VI	MATERIALES Y MÉTODOS	67
6.1	Contexto de la investigación	67
6.2	Tipo y diseño de estudio	68
6.3	Selección de la población, criterios de inclusión y exclusión	68

6.4 Tamaño de muestra y muestreo	69
6.5 Diagrama de diseño experimental	69
6.6 Definición de variables	69
6.7 Procedimiento de implementación del prototipo	71
6.8 Validación externa del prototipo. Cuantificación de MMP-8 en saliva por ELISA	86
VII RESULTADOS	88
7.1 Comportamiento similar entre el entrenamiento y la validación interna de identificación de los grupos (control, gingivitis y periodontitis) del prototipo	88
7.2 Índice de error en el prototipo	90
7.3 Desempeño del modelo EfficientNet-B2: Evolución del AUC y estabilidad en clasificación multiclase	91
7.4 Validación interna para la evaluación del desempeño del modelo mediante la matriz de confusión	93
7.5 Validación externa del prototipo mediante detección de MMP-8	97
7.6 Diseño e implementación de la interfaz de usuario	99
VIII DISCUSIÓN	103
8.1 Rendimiento del modelo EfficientNet-B2 en clasificación periodontal	103
8.2 Desempeño del modelo EfficientNet-B2 en clasificación multiclase	104
8.3 Comparación del modelo EfficientNet-B2 con estudios previos basados en imágenes clínicas y radiográficas	106
8.4 Interpretabilidad del modelo mediante visualizaciones Grad-CAM	107
8.5 Limitaciones del modelo y del estudio	109
IX CONCLUSIONES	112
X RECOMENDACIONES	113
XI REFERENCIAS	115
ANEXOS	131

ÍNDICE DE FIGURAS

Figura 1. Imagen obtenida de clínica propdental señalización de los tipos de encías	17
Figura 2. Tejido periodontal con gingivitis.	26
Figura 3. Tejido periodontal con periodontitis.	27
Figura 4. Medición de la profundidad de sondaje de la bolsa.	34
Figura 5. Periodontograma.	34
Figura 6. Sonda Carolina.	37
Figura 7. Elementos de un sensor.	48
Figura 8. Modelo simple de una red neuronal.	52
Figura 9. Estructura de un modelo de CNN.	57
Figura 10. Se muestra la acción de adjuntar y redimensionar las imágenes en Python versión 9.2. Fuente elaboración	73
Figura 11. Comandos utilizados para la transformación de imágenes en Python versión 9.2. Fuente elaboración propia.	75
Figura 12. Comandos utilizados para aplicar la transformación de imágenes en el programa de Python versión 9.2. Fuente elaboración propia.	77
Figura 13. Estructura de la red neuronal convolucional realizada en el programa de Phyton versión 9.2. Fuente elaboración propia	80
Figura 14. Diagrama de bloques de EfficientNetB2. Fuente elaboración propia.	80
Figura 15. Configuración del modelo, función de pérdida ponderada, optimizadores y schedulers para el entrenamiento en dos fases.	83
Figura 16. Comandos para la adquisición de las métricas de evaluación realizada en el programa de Phyton versión 9.2. Fuente elaboración propia.	85
Figura 17. Comandos para la predicción de realizada en el programa de Phyton versión 9.2. Fuente elaboración propia.	86
Figura 18. Exactitud del modelo EfficientNet-B2 durante las fases 1 y 2 del entrenamiento	88

Figura 19. Evolución de la función de pérdida (loss) del modelo EfficientNet-B2 durante las fases 1 y 2 del entrenamiento.	90
Figura 20. Evolución del AUC en el conjunto de validación a lo largo de las fases 1 y 2 del entrenamiento.	91
Figura 21. Curvas ROC por clase para el conjunto de validación	92
Figura 22. Matriz de confusión del modelo EfficientNet-B2 en el conjunto de prueba.	94
Figura 23. Distribución de los niveles salivales de MMP-8 (pg/mL) en pacientes con diagnóstico de gingivitis y periodontitis.	98
Figura 24. Resultados de la prueba t para muestras independientes y verificación de normalidad de los datos. Jamovi versión 2.3.28	99
Figura 25. Captura de pantalla de la interfaz principal donde se permite la carga de imágenes.	100
Figura 26. Muestra el explorador de archivos donde el usuario selecciona la imagen a analizar.	100
Figura 27. Vista previa de la imagen cargada correctamente con la opción de iniciar el análisis.	101
Figura 28. Diagnóstico generado por la IA, con indicaciones sobre la condición detectada.	101
Figura 29. Visualización Grad-CAM en imágenes correctamente clasificadas como gingivitis.	108

ÍNDICE DE TABLAS

Tabla 1. Clasificación de la periodontitis por la AAP y sus características principales.	29
Tabla 2. Estudios que aplican IA para la detección o el monitoreo de enfermedades periodontales.	62
Tabla 3. Definición conceptual y operacional de variables utilizadas en la investigación.	70
Tabla 4. Métricas de desempeño del modelo EfficientNet-B2 por clase en la clasificación de imágenes periodontales.	95
Tabla 5. Comparación entre los diagnósticos con Inflamperiodont-IA vs clínico.	97

ABREVIATURAS

IA	Inteligencia artificial
CNN	Red neuronal convolucional
CBCT	Tomografía Computarizada de Haz Cónico
RGB	Red - Green - Blue
ROC	Característica operativa del receptor
PR	Precisión - recall
AUC	Área bajo la curva
ELISA	Ensayo Inmunoabsorbente Ligado a Enzimas
MMP - 8	Metaloproteinasa de matriz 8
PD	Profundidad al sondaje
CAL	Nivel de inserción clínica
BOP	Sangrado al sondaje
SD	Desviación estándar
GPU	Graphics processing unit
ISO	Organización internacional de normalización
pg/mL	Picogramos por mililitro
CAM	Mapeo de activación de clases
Grad - CAM	Mapeo de activación de clase ponderado por gradiente

RESUMEN

El presente estudio tiene como objetivo el desarrollo y la validación de un prototipo para el análisis automático de imágenes intraorales, orientado a la detección temprana de enfermedades periodontales, en particular la gingivitis y la periodontitis. Las periodontopatías presentan una alta prevalencia a nivel global, no solo afectan la salud bucodental, sino que constituyen una de las principales causas de pérdida dental en adultos. La iniciativa surge como respuesta a las limitaciones de los métodos diagnósticos convencionales, los cuales dependen en gran medida de la pericia clínica y pueden generar resultados variables o tardíos. Este desarrollo busca ofrecer una herramienta más precisa, rápida y menos invasiva, que facilite al profesional la emisión de diagnósticos certeros y la planificación de tratamientos personalizados.

El proyecto fue desarrollado bajo un enfoque experimental y transversal, permitiendo analizar diversos parámetros visuales como coloración e inflamación, para establecer vínculos entre los signos visibles y la presencia de enfermedad. Se utilizó un conjunto de 1600 imágenes clínicas clasificadas en tres categorías: sano, gingivitis y periodontitis. Estas imágenes sirvieron para entrenar un modelo de red neuronal convolucional basado en la arquitectura EfficientNet-B2, ajustado mediante técnicas de transferencia de aprendizaje y entrenamiento especializado. Para validar su desempeño, las imágenes seleccionadas automáticamente por la red neuronal a partir del conjunto de prueba, las cuales ya contaban con diagnóstico previo emitido por especialistas. En el conjunto de prueba, la matriz de confusión mostró un alto número de aciertos en las tres clases: sano (51/65), gingivitis (191/202) y periodontitis (44/44), alcanzando una exactitud global superior al 93%. Los errores se concentraron mayoritariamente en la confusión entre los casos de sano y gingivitis, mientras que la clase de periodontitis fue clasificada sin errores. El análisis de las áreas bajo la curva (AUC) confirmó este desempeño, con valores de AUC de 1.00 para periodontitis y 0.98 para gingivitis y sano,

evidenciando una capacidad discriminativa elevada y balanceada entre clases. Este patrón refleja un rendimiento óptimo del modelo, con una diferenciación especialmente precisa de los casos de periodontitis. Adicionalmente, se llevó a cabo una validación externa mediante la cuantificación salival de la metaloproteinasa-8 (MMP-8), biomarcador asociado a la inflamación periodontal, en 14 pacientes con diagnóstico clínico. Aunque no se encontraron diferencias estadísticamente significativas entre el grupo de gingivitis y el de periodontitis, los niveles más altos de MMP-8 se registraron en los pacientes con periodontitis, respaldando así las predicciones del prototipo. A la par, se realizó una comparación directa entre el diagnóstico clínico y el generado por el sistema Inflamperiodont-IA en los mismos 14 pacientes, obteniéndose una concordancia del 78.6% (11/14). Los desaciertos observados se concentraron en casos clínicamente diagnosticados como gingivitis que fueron clasificados por la IA como "sano", lo cual sugiere una leve subestimación en casos leves de inflamación. No obstante, estos resultados refuerzan la aplicabilidad clínica del sistema al mostrar una alineación sustancial con el juicio profesional. Finalmente, se desarrolló una interfaz gráfica intuitiva que permite al profesional cargar imágenes fácilmente y recibir un diagnóstico preliminar en tiempo real. Esta propuesta representa un avance significativo en la odontología digital, al ofrecer una solución no invasiva, eficiente y accesible para mejorar la detección oportuna y la atención de las enfermedades periodontales.

ABSTRACT

This study aims to develop and validate a prototype for the automatic analysis of intraoral images, with the goal of early detection of periodontal diseases, specifically gingivitis and periodontitis. Periodontal diseases are highly prevalent worldwide, not only affecting oral health but also constituting one of the main causes of tooth loss in adults. The initiative arises in response to the limitations of conventional diagnostic methods, which rely heavily on clinical expertise and can produce variable or delayed results. This development seeks to offer a more accurate, faster, and less invasive tool that makes it easier for professionals to make accurate diagnoses and plan personalised treatments.

The project was developed using an experimental and cross-sectional approach, allowing for the analysis of various visual parameters such as colouration and inflammation to establish links between visible signs and the presence of disease. A set of 1,600 clinical images classified into three categories was used: healthy, gingivitis and periodontitis. These images were used to train a convolutional neural network model based on the EfficientNet-B2 architecture, adjusted using transfer learning and specialised training techniques.

To validate its performance, the images were automatically selected by the neural network from the test set, which already had a previous diagnosis issued by specialists. In the test set, the confusion matrix showed a high number of correct predictions in the three classes: healthy (51/65), gingivitis (191/202) and periodontitis (44/44), achieving an overall accuracy of over 93%. Errors were mainly concentrated in the confusion between healthy and gingivitis cases, while the periodontitis class was classified without errors. The analysis of the ROC curves confirmed this performance, with AUC values of 1.00 for periodontitis and 0.98 for gingivitis and healthy, showing a high and balanced discriminatory capacity between classes. This pattern reflects optimal model performance, with particularly accurate differentiation of periodontitis cases. In addition, external validation was performed by salivary quantification of metalloproteinase-8 (MMP-8), a biomarker

associated with periodontal inflammation, in 14 patients with a clinical diagnosis. Although no statistically significant differences were found between the gingivitis and periodontitis groups, higher levels of MMP-8 were recorded in patients with periodontitis, thus supporting the prototype's predictions.

At the same time, a direct comparison was made between the clinical diagnosis and that generated by the Inflammperiodont-IA system in the same 14 patients, obtaining a concordance of 78.6% (11/14). The errors observed were concentrated in cases clinically diagnosed as gingivitis that were classified by AI as 'healthy,' suggesting a slight underestimation in mild cases of inflammation. However, these results reinforce the clinical applicability of the system by showing substantial alignment with professional judgement. Finally, an intuitive graphical interface was developed that enables professionals to easily upload images and receive a preliminary diagnosis in real-time. This proposal represents a significant advancement in digital dentistry, offering a non-invasive, efficient, and accessible solution to enhance the timely detection and treatment of periodontal diseases.

INTRODUCCIÓN

Las enfermedades inflamatorias del periodonto, como la gingivitis y la periodontitis, representan una de las principales causas de pérdida dental a nivel global. Estas patologías se caracterizan por un proceso inflamatorio progresivo que compromete los tejidos de soporte dental [1]. La detección temprana es esencial, ya que, en la fase inicial, correspondiente a la gingivitis, la afección puede revertirse mediante un tratamiento adecuado. No obstante, una vez que evoluciona a periodontitis, el daño resultante en los tejidos periodontales se torna irreversible, aunque su progresión puede ser controlada mediante diversas estrategias terapéuticas [2].

A pesar de los avances en la odontología, los métodos convencionales de diagnóstico continúan dependiendo en gran medida de la experiencia y criterio clínico del profesional. Esta dependencia puede generar variabilidad en los diagnósticos y, en ciertos casos, retrasos en la identificación de la enfermedad, lo que dificulta la intervención oportuna y compromete el pronóstico del paciente [3]. En este contexto, la inteligencia artificial (IA) se ha posicionado como una alternativa innovadora para mejorar la precisión y eficiencia en el diagnóstico periodontal. Gracias a su capacidad para procesar y analizar grandes volúmenes de datos, incluyendo imágenes clínicas y radiográficas, la IA permite optimizar la detección temprana y minimizar la subjetividad en la interpretación de resultados. Este trabajo de investigación se centra en el desarrollo de un prototipo basado en inteligencia artificial, diseñado para la identificación automatizada de enfermedades inflamatorias periodontales a partir del análisis de imágenes. El objetivo principal es mejorar la precisión diagnóstica, optimizando a su vez los tiempos para establecer el diagnóstico individualizado de cada paciente y fomentar la integración de herramientas digitales en entornos clínicos. Con ello, se busca cerrar la brecha existente entre los avances tecnológicos y su aplicación en la odontología, promoviendo diagnósticos más accesibles, eficientes y estandarizados.

Este documento de tesis se encuentra organizado en tres secciones principales:

Marco teórico: Se exponen los fundamentos que sustentan la investigación, incluyendo una revisión detallada de la anatomía macroscópica y microscópica de los tejidos periodontales, su irrigación sanguínea y la epidemiología de las enfermedades periodontales. También se analiza la gingivitis y la periodontitis desde una perspectiva etiológica, incluyendo su clasificación, factores de riesgo y métodos de diagnóstico tradicionales y avanzados. Además, se presentan conceptos clave sobre la respuesta inflamatoria, el uso de biomarcadores y el impacto de tecnologías emergentes, como los biosensores y la inteligencia artificial, en el diagnóstico periodontal.

Metodología: Se describen los aspectos metodológicos del estudio, incluyendo el planteamiento del problema, la justificación de la investigación, la hipótesis y los objetivos generales y específicos. Asimismo, se detalla el diseño del estudio, los criterios de selección de la población, las variables de análisis, el tamaño de la muestra y las técnicas estadísticas utilizadas para la interpretación de los resultados.

Resultados y discusión: Se presentan los hallazgos obtenidos, con una descripción detallada de las características y desempeño del prototipo basado en inteligencia artificial desarrollado para la identificación de zonas de inflamación periodontal. Se incluyen análisis gráficos, pruebas de validación del algoritmo y el diseño de la interfaz de usuario. Adicionalmente, se realiza una comparación con estudios previos, destacando los aportes e implicaciones de esta propuesta en la práctica odontológica y su potencial impacto en el futuro del diagnóstico periodontal.

2.1 Generalidades

2.1.1 Anatomía de los tejidos periodontales

2.1.1.1 Anatomía macroscópica

El término periodonto proviene del griego, combinando *peri* (alrededor) y *odontos* (diente). Esta estructura está conformada por la encía, el ligamento periodontal, el cemento radicular y el hueso alveolar. Su función primordial es proporcionar estabilidad al diente dentro del tejido óseo, al mismo tiempo que protege la integridad de la mucosa masticatoria en la cavidad oral. A lo largo de la vida, el periodonto experimenta modificaciones asociadas al envejecimiento, ya que es una estructura dinámica en constante adaptación funcional y biológica [4].

Dentro de sus componentes, la encía representa la porción de la mucosa masticatoria que reviste la apófisis alveolar y rodea la región cervical de las piezas dentarias. Su estructura se compone de una capa epitelial y un tejido conjuntivo denominado lámina propia. Según su ubicación y características morfológicas, la encía se divide en tres secciones: libre, interdental y adherida. En este estudio, el análisis se centrará exclusivamente en la encía libre, por ser el punto clave del enfoque investigativo [5].

La encía libre se distingue por su coloración rosada coralina, su superficie opaca y su consistencia firme. Se ubica en las caras lingual o palatina de los dientes y se extiende desde el margen gingival hasta la zona apical del surco gingival libre. Su borde presenta una forma redondeada, lo que da lugar a una pequeña invaginación entre la superficie dentaria y el tejido gingival [4].

En el ámbito de la periodoncia, el uso de sondas periodontales es un instrumento avalado por la AAP (American Academy of Periodontology) y la EFP (European Federation of Periodontology), es fundamental para el diagnóstico clínico. Sin embargo, su inserción puede inducir una ligera separación entre la encía y la superficie dental, generando artificialmente un espacio conocido como surco o

bolsa gingival. En condiciones de salud periodontal, este espacio no está presente, ya que la encía se encuentra firmemente adherida al esmalte dentario. [6].

2.1.1.1.1 Tipos de encía

Los tres tipos principales de encías son la encía marginal o libre, la encía adherida o insertada y la encía interdental [6,7]. Se describen a continuación y se observan en la Figura 1:

1. **Encía marginal o libre:** Esta franja de tejido gingival, de unos 1.5 mm de ancho, rodea el cuello del diente en condiciones saludables. El término “libre” se refiere al hecho de que ya no está sujeta al hueso o a la dentición, extendiéndose hacia la pared externa del surco gingival.
2. **Encía adherida o insertada:** Esta región de la encía está firmemente adherida al tejido subyacente y varía en altura de 4 a 5 mm, ubicada sobre la cresta alveolar de los huesos maxilar y mandibular. De hecho, como resultado de esta adhesión, la única manera de separarla es mediante un procedimiento traumático que lesiona la estructura gingival.
3. **Encía interdental:** También llamada papila interdental, es una forma triangular de tejido gingival que separa los dientes adyacentes. Su función principal es salvaguardar el territorio interdental, además de asegurar las estructuras periodontales adyacentes.

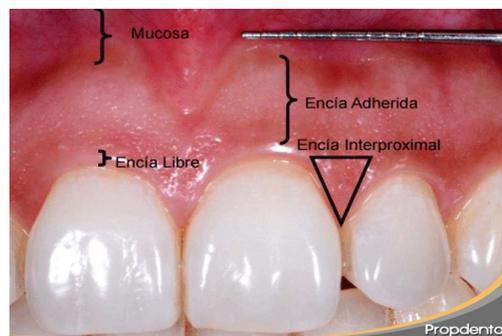


Figura 1. Imagen obtenida de clínica propdental señalización de los tipos de encías.

2.1.1.1.2 Ligamento periodontal

El ligamento periodontal es un tejido conectivo altamente especializado que funciona como un sistema de amortiguación de las fuerzas masticatorias. Consiste en fibras de colágeno extrínsecas que están organizadas en haces, llamados fibras principales o fibras de Sharpey. Estas fibras atraviesan todo el espacio periodontal, uniendo el cemento radicular y el hueso alveolar. A medida que se proyectan hacia afuera, se disecan y entrelazan para crear una estructura que contribuye a la estabilidad y función del periodonto [8].

Histológicamente, la estructura del ligamento periodontal está compuesta por fibroblastos y células mesenquimales indiferenciadas, que están altamente involucradas en la fabricación de las fibras de Sharpey. El papel de estas células en este proceso mejora la curación y regeneración del tejido ligamentoso periodontal cuando ocurre una lesión, lo cual es importante para el mantenimiento de la salud periodontal [9].

2.1.1.1.3 Cemento

El cemento dental es un tejido mineralizado que cubre las superficies radiculares de los dientes. La matriz orgánica contiene principalmente colágeno junto con sustancia fundamental, mientras que su mineralización es aproximadamente de la mitad de hidroxiapatita. Este tejido está relacionado con los cementoblastos, que son células que sintetizan la matriz orgánica. Los cementoblastos se retraen durante el proceso de formación, dejando atrás una matriz cementosa que se mineraliza [10].

Existen tres tipos principales de cemento [11]:

1. **Cemento acelular afibrilar:** Una matriz mineralizada de naturaleza no celular desprovista de fibras incrustadas. Como resultado de esta característica, no lleva a cabo la función de inserción dental.
2. **Cemento acelular extrínseco con fibras:** Ocurre en un corto período de tiempo después de que se complete el desarrollo de la corona dental y se

finaliza en cinco años. Se caracteriza por la presencia de fibras extrínsecas que ayudan a unir el diente al periodonto.

3. **Cemento celular y acelular intrínseco con fibras:** El potencial adaptativo les permite adaptarse a variaciones funcionales y cambios patológicos en el periodonto.

2.1.1.1.4 Hueso alveolar

El hueso alveolar se refiere al segmento de los maxilares y la mandíbula que contiene los alvéolos dentales, proporcionando el soporte estructural al cual se adhieren las raíces dentales. Las fibras del ligamento periodontal ayudan a asegurar el diente en el sistema óseo, que está estrechamente asociado con este tejido óseo para permitir una estabilidad y funcionalidad adecuadas del diente. Los osteoclastos y los osteoblastos participan en un proceso dinámico de remodelación ósea dentro del hueso alveolar. Los osteoclastos son las células que reabsorben el hueso (presentes en la pared alveolar, los espacios medulares y los canales de Havers), y los osteoblastos son responsables de producir nuevo tejido óseo, y ambos procesos permiten la nueva formación y adaptación del hueso alveolar a estímulos funcionales o patológicos [9].

Esta función osteolítica del metabolismo óseo de esta área regional está regulada por varios marcadores moleculares. Entre los más relevantes se encuentran los siguientes[12]:

- Fosfatasa ácida tartrato-resistente
- Receptores de calcitonina
- Receptores de vitronectina
- Catepsina K
- ATPasa vacuolar tipo V
- Anhidrasa carbónica II

Tales marcadores son cruciales para el mantenimiento de la homeostasis ósea, permitiendo que el hueso alveolar responda constantemente a las necesidades funcionales y a los cambios patológicos en el periodonto.

2.1.1.2 Anatomía microscópica

La encía libre consiste en una mezcla de estructuras epiteliales y tejido conectivo, que son vitales para el rol protector y el mantenimiento del periodonto. Histológicamente, el epitelio que cubre este tejido conectivo subyacente se divide en tres tipos básicos de epitelio: epitelio oral (hacia la cavidad oral), epitelio del surco (hacia el lado del diente no contactado) y epitelio de unión (que crea la adhesión entre la encía y el diente) [4].

La función principal del epitelio es la protección contra los estímulos externos; por lo tanto, el epitelio oral es un tipo de tejido estratificado escamoso queratinizado. Histológicamente, está compuesto de múltiples capas celulares que corresponden al grado de maduración de los queratinocitos. Estas capas son [13]:

- La capa basal (estrato basal o germinativo), la capa responsable de la proliferación celular.
- La capa espinosa (estrato espinoso), donde las células logran la morfología poligonal.
- La capa granular (estrato granuloso), donde comienza el proceso de queratinización.
- La capa queratinizada (estrato córneo), la más superficial y especializada.

Además del tipo de célula más abundante en los tejidos epiteliales, los queratinocitos (alrededor del 90% de la población celular), el epitelio oral contiene tipos de células dispares con funcionalidades específicas. Estos incluyen [11]:

- Melanocitos, responsables de la pigmentación.
- Células de Langerhans, que contribuyen a la respuesta inmune.
- Células de Merkel, asociadas con la sensibilidad mecánica.

- Células inflamatorias, que desempeñan un papel en la defensa y reparación del tejido.

Este análisis celular es muy relevante para la investigación periodontal, porque su presencia y distribución permiten la evaluación del estado inflamatorio del tejido y su relación con la salud periodontal.

El conocimiento de estas características histológicas y fisiológicas es fundamental para el conocimiento sobre la etiopatogenia de las enfermedades periodontales, además de guiar la base científica y la preparación de estrategias diagnósticas y terapéuticas. Por lo tanto, este conocimiento no solo crea la base de la investigación en el campo de la periodoncia, sino que también conduce a sus implementaciones clínicas directas.

2.1.1.2.1 Irrigación sanguínea del periodonto

Los vasos sanguíneos supraperiósticos, en la mayoría de los casos, son responsables del suministro de sangre a las encías; son las ramas terminales de las arterias de la región maxilofacial. Las arterias importantes para este proceso incluyen la arteria sublingual, la arteria mentoniana, la arteria bucal, la arteria facial, la arteria palatina mayor, la arteria infraorbitaria y la arteria alveolar posteroinferior [14].

Algunas áreas de la cavidad bucal no reciben sangre de una sola arteria, y esta disposición es evidentemente cefalizada por naturaleza para permitir una perfusión completa aquí en este sistema de órganos muy complejo, que también es altamente redundante al introducir ciertas arterias. Como resultado de las anastomosis entre terminales de diferentes arterias, el suministro de sangre a la región gingival puede permanecer constante y continuo.

Por lo tanto, el suministro de sangre para los tejidos duros y blandos de las mandíbulas superior e inferior no depende de un solo recurso vascular, sino más bien de una red interdependiente de vasos sanguíneos, produciendo un sistema anastomótico muy funcional. Tal interconexión no solo favorece el suministro de

oxígeno y nutrientes a los tejidos periodontales, sino que también contribuye a las reparaciones de los tejidos y a la respuesta adecuada a los agresores externos o procesos patológicos [15].

La anatomía de los tejidos gingivales, incluida la vascularización, es esencial para nuestra comprensión de la fisiología periodontal y la respuesta de estos tejidos al tratamiento quirúrgico o a los traumatismos. La integridad del sistema vascular es un factor clave en la cicatrización y en el mantenimiento de la salud periodontal, resultando en un enfoque clínico que tenga en cuenta las peculiaridades del suministro de sangre, siendo el más efectivo en la planificación de intervenciones dentales.

2.1.2 Epidemiología de las enfermedades periodontales

La periodontitis es una enfermedad inflamatoria crónica prevalente en todo el mundo, clasificada como la sexta condición crónica más frecuente a nivel mundial. Se estima que afecta aproximadamente al 10% de la población adulta, convirtiéndose en un problema de salud pública de magnitud significativa [16]. Los enfoques convencionales para el tratamiento no siempre son efectivos, particularmente en pacientes con una mayor predisposición a la enfermedad, a pesar de los avances en la terapia periodontal. Estas limitaciones destacan la necesidad de establecer estrategias terapéuticas innovadoras y también personalizadas que puedan abordar más eficazmente la complejidad de esta patología.

La periodontitis también representa una carga socioeconómica para los sistemas de salud, representando tanto costos directos derivados del tratamiento como costos indirectos asociados con la pérdida de productividad laboral [16]. Se ha estimado que la carga financiera de esta enfermedad en Estados Unidos asciende a aproximadamente 154.06 mil millones de dólares y en Europa a 158.65 mil millones de euros, subrayando las vastas cantidades de recursos destinados a su manejo clínico y los costos consecuentes asociados con su evolución. Estos datos

resaltan la necesidad de estrategias preventivas y terapéuticas mejoradas para aliviar la carga económica y social asociada con la enfermedad periodontal. Además del efecto local sobre los tejidos periodontales, varios estudios epidemiológicos han reportado una asociación entre la periodontitis y enfermedades sistémicas. Las enfermedades cardiovasculares, la diabetes mellitus tipo 2, la obesidad, la artritis reumatoide, la osteoporosis, las infecciones respiratorias, la enfermedad inflamatoria intestinal, la enfermedad de Alzheimer, la enfermedad del hígado graso no alcohólico, la enfermedad renal crónica y algunos cánceres están entre las patologías a las que se ha asociado [17]. Tales vínculos indican que la periodontitis no es solo un problema de salud oral, sino más bien un posible factor de riesgo involucrado en la etiopatogenia y progresión de una variedad de enfermedades sistémicas.

Estas asociaciones son fundamentales para desarrollar protocolos integrales de prevención, diagnóstico y tratamiento para la periodontitis. Una apreciación holística de sus efectos locales, así como de sus aspectos sistémicos y socioeconómicos, podría desempeñar un papel significativo en los esfuerzos hacia la mitigación de la carga global de esta enfermedad y, consecuentemente, de la salud pública en general, con la optimización de los recursos disponibles para su manejo.

2.1.2.1 Prevalencia de las enfermedades periodontales

Las enfermedades inflamatorias crónicas de los tejidos de soporte de los dientes son conocidas por causar la destrucción de las estructuras que incluyen tanto tejidos duros como blandos, responsables de la fijación de los dientes. En formas más avanzadas, estas condiciones llevan a la pérdida del tejido conectivo que une el diente al hueso y a la reabsorción del soporte óseo, lo que incrementa la movilidad del diente y, en ausencia de un tratamiento adecuado, resulta en la pérdida permanente de los dientes. Su alta prevalencia en la población en general

es una preocupación importante de salud pública que afecta significativamente la calidad de vida del paciente [18].

A escala global, el monitoreo epidemiológico en salud bucal también se ha realizado mediante indicadores definidos, que permiten la comparación entre regiones. En particular, los estudios a largo plazo demostraron una asociación entre estos cambios patológicos precoces y estados económicos de menor desarrollo. Aunque no se especifican dos variables entre las que puedan ser modificadas, se señala que las alteraciones periodontales mencionadas ocurren antes de los 35 años y que los cambios ya se han formado en la etapa presintomática, como depósitos calcificados en la superficie de los dientes e inflamación gingival, con mayor frecuencia en aquellos de menor desarrollo económico. Por otra parte, se ha observado que las poblaciones con más fácil acceso a servicios dentales pueden tener una menor prevalencia de depósitos calcificados en la cavidad oral; sin embargo, también se ha informado de un mayor número de casos donde la enfermedad progresa y empeora, llevando a la pérdida del apego periodontal y al aumento de la profundidad de las bolsas alrededor de los dientes [19].

En general, se cree que estas formas de condiciones afectan a un alto porcentaje de la población mundial, con una variación de su prevalencia dependiendo del estatus socioeconómico y del acceso a servicios de salud bucodental. Estas cifras enfatizan que las estrategias de prevención y tratamiento deben adaptarse para aliviar su carga, específicamente en entornos donde el cuidado dental tiene una accesibilidad limitada.

2.1.3 Gingivitis: Etapa inicial de la enfermedad periodontal

La periodontitis es una consecuencia de la gingivitis, que es un proceso inflamatorio reversible que tiene lugar en las encías marginales y adheridas como respuesta a la persistencia del biofilm supragingival (placa). La forma más prevalente de enfermedad periodontal es la gingivitis, que es una inflamación local

de la encía que, si no se resiste, progresa a una etapa más progresiva y destructiva de la enfermedad, conocida como periodontitis [2].

La gingivitis está directamente relacionada con la formación de biofilm dental, el cual está dominado por bacterias como *Streptococcus*, *Fusobacterium*, *Actinomyces*, *Veillonella*, *Treponema*, *Bacteroides*, *Capnocytophaga* y *Eikenella*. Estas bacterias provocan una respuesta inflamatoria local, haciendo que la gingivitis sea un factor de riesgo prominente para la progresión a periodontitis. Por lo tanto, el mantenimiento de la salud gingival es crucial para la prevención primaria de la enfermedad periodontal desarrollada [20].

Clínicamente, se manifiesta con enrojecimiento e inflamación gingival, y a veces sangrado al sondeo. A diferencia de la periodontitis, sin embargo, la gingivitis no induce sangrado espontáneo y suele ser indolora, lo que resulta en cambios clínicos discretos que la mayoría de los pacientes pueden no notar. La ausencia de síntomas fácilmente detectables lleva a que muchos no sean conscientes de la enfermedad, lo que resulta en un retraso en el diagnóstico y tratamiento, Figura 2 [21].

La gingivitis tiene entre sus características más relevantes: es reversible. La inflamación gingival debida al biofilm dental puede resolverse después de la eliminación de la biopelícula dental mediante el mantenimiento de la higiene bucal, el tratamiento profesional y la atención profesional basada en una terapéutica no quirúrgica, donde puede o no incluir soluciones con principios activos con actividad bacteriostática o bactericida que favorezcan la reparación tisular y se restaure la salud periodontal. Esta reversibilidad subraya el papel clave del diagnóstico y tratamiento temprano para prevenir la progresión a periodontitis, que lleva a un daño irreversible a los tejidos de soporte de los dientes.



Figura 2. Tejido periodontal con gingivitis. Fuente: Propia

2.1.4 Periodontitis: Enfermedad inflamatoria crónica y multifactorial

La periodontitis es una enfermedad inflamatoria crónica multifactorial, comúnmente relacionada con la acumulación de biopelícula dental (placa dental). Sin embargo, estas distintas condiciones a menudo son agrupadas por profesionales dentales y se les refiere como periodontitis, una enfermedad que implica la destrucción progresiva del aparato de soporte de los dientes (el ligamento periodontal y el hueso alveolar) y puede resultar en la pérdida de dientes si no se diagnostica y trata a tiempo. Se considera que es una enfermedad bacteriana de etiología infecciosa, ya que las bacterias patógenas pueblan el nicho ecológico subgingival, aprovechando la anatomía específica de los dientes, ya que estos, al estar parcialmente en contacto con el ambiente externo, permiten la colonización directa y el contacto íntimo con los microorganismos. Esta característica inherentemente distingue a la periodontitis como singular dentro de la categoría de enfermedades infecciosas [22].

Sin embargo, se ha documentado en varios estudios que la presencia de bacterias patógenas no es el único factor que influye en el inicio y la progresión de la periodontitis. Las condiciones locales (por ejemplo, el tabaquismo, la mala higiene oral) y sistémicas (por ejemplo, la diabetes mellitus, las alteraciones inmunológicas) también son clave en la modulación de la respuesta del huésped (tejido periodontal); no obstante, su relevancia para la periodontitis no se comprende completamente. Las razones de estas diferencias en la progresión de la enfermedad son multifactoriales y es importante abordar la periodontitis desde una perspectiva holística, considerando tanto a los agresores microbianos como a las

condiciones individuales del paciente que pueden facilitar o impedir la progresión de la enfermedad [23].

Clínicamente, la periodontitis se manifiesta a través de una serie de características comunes, entre las que destacan: inflamación gingival, pérdida de inserción clínica, evidencia radiográfica de pérdida de hueso alveolar, bolsas periodontales profundas (con profundidades de sondaje aumentadas), movilidad dentaria, sangrado al sondaje y migración patológica de los dientes (Figura 3). Estas manifestaciones clínicas reflejan tanto la gravedad de la enfermedad como también señalan marcadores diagnósticos y de monitoreo clave [24].



Figura 3. Tejido periodontal con periodontitis. Fuente Propia

2.1.4.1 Etiología

Las enfermedades gingivales son un rango diverso de condiciones específicas de las encías y no involucran la inserción periodontal ni otras estructuras de soporte de los dientes. Este grupo de alteraciones, de orígenes diversos, incluye: procesos inflamatorios (por ejemplo, gingivitis inducida por placa), procesos condicionados por factores sistémicos (cambios hormonales o malnutrición), reacciones debido a medicamentos, patologías de origen bacteriano, viral, fúngico, genético o traumático, patologías vinculadas a enfermedades sistémicas [19]. La diversidad etiológica de las enfermedades gingivales representa un desafío para los clínicos que necesitan individualizar el diagnóstico y el enfoque terapéutico.

Las enfermedades periodontales (como la periodontitis) tienen una etiología más compleja y multifactorial que las enfermedades gingivales. Para la periodontitis, el

desarrollo y progresión de la enfermedad dependen de la interacción de tres niveles primarios [25]:

- **Nivel microbiano:** La presencia de comunidades microbianas disbióticas en el nicho subgingival, con capacidad para desencadenar una respuesta inflamatoria destructiva.
- **Nivel del huésped:** Factores genéticos, edad, sexo, raza, zona geográfica, estado nutricional, estadio hormonal que predisponen o protegen contra la enfermedad, modulando la respuesta inmuno-inflamatoria del tejido periodontal.
- **Factores ambientales y sistémicos:** Elementos como el tabaquismo, el estrés, el apetito y la salud general, que determinan la dirección de la respuesta del huésped en términos de protección completa o daño.

Cabe enfatizar que la disbiosis microbiana no es suficiente para iniciar la periodontitis. Su papel patogénico está determinado por la presencia de factores de riesgo complementarios, tales como: el genotipo del huésped, el uso de tabaco, una dieta deficiente, malos hábitos de higiene oral. Estos dan lugar a moduladores que pueden acelerar o empeorar la progresión de la enfermedad [26].

En resumen, las enfermedades gingivales están confinadas a las encías y tienen un origen más localizado y polimorfo, mientras que las enfermedades periodontales como la periodontitis son el resultado de una compleja interacción de factores microbianos, genéticos y ambientales. Esta diferencia es importante tanto para entender la fisiopatología de las dos entidades como para diseñar estrategias adecuadas de prevención y tratamiento.

2.1.4.2 Clasificación

La Academia Estadounidense de Periodoncia (AAP) clasifica las enfermedades periodontales de la siguiente manera [27]:

Tabla 1. Clasificación de la periodontitis por la AAP y sus características principales.

Enfermedad o afección	Subdivisión	Características
Enfermedades gingivales	a. Placa inducida	Por placa inducida no tendrá factores contribuyentes locales, también se debe a la modificación por factores sistémicos, medicamentos o desnutrición.
	b. No inducido por placa	No inducido por placa, se origina por infecciones bacterianas, fúngicas o virales específicas, por ejemplo, las condiciones dermatológicas o reacciones alérgicas.
Periodontitis crónica	a. Localizado	Destruye los tejidos de soporte de los dientes y reabsorbe el hueso alveolar, a diferencia de la periodontitis agresiva, el avance del daño es relativamente más lento. Este tipo de enfermedad tiene como característica el tener diferentes factores, tales como genéticos, ambientales y microbiológicos [28].
	b. Generalizado	
Periodontitis agresiva	a. Localizado	Se desarrollará rápidamente en el huésped, que por lo general son individuos sanos; esta dañará principalmente el hueso alveolar.
	b. Generalizado	La localizada afecta los tejidos periodontales de los incisivos y primeros molares; se presenta particularmente en la pubertad. La generalizada será antes de los 30 años, lesionando no solamente los primeros molares, sino que eventualmente se generaliza [29].
		Se ha descubierto que la periodontitis está asociada con diversas enfermedades sistémicas, las cuales

Periodontitis como
manifestación de
enfermedad sistémica

están relacionadas con los sistemas gastrointestinal, cardiovascular, endocrino, respiratorio y nervioso central del cuerpo, e incluso con el cáncer. Además de incluir algunos trastornos hematológicos, tales como la neutropenia adquirida y la leucemia, diversos trastornos genéticos como neutropenia familiar y cíclica, síndrome de Down, síndrome de deficiencia de adhesión de leucocitos, síndrome de Papillon-Lefèvre, síndrome de Chediak-Higashi, síndromes de histiocitosis, hipofosfatasa y otros [30].

Enfermedades
periodontales
necrotizantes

Es una enfermedad infecciosa; su principal factor será la inmunosupresión. Por esta razón, la mayor parte de casos con este padecimiento son pacientes inmunodeprimidos, particularmente con VIH. Sin embargo, el desarrollo de esta enfermedad va a depender de diversas circunstancias, como por ejemplo el tabaquismo, desnutrición, entre otros. Además, el desarrollo del padecimiento será rápido y destructivo [31].

Abscesos del
periodonto

El absceso periodontal se describe como una acumulación localizada de pus dentro de la pared gingival de una bolsa periodontal; se desarrolla rápidamente y destruye los tejidos periodontales. Serán una característica clínica de la periodontitis tanto crónica como agresiva. La formación de un absceso periodontal refleja la exacerbación aguda de una bolsa periodontal preexistente. Sus factores

Periodontitis asociada
a lesiones
endodónticas

principales serán por impactación de cuerpo extraño, traumatismo, incluido el traumatismo oclusal que causa fracturas radiculares verticales y horizontales o desgarros del cemento [32].

Se va a caracterizar por el daño de la pulpa y la enfermedad periodontal en un mismo diente, la infección se desarrollará a través del agujero apical, este se encuentra entre la pulpa y el periodonto. La principal causa de esta afección serán las placas bacterianas, que están formadas por microorganismos aeróbicos y anaeróbicos [33].

2.1.4.3 Factores de riesgo en la periodontitis: Una perspectiva integral.

Para evaluar los factores de riesgo de periodontitis, es importante establecer la idea abstracta de riesgo en relación con la salud oral. En este contexto, el riesgo se define como la probabilidad de desarrollar una enfermedad (es decir, periodontitis). Estos factores de riesgo difieren entre los pacientes y son un determinante clave del curso de la enfermedad, su gravedad y la respuesta al tratamiento. Identificar y manejar estos casos es crucial para desarrollar medidas preventivas y terapéuticas adecuadas [34].

Entre los factores de riesgo más estudiados para la periodontitis se encuentran:

1. **Factores socioeconómicos:** La salud periodontal está fuertemente influenciada por el estado socioeconómico. Los factores de riesgo para una mala salud oral a menudo prevalecen durante la infancia, cuando el acceso limitado a servicios de salud y la mala nutrición pueden afectar negativamente la salud oral en la adultez. Además, el estrés psicosocial y físico, que a menudo se observa en entornos socioeconómicamente

desfavorecidos, puede promover el inicio y la progresión de enfermedades periodontales (33).

2. **Tabaquismo:** Es uno de los principales factores de riesgo para la periodontitis. Está relacionado con cambios en la respuesta inflamatoria y la susceptibilidad a los patógenos periodontales. Además, fumar perjudica la cicatrización de los tejidos y disminuye la efectividad de los tratamientos periodontales, lo que resulta en un resultado más severo de la enfermedad [35].
3. **Consumo de sustancias ilícitas:** El uso de drogas recreativas, incluyendo el cannabis y la cocaína, también se ha asociado con un mayor riesgo de enfermedades de las encías. El cannabis tiene una asociación prominente con la pérdida de inserción periodontal, presencia de bolsas profundas, elevaciones gingivales y agrandamiento gingival. En el caso de la cocaína, está vinculada a lesiones gingivales traumáticas y ulcerativas necróticas, aumentando aún más la lesión en los tejidos [35].
4. **Diabetes mellitus:** Patología, especialmente en un estado no controlado, es un factor de riesgo reconocido para la periodontitis. Las dos enfermedades están vinculadas de manera bidireccional, ya que la periodontitis empeora el control glucémico y la diabetes predispone a los individuos a infecciones y retrasa la cicatrización de los tejidos periodontales. Como tal, la diabetes y la periodontitis comparten comorbilidades, incluyendo un mayor riesgo de enfermedad cardiovascular [36].
5. **Nutrición y estilos de vida:** Una alimentación insuficiente y estilos de vida poco saludables (sedentarismo) favorecen la acumulación de placa bacteriana y la inflamación gingival. Por el contrario, la salud mental es un factor importante, ya que condiciones como la depresión y la ansiedad suprimen el sistema inmunológico y ayudan al progreso de las infecciones periodontales.

2.1.4.4 Diagnóstico

El diagnóstico clínico de la enfermedad periodontal es un proceso sistemático que comienza con la elaboración de una historia clínica completa. Este documento es fundamental para identificar los factores de riesgo asociados a la enfermedad, así como para planificar y ejecutar una terapia periodontal efectiva y personalizada. La historia clínica no solo recopila información sobre las condiciones médicas generales del paciente y los medicamentos que utiliza, sino que también permite evaluar aspectos clave para la prevención, el diagnóstico y el tratamiento de la periodontitis.

2.1.4.4.1 Sonda periodontal

La profundidad de sondaje de la bolsa (PPD, por sus siglas en inglés) es un parámetro clínico fundamental en el diagnóstico y monitoreo de la enfermedad periodontal. Este indicador se define como la distancia medida en milímetros desde el margen gingival libre (MGF) hasta el fondo de la bolsa gingival o periodontal. Junto con el nivel de inserción clínica (CAL, por sus siglas en inglés), la PPD proporciona información esencial sobre la severidad de la afectación periodontal y la extensión de la pérdida de inserción [37].

La medición de la PPD y el CAL realizadas con un sondeo periodontal estandarizado y graduado, lo que garantiza una evaluación precisa de todas las superficies dentarias (vestibular, lingual/palatina, mesial y distal). Ambos se expresan en milímetros (mm), registrados al número entero más cercano, permitiendo comparaciones y seguimiento longitudinal de los cambios en el estado periodontal.

- **Profundidad de sondaje de la bolsa (PPD):** Indica la profundidad de la bolsa periodontal que puede incrementarse por hiperplasia gingival inflamatoria, pérdida de inserción o ambas. Un PPD más alto es una de las principales características de la presencia y gravedad de la enfermedad periodontal.

- **Nivel de inserción clínica:** Distancia desde la unión cemento-esmalte (UCE) hasta el fondo de la bolsa periodontal, indicando la pérdida de inserción clínica, un signo irreversible de destrucción de tejido.

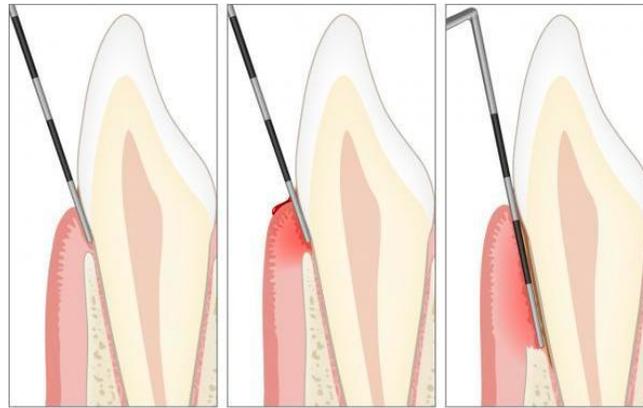


Figura 4. Medición de la profundidad de sondaje de la bolsa. Fuente: <https://www.periodontal-health.com>

La PPD debe evaluarse en todas las superficies de todos los dientes presentes y en los implantes existentes en la cavidad oral. Hoy en día, todos estos datos se registran en el mapa periodontal (Figura 5), que será nuestro principal elemento de diagnóstico.

Periodontograma Fecha

Apellido del paciente Nombre Fecha de nacimiento

Examen inicial Reevaluación Clínico

	18	17	16	15	14	13	12	11	21	22	23	24	25	26	27	28
Movilidad	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Implante																
Defecto de furca																
Sangrado al sondaje																
Placa																
Margen Gingival	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Profundidad de Sondaje	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Vestibular

Palatino

Margen Gingival	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Profundidad de Sondaje	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Placa																
Sangrado al sondaje																
Defecto de furca																
Nota																

Figura 5. Periodontograma. Fuente: <https://www.periodontalchart-online.com/es/>

Algunos otros factores reconocidos pueden tener un impacto en las lecturas de CAL y PPD, tales como: el grosor de la punta de la sonda, la angulación/posicionamiento de la punta de la sonda, la escala de graduación de la sonda, la presión ejercida sobre la sonda, el grado de inflamación de los tejidos periodontales, que será una expresión de la densidad del sellado del tejido colagenoso.

La evaluación sistemática de PPD y CAL es fundamental para realizar un diagnóstico preciso, definir el tratamiento y monitorear la respuesta terapéutica. Estos parámetros no solo permiten cuantificar la extensión y gravedad de la enfermedad, sino que también son útiles para determinar los sitios específicos donde se requieren enfoques más agresivos.

2.1.4.4.2 Instrumentación para el diagnóstico de la periodontitis: Tipos de sondas periodontales

El diagnóstico de la periodontitis requiere el uso de sondas periodontales, instrumentos esenciales para medir la profundidad del surco gingival y evaluar el estado de los tejidos periodontales. Existen diversos tipos de sondas, cada una con características específicas que las hacen adecuadas para diferentes contextos clínicos y de investigación. Entre las más utilizadas se encuentran [38]:

- *Sonda de Marquis*: Calibrada cada 3 mm, es ampliamente utilizada en la práctica clínica para evaluar la profundidad de sondaje y el nivel de inserción clínica.
- *Sonda de Williams*: Presenta marcas de calibración en 3, 5, 8 y 10 mm, lo que permite una medición detallada de bolsas periodontales más profundas.
- *Sonda Goldman Fox*: Combina las características de la sonda de Williams en un extremo, mientras que el otro extremo es plano, lo que facilita su uso en diferentes situaciones clínicas.

- *Sonda OMS (Organización Mundial de la Salud):* Calibrada cada 3 mm, está diseñada principalmente para estudios epidemiológicos, permitiendo la estandarización de mediciones en investigaciones a gran escala.
- *Sonda de Florida:* De tipo electrónica, cuenta con un software integrado que automatiza la medición y el registro de datos, lo que la convierte en una herramienta avanzada para el diagnóstico periodontal.

En condiciones de salud periodontal, la profundidad del surco gingival no supera los 3 mm. Cuando esta medida excede los 4 mm, se considera una situación patológica, caracterizada por la formación de una bolsa periodontal, resultado de la pérdida de inserción y la destrucción de los tejidos de soporte. Es importante destacar que, en casos de gingivitis (inflamación gingival sin pérdida de inserción), la profundidad del surco puede mantenerse dentro de los límites normales (≤ 3 mm), lo que subraya la importancia de diferenciar entre gingivitis y periodontitis durante el diagnóstico [27].

El procedimiento de medición, conocido como sondaje, se realiza aplicando una presión constante de 25 g en el fondo del surco o bolsa periodontal. Para ello, se utiliza una sonda calibrada de 15 mm, como la Sonda Carolina, desarrollada por la Universidad de Carolina del Norte, además de ser avalada por la AAP y EFP. Esta sonda es una de las más utilizadas en la práctica clínica debido a su diseño preciso, que incluye marcas cada 1 mm y referencias destacadas en los 3 y 5 mm, lo que facilita la identificación de bolsas periodontales y la medición del nivel de inserción clínica [38].

La sonda Carolina es particularmente valorada por su precisión y facilidad de uso, características que la convierten en una herramienta indispensable para la elaboración del periodontograma. Su diseño permite a los profesionales registrar datos con mayor exactitud en comparación con otras sondas disponibles en el mercado, lo que contribuye a un diagnóstico más confiable y un seguimiento más efectivo de la enfermedad periodontal. En la Figura 4 se ilustra la Sonda Carolina, destacando sus características principales.



Figura 6. Sonda Carolina. Fuente: Propia

2.1.4.4.3 Diagnóstico por tomografía computarizada

La radiografía periapical convencional ha sido considerada la técnica estándar de oro para el diagnóstico y evaluación de los resultados del tratamiento endodóntico durante décadas. Una limitación importante de esta metodología, sin embargo, es la proyección de estructuras tridimensionales en una imagen bidimensional. Esta limitación dificulta la correcta visualización de la relación espacial de las raíces dentales, la anatomía circundante y las posibles lesiones periapicales, y posteriormente limita el diagnóstico preciso y la planificación del tratamiento [39]. Estas limitaciones motivaron el desarrollo de la visualización tridimensional de estructuras anatómicas utilizando una tecnología reciente, que es la tomografía computarizada de haz cónico (CBCT, por sus siglas en inglés). La CBCT, a diferencia de los rayos X convencionales, elimina o reduce varias estructuras superpuestas, mejorando en gran medida la claridad y el detalle de la imagen. Además, esta técnica permite reconstrucciones tridimensionales y exploraciones multiplanares de los conductos radiculares, el tejido óseo de soporte y las regiones periapicales, sirviendo como un recurso valioso para el diagnóstico y la planificación terapéutica en endodoncia y periodoncia [40].

Todo examen radiográfico debe seguir un examen clínico completo que justifique la solicitud de estudios de imágenes. Los datos de la CBCT están compuestos por

vóxeles (píxeles volumétricos), similares a los píxeles en una imagen bidimensional, pero capaces de representar volúmenes en el espacio tridimensional. Estas imágenes no solo permiten la evaluación tridimensional de la región de interés, sino que también deben proporcionar una resolución espacial adecuada para permitir la evaluación de la anatomía dental y alveolar [41].

Además, aunque la resolución espacial de la CBCT es adecuada para la mayoría de los diagnósticos clínicos, es mucho menor que la de las radiografías intraorales convencionales. Las radiografías intraorales, a pesar de sus ventajas faltantes, tienen una resolución de 15 a 20 líneas por milímetro, pero la resolución de la CBCT es generalmente más baja, y puede restringir la detección de detalles finos en algunos escenarios clínicos [42]. El advenimiento de la CBCT ha transformado la odontología al proporcionar imágenes tridimensionales precisas y detalladas de estructuras anatómicas.

2.1.5 Inflamación

La inflamación es un proceso biológico fundamental que afecta órganos, tejidos y sistemas susceptibles, incluido el periodonto. En condiciones de salud, el proceso inflamatorio sigue un ciclo de resolución programado, mediado por vías naturales de curación que restablecen la homeostasis tisular. Sin embargo, en enfermedades donde la inflamación es el eje central de la patología, como en las enfermedades periodontales, se observa una desregulación o disfunción de estas vías de resolución. Esto conduce a un fracaso en la curación y a perpetuar la inflamación crónica, progresiva y destructiva, que no se resuelve adecuadamente y resulta en daño tisular irreversible [43].

El margen oclusal del periodonto está formado por el epitelio de unión, un epitelio escamoso no queratinizado que conecta el epitelio del surco gingival con los tejidos conectivos subyacentes. Este epitelio de unión mantiene una unión semipermeable a la superficie del diente, actuando como una barrera inicial contra los patógenos de la cavidad bucal. Los principales tejidos conectivos que conforman el

periodonto son el cemento radicular, el ligamento periodontal y el hueso alveolar, los cuales desempeñan un papel crucial en la estabilidad y función dentaria [44].

La acumulación de placa dental, compuesta por bacterias patógenas, desencadena una cascada de reacciones tisulares que dan lugar a la gingivitis. Estas reacciones incluyen vasodilatación, formación de nuevos vasos sanguíneos, aumento de la secreción de líquido crevicular y la migración de leucocitos y linfocitos al sitio de la infección. Si no se controla, esta respuesta inflamatoria puede progresar a periodontitis, caracterizada por la destrucción de los tejidos de soporte dentario [45].

La homeostasis entre la invasión bacteriana y la respuesta inflamatoria, así como entre la pérdida y regeneración del tejido, está regulada por una familia de pequeños RNA. Estas moléculas no solo controlan la función fisiológica de los tejidos periodontales sanos, sino que también modulan la pato-biología de bacterias y virus invasores, así como la respuesta del huésped a los patógenos que ingresan al surco gingival desde la cavidad bucal [46].

Las citoquinas y quimioquinas son mediadores clave de la respuesta inmune del huésped frente a la infección microbiana oral. Estas moléculas contribuyen al inicio y progresión de la inflamación gingival y periodontal. En las etapas iniciales de la inflamación, las citoquinas son producidas por células residentes, como células epiteliales y fibroblastos, así como por fagocitos, como neutrófilos y macrófagos. La interleucina-6 (IL-6) y el factor de necrosis tumoral alfa (TNF- α) son algunas de las citoquinas proinflamatorias más importantes en el mecanismo de patogénesis de la enfermedad periodontal. La sobreactividad de estas citoquinas se correlaciona con la severidad de la enfermedad periodontal y regula positivamente la respuesta inflamatoria, lo que lleva a la destrucción de los tejidos [31].

Es crucial detectar y cuantificar proteínas y moléculas en este proceso debido a la complejidad de los mecanismos inflamatorios involucrados en la enfermedad periodontal. Aunque esta detección permite la comprensión de la patogénesis de la enfermedad, también promueve el desarrollo de medios diagnósticos y

terapéuticos más precisos. Por lo tanto, el conocimiento de biomarcadores específicos, incluidas las citoquinas proinflamatorias (IL-1, IL-6 y TNF- α), es crucial para delinear planes de intervención tempranos y personalizados [47].

2.1.5.1 Biomarcadores en enfermedad periodontal

Clínicamente, los biomarcadores se definen como parámetros biológicos que pueden medirse con precisión para reflejar procesos biológicos normales, procesos patogénicos o respuestas biológicas a una exposición o intervención [48]. En el caso de la periodontitis, los biomarcadores son una parte importante de la investigación sobre la causa de la enfermedad, así como del desarrollo de diagnósticos y opciones terapéuticas más específicas.

La patogénesis de la periodontitis está vinculada a una serie de cambios enzimáticos y moleculares en los que, entre otros, están involucrados el malondialdehído (MDA), el ácido siálico (SA), la lactato deshidrogenasa (LDH), el cortisol, la β -glucuronidasa, la interleucina 1 β (IL-1 β), los antioxidantes, el estrés oxidativo, la superóxido dismutasa (SOD), la 8-hidroxideoxiguanosina, la glutatión peroxidasa (GPx) y el 4-hidroxinonenal. Estas moléculas juegan un papel en múltiples procesos biológicos como la inflamación, la respuesta inmune, el estrés oxidativo y la degradación del tejido, todos los cuales son clave en el desarrollo de la enfermedad periodontal [49].

Un ejemplo de biomarcador frecuentemente estudiado en la periodontitis es la IL-1 β , conocida como una citoquina proinflamatoria con una función crucial en la respuesta inflamatoria. La IL-1 β induce la expresión de metaloproteinasas de matriz (MMPs), enzimas que promueven la resorción ósea y la degradación de los tejidos periodontales. Además, facilita la secreción de otras citoquinas y mediadores inflamatorios, lo que amplifica la respuesta inflamatoria y sostiene el daño tisular [50].

Otro mecanismo importante de la patogénesis de la periodontitis es el estrés oxidativo. Este sufre un desequilibrio entre la formación de especies reactivas de

oxígeno (EROx) y la capacidad funcional de los antioxidantes del cuerpo. Por ejemplo, el MDA, un producto de la peroxidación lipídica, refleja el estrés oxidativo en los tejidos periodontales, al igual que uno de los productos del daño oxidativo al ADN, la 8-hidroxideoxiguanosina. En contraste, las enzimas antioxidantes como la superóxido dismutasa (SOD) y la glutatión peroxidasa (GPx) desempeñan un papel protector mediante la eliminación de EROx y minimizando el daño celular [51].

La detección y medición de estos biomarcadores proporcionan información sobre la patogénesis de la periodontitis y pueden explotarse para mejorar los métodos diagnósticos y terapéuticos. Por ejemplo, la detección de niveles elevados de IL-1 β o malondialdehído en fluidos (líquido crevicular gingival o saliva) podría funcionar como un indicador de la enfermedad o como un medio para monitorear la respuesta al tratamiento.

2.1.5.1.2 Metaloproteinasa-8 (MMP-8)

Las MMP son una familia de endopeptidasas dependientes de zinc y calcio que participan en la degradación de componentes de la matriz extracelular (MEC), como el colágeno, la elastina y la fibronectina. Se encuentran entre las proteasas de la MEC más importantes. Estas enzimas activan diversos factores de crecimiento, receptores de superficie celular y moléculas de adhesión [52]. En condiciones fisiológicas, participan en procesos como la embriogénesis, la morfogénesis, la angiogénesis, la remodelación tisular y la cicatrización de heridas [53] degradando y promoviendo el recambio de colágenos, elastina y gelatina [54], promoviendo la supervivencia celular, exhibiendo acción antitumoral y regulando los receptores hormonales. También pueden modificar citocinas, factores de crecimiento y moléculas de adhesión, lo que sugiere funciones complejas sobre mediadores químicos [52]. En los seres humanos, las MMP se conforman de 23 miembros codificados por dos genes distintos, que se pueden distinguir en dos tipos principales: MMP secretadas a la matriz extracelular como proenzimas y

metaloproteinasas unidas a la membrana, que se unen a la membrana celular [55]. Se clasifican según su especificidad y homología de sustrato. Dependiendo de su especificidad, se dividen en 6 grupos: colagenasas (MMP-1, -8, -13, -18), gelatinasas (MMP-2, -9), estromelisin (MMP-3, -10, -11), matrilisinas (MMP-7, -26) y metaloproteinasas de tipo membrana (MT-MMP) (MMP-14, -15, -16, -24, -17, -25). También se han evidenciado la MMP-12 (metaloelastasa), MMP-20 (esmealisina), MMP-28, MMP-22, MMP-23, que son cada una representativa de sí misma [56].

Las colagenasas y las gelatinasas están implicadas en la periodontitis porque el principal componente de la MEC es el colágeno tipo I, presente en el ligamento periodontal [57]. Estas incluyen las MMP-1, -8 -9 y -13, que degradan el colágeno intersticial I, II y III [57,58]. Además de los agentes físicos y químicos, los agentes caotrópicos o la presencia de LPS, las citocinas proinflamatorias como IL-1 o TNF- α se unen a factores de transcripción para la inducción de la síntesis de MMP en forma de zimógenos pre-proMMP y proMMP, que son activados por endopeptidasas y otras MMP activas o proteasas macrobióticas [55,59]. La activación oxidativa no proteolítica de las MMP es esencial en la inflamación periodontal. Las EROS activan a las MMP en los tejidos periodontales a través de la secreción de mieloperoxidasa, resultado de la granulación de neutrófilos estimulada por bacterias periodontopatógenas, generando ácido hipocloroso que degrada el tejido conectivo [57,60,61] y activa la proMMP-8 [62,63] y la proMMP-9 [63]. Las MMP degradan diferentes tipos de colágeno, como los tipos I, II, III, IV, V, VI, VII, VIII, IX, X y XIV, así como entactina, fibronectina, tenascina, laminina, proteína básica de mielina y vitronectina [54].

2.1.6 Importancia de desarrollos tecnológicos en el diagnóstico de enfermedades odontológicas

En las últimas décadas, los avances tecnológicos han transformado radicalmente el campo de la odontología, especialmente en el ámbito del diagnóstico. La introducción de herramientas modernas ha permitido una mayor precisión y rapidez en la identificación de enfermedades bucales, incluso en etapas tempranas, lo que ha revolucionado la forma en que los profesionales planifican y ejecutan los tratamientos. Tecnologías como la radiografía digital, CBCT, los escáneres intraorales y la IA han facilitado un enfoque más detallado, personalizado y menos invasivo, mejorando significativamente la atención al paciente [64].

La implementación de la IA y el aprendizaje automático en odontología requiere el manejo de grandes volúmenes de datos, que pueden incluir imágenes (fotografías clínicas, radiografías), texto (historiales clínicos, síntomas) y audio (grabaciones de voz, sonidos de auscultación o percusión). En los últimos años, la aplicación de la IA ha generado un interés considerable en diversas especialidades odontológicas, como la ortodoncia [65,66], la endodoncia [67] y la periodoncia [68,69]. Aunque los estudios realizados muestran resultados prometedores, la mayoría de estas aplicaciones aún se encuentran en etapas de desarrollo, lo que subraya la necesidad de continuar investigando y validando estas tecnologías en contextos clínicos reales.

Entre los avances más destacados en el campo odontológico se encuentra el Dental Prescale, un dispositivo desarrollado por la empresa japonesa Fuji a principios de la década de 1990. Este instrumento, basado en material piezoeléctrico, permite medir la fuerza de mordida de manera precisa y no invasiva, lo que ha sido de gran utilidad en el diagnóstico y tratamiento de trastornos oclusales [70].

Otra innovación relevante es el prototipo de protector bucal desarrollado en 2015 por la Universidad Médica y Dental de Tokio, diseñado para detectar y medir los niveles de glucosa en la saliva. Este dispositivo representa un avance significativo

en la monitorización de parámetros metabólicos relacionados con enfermedades sistémicas, como la diabetes, y su impacto en la salud bucodental [71].

A pesar de los avances tecnológicos, los dispositivos específicos para la detección de la periodontitis aún se encuentran en etapas experimentales. Actualmente, el único equipo disponible en el mercado es el Periosafe, diseñado para medir los niveles de metaloproteinasa de matriz-8 (MMP-8), un biomarcador clave en la patogénesis de la enfermedad periodontal. Sin embargo, este dispositivo presenta ciertas limitaciones: su distribución está restringida a Alemania y su costo es elevado, alcanzando aproximadamente \$280,000.00 pesos mexicanos, lo que limita su accesibilidad y uso generalizado [72].

El funcionamiento del Periosafe es relativamente sencillo: una línea en el dispositivo indica que la prueba se ha procesado correctamente y que el resultado es negativo. Por el contrario, un resultado positivo se representa mediante dos líneas, donde la intensidad de la segunda línea permite determinar el nivel de riesgo de periodontitis. Una línea tenue sugiere un riesgo bajo, mientras que una línea oscura indica un riesgo alto [73].

La integración de estas tecnologías en la práctica clínica no solo mejora la precisión diagnóstica, sino que también facilita la detección temprana de enfermedades periodontales, lo que es crucial para implementar intervenciones preventivas y terapéuticas oportunas. Sin embargo, es fundamental abordar los desafíos asociados con la accesibilidad, el costo y la validación clínica de estas herramientas para garantizar su adopción generalizada.

2.1.6.1 Biosensores

Un biosensor se define como un dispositivo analítico capaz de cuantificar reacciones biológicas o químicas, generando señales proporcionales a la concentración de un analito específico en una muestra. Estos dispositivos han ganado relevancia en diversas áreas, incluyendo el seguimiento de enfermedades, el descubrimiento de fármacos, la detección de contaminantes ambientales, la

identificación de microorganismos patógenos y la medición de biomarcadores en fluidos corporales, lo que los convierte en herramientas esenciales para el diagnóstico y la monitorización de enfermedades [74].

Un biosensor está compuesto por cinco componentes principales, cada uno de los cuales desempeña un papel crucial en su funcionamiento [75]:

1. **Analito:** Es la sustancia específica que se desea detectar o cuantificar, como glucosa, proteínas, enzimas o microorganismos.
2. **Bioreceptor:** Es una molécula biológica (por ejemplo, anticuerpos, enzimas o ácidos nucleicos) que reconoce y se une selectivamente al analito, generando una interacción específica.
3. **Transductor:** Convierte la interacción entre el analito y el bioreceptor en una señal mensurable, que puede ser óptica, eléctrica, térmica o mecánica, dependiendo del tipo de biosensor.
4. **Electrónica:** Procesa la señal generada por el transductor y la acondiciona para su posterior interpretación. Este componente es responsable de amplificar y filtrar la señal, asegurando su precisión y fiabilidad.
5. **Pantalla:** Es la interfaz que combina hardware y software para presentar los resultados de la medición. La señal de salida puede mostrarse en formato numérico, gráfico o como una imagen, dependiendo de la aplicación y el diseño del biosensor.

Los biosensores han demostrado ser herramientas versátiles y eficaces en el campo de la medicina y la odontología. Entre sus aplicaciones más destacadas se encuentran la detección de enfermedades, la monitorización de tratamientos, descubrimiento de fármacos y detección de patógenos.

2.1.6.1.1 Biosensores salivales

La saliva ha emergido como un fluido biológico de gran relevancia en el diagnóstico clínico, ya que refleja prácticamente todo el espectro de estados fisiológicos y patológicos del organismo. Este fluido contiene información valiosa sobre los

niveles tisulares de diversas sustancias, así como sobre el estado hormonal e inmunológico del paciente. Su accesibilidad, facilidad de recolección y naturaleza no invasiva la convierten en una muestra ideal para el desarrollo de técnicas diagnósticas avanzadas, como los biosensores [76].

La complejidad y especificidad de los biosensores utilizados en el análisis de saliva varían según el principio de funcionamiento y la tecnología empleada. Estos métodos pueden clasificarse en orden creciente de complejidad y precisión de la siguiente manera [77,78]:

1. **Métodos enzimáticos:** Basados en la detección de enzimas específicas presentes en la saliva, estos métodos son relativamente simples, pero ofrecen una sensibilidad limitada.
2. **Métodos antígeno-anticuerpo:** Utilizan la interacción específica entre antígenos y anticuerpos para detectar biomarcadores, lo que aumenta la precisión y selectividad del análisis.
3. **Métodos de hibridación:** Emplean secuencias de ADN o ARN para identificar patógenos o biomarcadores genéticos, ofreciendo una alta especificidad molecular.

Muchos de estos métodos están basados en el principio de ensayo por inmunoabsorción ligado a enzimas (ELISA), una técnica ampliamente utilizada para detectar y cuantificar enzimas y otros biomarcadores en fluidos biológicos. En el caso de la saliva, el ELISA permite identificar biomarcadores asociados a enfermedades periodontales, infecciones y otras patologías sistémicas [79].

Los métodos basados en coloides de oro, como la resonancia de plasmones superficiales localizados (LSPR), representan una evolución significativa en el diseño de biosensores. Estas tecnologías permiten realizar pruebas cualitativas de bajo costo, donde las reacciones de color típicas del ELISA se manifiestan como una línea visible en un biochip. Este enfoque simplifica la interpretación de los resultados y reduce la necesidad de equipos complejos, lo que facilita su implementación en entornos clínicos y de investigación [80].

En 2011, investigadores de la Universidad de California y la Universidad de Iwate reportaron el desarrollo de biosensores basados en sistemas micro y nanoelectromecánicos (MEMS/NEMS). Estos dispositivos exhiben una sensibilidad y especificidad exquisitas, permitiendo la detección de analitos como IL-6 e IL-8 a nivel molecular. Estas citoquinas, asociadas con procesos inflamatorios y enfermedades periodontales, pueden ser cuantificadas con una precisión sin precedentes, lo que abre nuevas posibilidades para el diagnóstico temprano y el monitoreo de estas afecciones [80].

La integración de biosensores avanzados en el análisis de saliva representa un avance significativo en el campo del diagnóstico clínico y periodontal. Estas tecnologías no solo mejoran la precisión y rapidez de las pruebas, sino que también permiten la detección de biomarcadores en concentraciones extremadamente bajas, lo que es crucial para el diagnóstico temprano de enfermedades.

2.1.6.1.1 Principio de funcionamiento

El funcionamiento de los biosensores salivales sigue los mismos principios básicos que cualquier otro tipo de biosensor. Estos dispositivos están diseñados para detectar y cuantificar analitos específicos en fluidos biológicos, como la saliva, mediante un proceso que combina elementos de reconocimiento bioquímico y transducción de señales. A continuación, se describe el proceso general de funcionamiento de estos biosensores [81,82]:

1. **Detección del analito:** El primer paso consiste en identificar el analito específico que se desea detectar. Dado que los biosensores son una subclase de sensores químicos, su diseño está orientado a la detección de moléculas o biomarcadores particulares en fluidos biológicos, como la saliva, la orina o la sangre.
2. **Selección del biofluido:** Una vez identificado el analito, se determina el biofluido más adecuado para su detección. En el caso de los biosensores

salivales, la saliva es el fluido de elección debido a su accesibilidad, facilidad de recolección y contenido de biomarcadores relevantes.

3. **Elección del bioreceptor:** El siguiente paso es seleccionar un bioreceptor, es decir, un elemento de reconocimiento bioquímico específico que interactúe de manera selectiva con el analito. Este componente es crucial, ya que determina la especificidad y sensibilidad del biosensor. Los bioreceptores pueden incluir enzimas, anticuerpos, ácidos nucleicos u otras moléculas biológicas capaces de unirse al analito de interés.
4. **Transducción de la señal:** Una vez que el bioreceptor ha interactuado con el analito, se produce un cambio físico o químico que debe ser traducido en una señal medible. Este proceso de transducción es llevado a cabo por un transductor fisicoquímico, que convierte la interacción bioquímica en una señal analógica.
5. **Procesamiento y visualización de datos:** La señal analógica generada por el transductor es posteriormente codificada y procesada para convertirla en datos digitales. Estos datos son finalmente mostrados en una interfaz, que puede ser una pantalla digital, un gráfico o cualquier otro formato que permita su interpretación por parte del usuario.

En la Figura 7 se ilustra de manera general este proceso, desde la detección del analito hasta la visualización de los resultados, destacando cada uno de los componentes y etapas involucradas en el funcionamiento de los biosensores salivales.

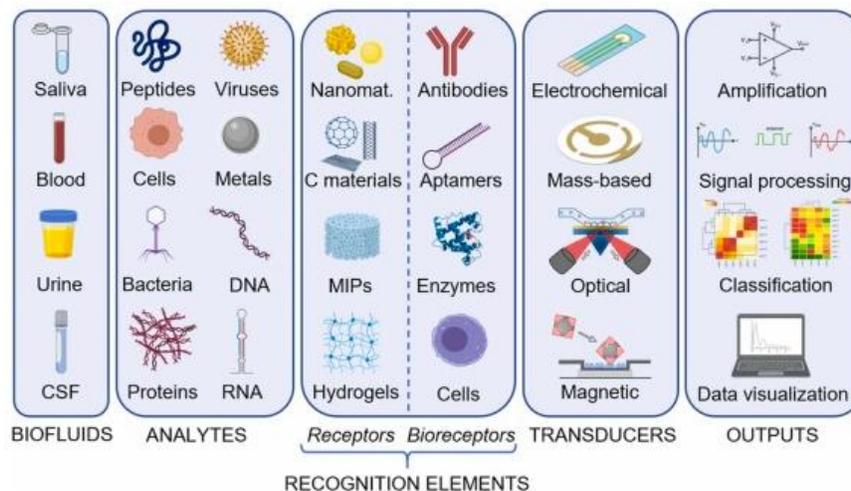


Figura 7. Elementos de un sensor. Fuente: (69)

Los biosensores salivales ofrecen varias ventajas en comparación con otros métodos diagnósticos. Su naturaleza no invasiva, la rapidez en la obtención de resultados y la capacidad para detectar biomarcadores en tiempo real los convierten en herramientas valiosas para el diagnóstico y monitoreo de enfermedades. Además, su diseño modular permite adaptarlos a la detección de una amplia gama de analitos, desde moléculas pequeñas hasta proteínas y patógenos.

2.1.6.1.2 Biosensores electroquímicos

Un sensor químico es un dispositivo que transforma información química, por ejemplo, la concentración de un componente específico en una muestra o la composición total de la misma, en una señal analítica útil [83]. Al igual que otros biosensores ya descritos, este dispositivo se compone de elementos fundamentales similares. Entre ellos destaca el elemento de transducción, implementado generalmente como una celda electroquímica cuyo componente principal es el electrodo de trabajo. En sistemas potencioestáticos, se emplea comúnmente una configuración de tres electrodos (trabajo, auxiliar y de referencia), mientras que para aplicaciones en conductimetría y espectroscopia de impedancia electroquímica se utiliza con frecuencia un formato de dos electrodos (trabajo y auxiliar).

El electrodo, definido como un conductor que facilita el transporte de carga mediante el movimiento de electrones y huecos, puede fabricarse a partir de diversos materiales como cerámicos, polímeros o metales, utilizando variados procesos de manufactura. Dichos procesos permiten la obtención de electrodos en diferentes escalas, desde estructuras macroscópicas (más de 1 mm) hasta micro y nanoestructuras, lo que posibilita su clasificación en función del tipo y forma del material, el proceso de fabricación y el diseño empleado [84].

El otro componente esencial del biosensor es el elemento de bioreconocimiento, el cual puede clasificarse en biocatalíticos o biocomplejos. En el primer caso, la

respuesta del biosensor se basa en reacciones catalizadas por macromoléculas, siendo las enzimas, las células enteras y los tejidos los elementos de bioreconocimiento biocatalítico más utilizados. En cambio, en el caso de los biocomplejos, la respuesta se fundamenta en la interacción de los analitos con macromoléculas o conjuntos moleculares organizados; en esta categoría, anticuerpos, péptidos y fagos son los elementos más empleados para la detección de patógenos. Además de las biomacromoléculas, se ha demostrado la viabilidad de implementar polímeros impresos en el desarrollo de biosensores electroquímicos [85].

2.1.7 Inteligencia artificial

La IA es una disciplina de la ciencia de la computación enfocada en el desarrollo de sistemas y algoritmos capaces de realizar tareas que, tradicionalmente, requieren inteligencia humana. Estas tareas incluyen el aprendizaje, el razonamiento, la percepción, la toma de decisiones y la resolución de problemas, entre otras. La IA busca emular y, en algunos casos, superar las capacidades cognitivas humanas mediante el uso de tecnologías avanzadas y modelos computacionales [64].

El término inteligencia artificial fue introducido formalmente en 1956 por John McCarthy, reconocido como el “Padre de la IA”, durante la Conferencia de Dartmouth. McCarthy definió la IA como la ciencia y la ingeniería de crear máquinas inteligentes, particularmente programas informáticos capaces de realizar acciones que, en condiciones normales, dependen de la intervención humana. Su visión sentó las bases para el desarrollo de sistemas autónomos que pueden aprender, adaptarse y mejorar su desempeño con el tiempo [86].

En el contexto de la odontología, la IA ha demostrado un potencial notable en áreas como el diagnóstico por imágenes, la planificación de tratamientos y la personalización de la atención al paciente. Su integración en herramientas como la CBCT y los sistemas de análisis de imágenes radiográficas ha permitido mejorar la

precisión y eficiencia de los procedimientos clínicos, reduciendo al mismo tiempo los errores humanos y los tiempos de diagnóstico.

2.1.7.1 Redes neuronales

El fundamento teórico de la IA radica en la emulación de la estructura y dinámica del cerebro humano. En el sistema nervioso central, las neuronas están interconectadas a través de una red altamente compleja que permite la propagación y procesamiento de información en todo el organismo. Estas interconexiones, denominadas sinapsis, facilitan la transmisión de señales bioeléctricas y neuroquímicas, posibilitando procesos cognitivos como el aprendizaje, la memoria y la toma de decisiones. Inspirada en estos mecanismos biológicos, la IA, a través de redes neuronales artificiales, replica el flujo de información mediante modelos matemáticos y algoritmos de optimización que buscan mejorar la capacidad de reconocimiento, predicción y adaptación a nuevos entornos [87].

La IA, particularmente mediante el uso de redes neuronales artificiales, busca emular los mecanismos del procesamiento biológico de la información. Estas redes están conformadas por unidades computacionales denominadas nodos (análogos a las neuronas biológicas), organizados en capas interconectadas que facilitan el flujo y la transformación de datos. Cada capa de la red neuronal cumple una función específica en la extracción y abstracción de características, aplicando operaciones matemáticas que permiten la identificación de patrones complejos. A través de este proceso de ajuste iterativo, el modelo optimiza su capacidad de aprendizaje, logrando ejecutar tareas con un alto grado de precisión y adaptabilidad [88].

El funcionamiento de la IA puede entenderse como un proceso de filtrado y transformación de la información, inspirado en las fases por las cuales el cerebro humano procesa los datos. Estas fases incluyen entrada de datos, procesamiento en capas y generación de resultados.

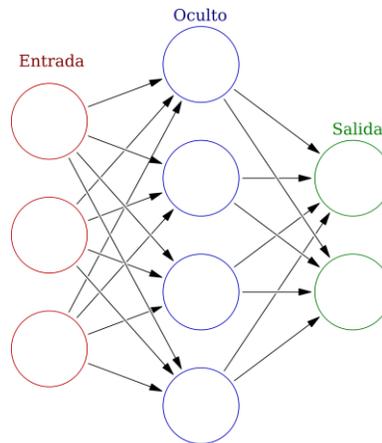


Figura 8. Modelo simple de una red neuronal. Fuente: propia

2.1.7.2 Deep Learning

El aprendizaje profundo (Deep Learning, DL) es una disciplina avanzada dentro del campo de la inteligencia artificial, caracterizada por el uso de redes neuronales artificiales con múltiples capas para el procesamiento y análisis de grandes volúmenes de datos. Estas arquitecturas, inspiradas en la organización y el funcionamiento del cerebro humano, permiten la extracción jerárquica de características mediante representaciones de datos en distintos niveles de abstracción. Esta capacidad de modelado facilita la identificación de patrones complejos y la optimización de tareas como el reconocimiento de imágenes, el procesamiento del lenguaje natural y la toma de decisiones en entornos dinámicos [89].

La arquitectura de los modelos de aprendizaje profundo se caracteriza por su alto grado de complejidad, dado que emplea redes neuronales artificiales con múltiples capas interconectadas. Cada una de estas capas ejecuta un procesamiento jerárquico y no lineal, transformando progresivamente los datos de entrada en representaciones de mayor abstracción y relevancia semántica. Esta capacidad de aprendizaje en distintos niveles de granularidad permite a los modelos de DL abordar tareas computacionalmente exigentes, como el reconocimiento de imágenes, la clasificación de datos y la predicción de patrones, logrando niveles

de precisión y eficiencia significativamente superiores a los enfoques convencionales basados en aprendizaje automático clásico [90].

El aprendizaje profundo puede implementarse de dos maneras principales: supervisado y no supervisado [91].

- **Aprendizaje supervisado:** En este enfoque, el modelo DL requiere datos etiquetados o datos de “verdad fundamental” durante la fase de entrenamiento. Estos datos etiquetados sirven como referencia para que la red neuronal aprenda a asociar las entradas con las salidas correctas. Una vez entrenado, el modelo se prueba con datos no etiquetados, donde realiza predicciones y clasifica las imágenes basándose en lo aprendido.
- **Aprendizaje no supervisado:** A diferencia del aprendizaje supervisado, este enfoque no requiere datos etiquetados. En su lugar, el modelo DL busca patrones y similitudes dentro de los datos de entrada para clasificarlos de manera automática. Este método es especialmente útil en situaciones donde los datos etiquetados son escasos o difíciles de obtener, permitiendo la identificación de estructuras ocultas y relaciones no evidentes en los datos.

2.1.7.3 Aplicación de la IA en el área médica

En los últimos años, los avances en IA han captado el interés de profesionales en diversas áreas de la salud, transformando los enfoques en diagnóstico, tratamiento y monitoreo de enfermedades. La incorporación de tecnologías como el internet de las cosas (IoT) y la telemedicina ha facilitado el desarrollo de sistemas basados en IA para el seguimiento de patologías específicas, mejorando la calidad de la atención médica y optimizando la labor de los especialistas [92].

El IoT ha revolucionado la telemedicina, permitiendo la recopilación y transmisión de datos en tiempo real desde dispositivos médicos conectados. Al integrarse con algoritmos de IA, estos sistemas pueden analizar la información para identificar patrones clínicamente relevantes, posibilitando el monitoreo de enfermedades crónicas como la diabetes (seguimiento de glucosa) y las patologías

cardiovasculares (monitorización de variables cardíacas). Esta capacidad predictiva no solo facilita el seguimiento continuo del paciente, sino que también permite anticipar la evolución de la enfermedad, brindando a los profesionales información clave para la toma de decisiones médicas fundamentadas [92,93].

Uno de los campos más beneficiados por la IA es el diagnóstico por imágenes, donde el uso de redes neuronales profundas ha permitido analizar imágenes radiológicas con una precisión comparable, e incluso en algunos casos superior, a la de los especialistas humanos. En disciplinas como la radiología, la IA facilita la detección de tumores, fracturas mediante el procesamiento avanzado de imágenes. Asimismo, en procedimientos como la endoscopia, los algoritmos de IA pueden analizar videos en tiempo real para identificar anomalías que podrían pasar desapercibidas en una evaluación convencional [94].

El impacto de la IA también ha sido significativo en el ámbito quirúrgico. Inicialmente, sistemas como PUMA560, Probot, AESOP, Robodoc y Acrobot actuaban como herramientas de asistencia bajo control humano. Sin embargo, con los avances en aprendizaje automático, han emergido sistemas quirúrgicos inteligentes que combinan robótica e IA para mejorar la precisión y eficiencia en intervenciones quirúrgicas [95].

Un ejemplo destacado es el sistema Da Vinci, aprobado por la Administración de alimentos y medicamentos (Food and Drug Administration “FDA”) en el año 2000, que ha revolucionado la cirugía mínimamente invasiva. Gracias a su capacidad para filtrar los temblores naturales de la mano del cirujano y proporcionar una visión tridimensional mejorada del campo operatorio, este sistema ha reducido significativamente los riesgos quirúrgicos y mejorado los resultados postoperatorios. La integración de IA en estos sistemas ha marcado un punto de inflexión en la cirugía moderna, optimizando la seguridad y precisión de los procedimientos [92,95].

A pesar de estos avances, una de las principales preocupaciones en la implementación de IA en medicina es la opacidad de los modelos algorítmicos, un

fenómeno conocido como “caja negra” (black box). La mayoría de los algoritmos de IA procesan los datos de entrada y generan resultados sin que se pueda interpretar fácilmente el proceso de decisión subyacente. Esta falta de transparencia genera incertidumbre en algunos profesionales de la salud, quienes cuestionan la confiabilidad de los sistemas automatizados al no poder explicar con exactitud por qué un algoritmo toma una determinada decisión.

2.1.8 Procesamiento de imágenes

Las técnicas para el análisis de una imagen digital se van a agrupar en el procesamiento digital de imágenes. Estas herramientas se van a organizar según el nivel de procesamiento que se desea realizar para el análisis. Estos procesos son los siguientes [96]:

- **Pre - procesamiento:** Operaciones para adaptar la información de una imagen y tener mejor análisis en pasos posteriores.
- **Segmentación:** Operaciones para hacer una partición de la imagen en varias regiones que representan la información necesaria para el problema a resolver.
- **Detección de objetos y clasificación:** Determinación y clasificación de los objetos contenidos en la imagen.
- **Análisis de imagen.** Obtener información de alto nivel acerca de lo que la imagen muestra.

2.1.8.1 Partes de una imagen

Es fundamental detallar cada uno de los componentes presentes en las imágenes, ya que estos serán procesados para la obtención de los resultados según el protocolo establecido.

El píxel es la unidad básica de una imagen digital. Una imagen se define como una matriz bidimensional compuesta por píxeles de distintas intensidades luminosas, lo que da lugar a representaciones en escala de grises o en color. En el caso de

imágenes en color, estas se generan mediante la combinación de los tres colores primarios: rojo, verde y azul (RGB). [97]

Dentro de cada píxel se pueden identificar varios atributos fundamentales:

- **Brillo:** Indica el nivel de iluminación de un área específica.
- **Tono:** Define la similitud de un área con los colores primarios (rojo, verde o azul) o una combinación de estos.
- **Luminosidad:** Representa la relación del brillo de una zona respecto a una referencia blanca dentro de la imagen.
- **Croma:** Determina la saturación o pureza del color en relación con un punto de referencia en blanco.

Estos parámetros son esenciales para el procesamiento de imágenes, ya que permiten aplicar diversos filtros y técnicas de mejora con el objetivo de extraer la información relevante y obtener los resultados deseados con precisión.

2.1.8.2 Adquisición de imágenes

Existen diversas técnicas para la adquisición de imágenes médicas, entre las cuales se encuentra la tomografía computarizada (TC). Este método emplea rayos X que atraviesan el cuerpo del paciente, y los valores obtenidos son capturados por detectores especializados. Posteriormente, estos datos son enviados a un ordenador, donde la señal es procesada para reconstruir la imagen y visualizarla en un monitor, permitiendo un análisis detallado de la estructura interna del organismo. En el presente protocolo, la adquisición de imágenes se realizará mediante una cámara fotográfica digital, específicamente una cámara réflex digital de lente única, debido a la alta calidad y resolución que ofrece. La densidad de píxeles en cada imagen será un factor determinante, ya que influirá directamente en la precisión del procesamiento y análisis de la imagen, permitiendo obtener resultados más detallados y confiables.

2.1.9 Redes neuronales convolucionales

Las redes neuronales convolucionales (CNN, por sus siglas en inglés) son un modelo ampliamente utilizado en el campo del aprendizaje automático (Machine Learning, ML), especialmente en tareas como el reconocimiento de imágenes, el procesamiento de voz y el análisis del lenguaje natural. Su diseño se basa en la organización de múltiples unidades de procesamiento, similares a las neuronas biológicas, dispuestas en capas interconectadas. Estas capas funcionan como una representación simplificada de ciertas áreas del cerebro, estableciendo conexiones ponderadas que imitan los procesos de integración y activación propios de las sinapsis neuronales. A medida que la información avanza a través de la red, se generan combinaciones no lineales de los datos de entrada, que se transmiten de una capa a otra hasta llegar a la fase final del procesamiento. En esta última etapa, la red lleva a cabo tareas de clasificación o regresión, dependiendo del objetivo específico del modelo [98].

Una de las principales características de las CNN es su capacidad para extraer características de manera jerárquica. En las primeras capas, identifican patrones básicos, como bordes y texturas, mientras que en las capas más profundas logran reconocer estructuras más complejas y características semánticas avanzadas. Esta progresión permite que el modelo identifique con precisión los elementos clave dentro de una imagen. Su arquitectura ha sido diseñada específicamente para el procesamiento de datos visuales, lo que se refleja en la disposición tridimensional de sus neuronas, organizadas en altura, ancho y profundidad. La Figura 9 ilustra la estructura fundamental de una CNN aplicada a la clasificación de imágenes [99].

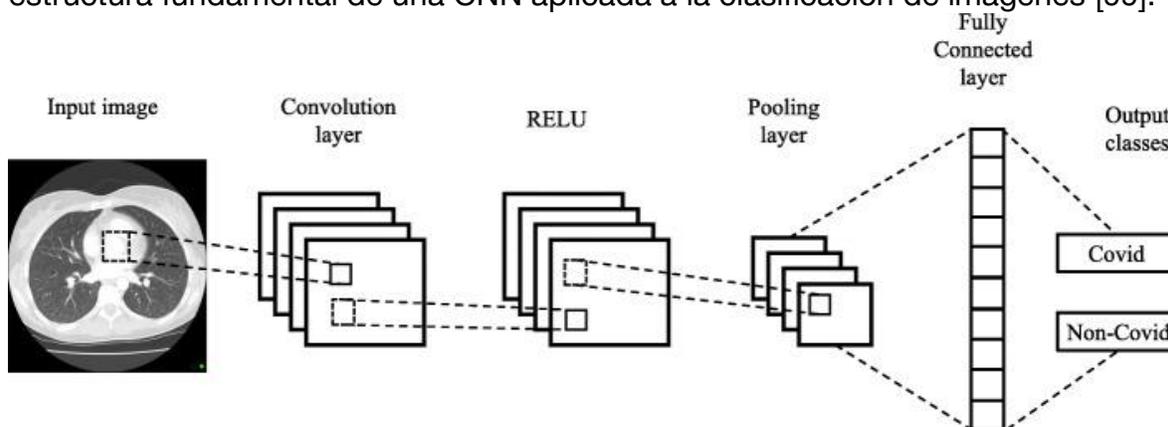


Figura 9. Estructura de un modelo de CNN. Fuente: (86)

El funcionamiento de una CNN se basa en tres tipos principales de capas: convolucionales, de agrupamiento (pooling) y completamente conectadas (fully connected). Las capas convolucionales y de agrupamiento se encargan de extraer las características más relevantes de la imagen de entrada, mientras que las capas completamente conectadas procesan esta información para generar una predicción. Para que una CNN sea efectiva en el reconocimiento de imágenes, debe ser entrenada previamente con un conjunto de datos etiquetados que contengan ejemplos de los objetos a identificar. Durante este proceso, la red aprende a asociar las características extraídas con las etiquetas correspondientes mediante técnicas de retropropagación y optimización de parámetros. Una vez entrenada, la CNN puede aplicar el conocimiento adquirido para analizar nuevas imágenes, asignándoles una categoría en función de la probabilidad estimada de cada posible clase [100].

2.1.9.1 Estructura de las redes neuronales convolucionales

El modelo de una CNN está conformado por diversas capas, cada una con un rol específico en el procesamiento y transformación de los datos. Estas capas trabajan en conjunto para extraer características relevantes, reducir la dimensionalidad y, finalmente, realizar una predicción. A continuación, se describen las principales capas que componen una CNN [101,102]:

1. **Capa convolucional:** La capa convolucional es el componente esencial de una CNN, ya que permite la extracción de características a partir de la imagen de entrada. Su función principal es aplicar una operación de convolución mediante un conjunto de filtros aprendibles, los cuales se representan como matrices de pequeñas dimensiones. Estos filtros se deslizan sobre la imagen, calculando el producto escalar entre sus valores y las regiones locales del mapa de entrada. Como resultado, se generan mapas de características que resaltan patrones específicos, tales como bordes, texturas y formas. Este proceso facilita el reconocimiento de

estructuras relevantes dentro de la imagen y constituye la base del aprendizaje en una CNN.[103]

$$(f * g)[n] = \sum_{m=-\infty}^{\infty} f[m] g[-n] \quad (1)$$

2. **Capa de agrupación (Pooling):** La capa de agrupación tiene como objetivo reducir las dimensiones espaciales de los mapas de características generados por las capas convolucionales. Para lograrlo, aplica una función de agregación —como la selección del valor máximo (*max pooling*) o el cálculo del promedio (*average pooling*)— sobre regiones locales específicas de la imagen. Esta reducción en la dimensionalidad disminuye la carga computacional del modelo y mejora su capacidad de generalización, frente a variaciones en la posición, escala u orientación de los objetos dentro de la imagen [104].

El tamaño de salida (O) de una operación de agrupación puede definirse mediante la siguiente fórmula:

$$O = \left\lfloor \frac{I-K}{S} \right\rfloor + 1 \quad (2)$$

donde:

- I es el tamaño de la entrada.
- K es el tamaño del kernel o ventana de agrupación.
- S es el valor del *stride* o paso de desplazamiento.

3. **Capa de activación:** Después de cada operación de convolución o agrupación, se aplica una función de activación $f(x)$ que introduce no linealidad en el modelo, permitiéndole aprender representaciones más complejas de los datos de entrada.

$$a = f(z) \quad (3)$$

donde z representa la entrada a la función de activación y a su salida.

Existen diversas funciones, como, ReLU (Rectified Linear Unit), sigmoide o tanh o softmax. Una de las funciones de activación más comunes en redes convolucionales es la ReLU, definida como:

$$f(z) = \max(0, z) \quad (4)$$

La función ReLU permite una propagación eficiente del gradiente durante el entrenamiento y mejora la convergencia de los modelos profundos [105].

4. **Capa de normalización por lotes (Batch Normalization):** La capa de normalización por lotes ajusta la media y la desviación estándar de las activaciones de una capa en función de las estadísticas del lote actual. Este proceso estabiliza el entrenamiento al reducir el problema del desplazamiento de variables internas (internal covariate shift), permitiendo que la red aprenda de manera más eficiente y acelera la convergencia. Además, contribuye a mejorar la generalización del modelo, reduciendo la sensibilidad a la inicialización de los pesos [101].
5. **Capa de abandono (Dropout):** La capa de abandono es una técnica de regularización que evita el sobreajuste (overfitting) al desactivar aleatoriamente un porcentaje de neuronas durante el entrenamiento. Al impedir que el modelo dependa excesivamente de ciertas neuronas específicas, esta estrategia favorece el aprendizaje de representaciones más generalizables y robustas, mejorando el rendimiento del modelo en datos no vistos [106].
6. **Capa completamente conectada (Fully Connected):** La capa completamente conectada se encuentra al final de la arquitectura de la CNN y tiene la función de combinar las características extraídas por las capas anteriores para generar la predicción final. En esta estructura, cada neurona de la capa anterior está conectada a todas las neuronas de la capa actual, permitiendo que la red realice tareas de clasificación, regresión u otras aplicaciones específicas [107].

2.2 Antecedentes del problema

2.2.1 Aplicación de inteligencia artificial en el área odontológica

En los últimos años, los avances tecnológicos han abierto nuevas fronteras en el desarrollo de la inteligencia artificial, facilitando su aplicación en áreas tan diversas como la odontología. Estas innovaciones han modificado tanto la forma en que se brinda atención clínica como la experiencia del paciente, al introducir herramientas que optimizan la eficiencia, precisión y calidad de los servicios dentales.

En su nivel más elemental, la inteligencia artificial ha permitido mejorar la gestión de pacientes, automatizando procesos como la asignación de citas y ofreciendo diagnósticos preliminares basados en el historial médico, siempre que la información disponible sea completa y precisa [108]. Aunque estas primeras aplicaciones son solo el comienzo, su impacto en la organización y atención resulta considerable.

Un ejemplo destacado se encuentra en el análisis de imágenes odontológicas. Actualmente, existen prototipos y sistemas que utilizan Redes Neuronales Convolucionales para examinar radiografías periapicales y panorámicas, identificando afecciones como caries o periodontitis [109–112]. Estas redes, al captar detalles mínimos en las imágenes, han demostrado una precisión diagnóstica que en algunos casos supera la obtenida por especialistas, quienes dependen de métodos tradicionales y de la experiencia clínica.

Asimismo, la inteligencia artificial ha encontrado aplicaciones en el análisis de imágenes generadas mediante tomografía computarizada de haz cónico. Esta tecnología posibilita la creación de modelos tridimensionales de la estructura dental y maxilofacial, lo que resulta esencial para planificar tratamientos de ortodoncia y cirugía [113–115]. La capacidad de la IA para evaluar estos modelos y sugerir tratamientos personalizados contribuye a tomar decisiones clínicas más acertadas y a mejorar los resultados para los pacientes.

Estos avances no solo representan un cambio significativo en la práctica odontológica, sino que también ofrecen a los profesionales una herramienta complementaria para confirmar y refinar sus diagnósticos. De esta manera, la inteligencia artificial se consolida como un recurso estratégico que, basado en el análisis objetivo de datos, no solo incrementa la precisión en el diagnóstico, sino que también abre nuevas oportunidades para personalizar tratamientos y elevar el nivel de atención en el ámbito dental. A continuación se detalla la evidencia científica previa que ha utilizado IA para la identificación de enfermedades periodontales.

Tabla 2. Estudios que aplican IA para la detección o el monitoreo de enfermedades periodontales.

Referencia	Objetivo del estudio	Nº de imágenes	Descripción general del estudio
[116]	Evaluar la precisión de un sistema de IA para identificar zonas específicas con y sin inflamación gingival en fotografías intraorales.	567 fotografías (frontal-view)	Utilizando DeepLabv3+, el modelo logró una sensibilidad de 92% y especificidad de 94%, con resultados comparables a los de un examen clínico.
[117]	Evaluar con una app móvil mediante fotografías semanales la reducción de gingivitis mediante monitoreo remoto.	~1345 fotografías (estimado)	Se observó una reducción significativa en el índice de gingivitis (MGI) tras 8 semanas, aunque sin métricas de sensibilidad o precisión computacional.
[118]	Detectar y localizar gingivitis, cálculo y depósitos blandos usando aprendizaje multi-tarea.	3932	El modelo multitarea logró AUC de 87.1% para gingivitis y sensibilidad de 87.8%; usó imágenes RGB tomadas con celulares y cámaras digitales.

[119]	Detectar signos tempranos de gingivitis en pacientes ortodónticos.	134	Utilizó Faster R-CNN con ResNet-50; alcanzó una sensibilidad del 41.75% y una precisión del 88.02%; mostrando viabilidad del enfoque en contexto clínico.
[120]	Aplicar redes neuronales convolucionales para detectar enfermedad periodontal.	No reportado	El estudio mostró que una CNN puede detectar enfermedad periodontal en imágenes, pero no reportó métricas específicas como sensibilidad o precisión.
[121]	Determinar un sistema automático para detectar periodontitis mediante imágenes clínicas.	No reportado	La IA alcanzó una sensibilidad de 66.7% para detección de periodontitis. Aunque no centrado en gingivitis, es relevante como antecedente en diagnóstico periodontal automatizado.

2.3 Planteamiento del problema

La enfermedad periodontal constituye un desafío sanitario global, catalogada como la sexta patología más común. Esta afección impacta significativamente a la población adulta (especialmente a los adultos mayores), donde se estima que hasta la mitad de los individuos experimenta pérdida dental debido a esta condición. Información reciente indica que cerca de 750 millones de personas en el mundo padecen una forma severa de enfermedad periodontal [122]. En México, la Secretaría de salud reportó en 2018 que la proporción de personas con periodonto sano varía notablemente según la edad: el 60% de los jóvenes de 18 años presenta una salud periodontal óptima, cifra que disminuye al 42.5% en el grupo de 35 a 44 años y se reduce a 34.3% en adultos entre 65 y 74 años [123]. Estos indicadores

evidencian la magnitud del problema y la necesidad urgente de abordarlo de manera efectiva.

A pesar de su alta incidencia, las innovaciones tecnológicas dirigidas al diagnóstico y manejo de la enfermedad periodontal han sido limitadas y presentan importantes deficiencias. Por ejemplo, en 2018 se realizó un estudio en Filipinas que empleó imágenes microscópicas dentales analizadas mediante CNN para identificar periodontitis; sin embargo, este método solo clasificaba las muestras como "saludables" o "con periodontitis", sin capturar la complejidad de la afección [120]. De igual manera, en 2017, investigadores en Corea del Sur propusieron algoritmos de inteligencia artificial para la detección y clasificación de la periodontitis, aunque los resultados no alcanzaron la precisión necesaria para su uso clínico [121]. En otros países asiáticos se han desarrollado prototipos de software que analizan imágenes bucales para identificar alteraciones periodontales, pero estos sistemas muestran una efectividad aproximada del 70% y generan una elevada proporción de resultados indeterminados, lo que limita su aplicabilidad práctica. Estas limitaciones resaltan la necesidad urgente de perfeccionar las herramientas diagnósticas para lograr una detección temprana, precisa y fiable.

Frente a este escenario, la presente investigación propone la creación de un repositorio de imágenes de pacientes con enfermedad periodontal, enfocándose en las fases de gingivitis y periodontitis. El objetivo central es desarrollar un prototipo basado en inteligencia artificial que permita la detección precoz de estas afecciones. Para asegurar la validez del modelo, se utilizarán imágenes previamente evaluadas por especialistas, lo que facilitará la medición de la confiabilidad y exactitud del sistema. Este enfoque no solo aspira a superar las limitaciones de los prototipos existentes, sino que también pretende ofrecer una herramienta diagnóstica accesible y eficaz, contribuyendo a mejorar la calidad de vida de los pacientes y a reducir las complicaciones asociadas a esta patología.

III JUSTIFICACIÓN

La inflamación de los tejidos periodontales se ha vinculado con diversas enfermedades sistémicas, como la diabetes y ciertos tipos de cáncer, lo que resalta la importancia de contar con diagnósticos tempranos y precisos para afecciones como la gingivitis y la periodontitis. En la actualidad, existe una notable ausencia de investigaciones o desarrollos tecnológicos que utilicen imágenes intraorales frontales para la detección automatizada de estas patologías. Esta carencia en la literatura y en la práctica clínica impulsa la innovación en el área, motivando el diseño de un prototipo basado en inteligencia artificial que ofrezca diagnósticos certeros mediante el análisis de imágenes periodontales.

Los métodos diagnósticos predominantes en la actualidad incluyen el sondaje periodontal y la radiología intraoral. Aunque el sondaje se ha estandarizado, su aplicación puede resultar dolorosa para el paciente y está sujeta a errores de medición. Por su parte, la radiología intraoral enfrenta limitaciones en cuanto a la calidad de las imágenes, debido a los ajustes técnicos necesarios para su procesamiento e impresión. La tomografía de haz cónico ofrece imágenes tridimensionales de alta calidad, pero su elevado coste (alrededor de \$2800.00, dependiendo de la clínica) la vuelve inaccesible para muchos.

En respuesta a estas limitaciones, el prototipo propuesto en el presente estudio, representa una solución novedosa, económica y eficaz. El prototipo permite que el profesional cargue fotografías del tejido periodontal del paciente, facilitando la obtención de un diagnóstico rápido y preciso sin necesidad de recurrir a procedimientos invasivos. Al tratarse de un sistema no invasivo, se reduce considerablemente la incomodidad para el paciente, dado que únicamente se requiere la captura de imágenes.

La interfaz del prototipo se ha diseñado para ser intuitiva y fácil de utilizar, eliminando la necesidad de una capacitación intensiva. Esto se logra mediante el empleo de una CNN, la cual procesa las imágenes para identificar y diagnosticar la afección presente.

IV HIPÓTESIS

El prototipo basado en inteligencia artificial para la identificación de gingivitis o periodontitis tendrá un 95 % de confiabilidad en el diagnóstico.

V OBJETIVOS

5.1 Objetivo general

Desarrollar y validar un prototipo basado en inteligencia artificial para la identificación de la inflamación del tejido periodontal, mediante el análisis de imágenes bucales.

5.2 Objetivos específicos

1. Diseñar un prototipo con un banco de imágenes de enfermedades periodontales en pacientes con gingivitis y periodontitis para la identificación de dichas afecciones.
2. Evaluar la confiabilidad del prototipo mediante una validación interna con imágenes clínicas previamente diagnosticadas por especialistas bajo condiciones de verificación ciega, utilizando una matriz de confusión.
3. Realizar la validación externa de la efectividad del prototipo mediante la medición de la MMP-8 por ELISA en la saliva de pacientes previamente diagnosticados.

VI MATERIALES Y MÉTODOS

6.1 Contexto de la investigación

El proyecto se desarrolló bajo un diseño experimental, orientado al desarrollo de un prototipo capaz de detectar de forma temprana enfermedades periodontales — en concreto, gingivitis y periodontitis— a partir del análisis de imágenes intraorales frontales. Para ello, se implementó una CNN entrenada con un extenso banco de imágenes de pacientes con dichas afecciones.

En la vertiente experimental se estableció un procedimiento para procesar diversos parámetros extraídos de las imágenes, tales como la coloración, la presencia de sangrado e inflamación. Este análisis permitió evaluar la influencia de cada factor en la identificación de patrones característicos de las patologías, facilitando el establecimiento de relaciones causales entre las variables y la manifestación de la enfermedad, lo cual resulta fundamental para la verificación de las hipótesis planteadas.

Adicionalmente, esta investigación se enmarca dentro del campo de la investigación básica, puesto que su objetivo principal es profundizar en los patrones subyacentes al diagnóstico automatizado de patologías periodontales. La validación del prototipo se realizó en forma interna y externa; en la primera validación, se compararon los resultados del sistema con un conjunto de imágenes previamente diagnosticadas por especialistas, lo que permitió evaluar su precisión y efectividad en un entorno clínico simulado.

En la validación externa, se realizó la cuantificación de la enzima metaloproteinasa-8 (MMP-8) en saliva de 14 pacientes, con diagnóstico previo. Esto nos permitió confirmar la correlación entre los resultados del prototipo y el estado clínico real de los tejidos periodontales evaluados.

6.2 Tipo y diseño de estudio

Se trata de un estudio cuantitativo, observacional, transversal y analítico con enfoque descriptivo-correlacional. El objetivo principal fue desarrollar y validar un prototipo basado en inteligencia artificial para la clasificación automática de imágenes clínicas intraorales del periodonto en tres categorías: periodonto sano, gingivitis y periodontitis.

El estudio incluyó dos fases principales:

- Entrenamiento y evaluación del modelo de clasificación, utilizando una base de datos de imágenes diagnosticadas por especialistas.
- Validación externa y clínica, mediante la comparación de las predicciones del prototipo con imágenes intraorales y con los niveles salivales de MMP-8 determinados mediante ELISA en un subgrupo de pacientes.

Este diseño permitió evaluar tanto el desempeño técnico del modelo como su concordancia con marcadores clínicos y biológicos, fortaleciendo su aplicabilidad en contextos reales de detección temprana de enfermedad periodontal.

6.3 Selección de la población, criterios de inclusión y exclusión

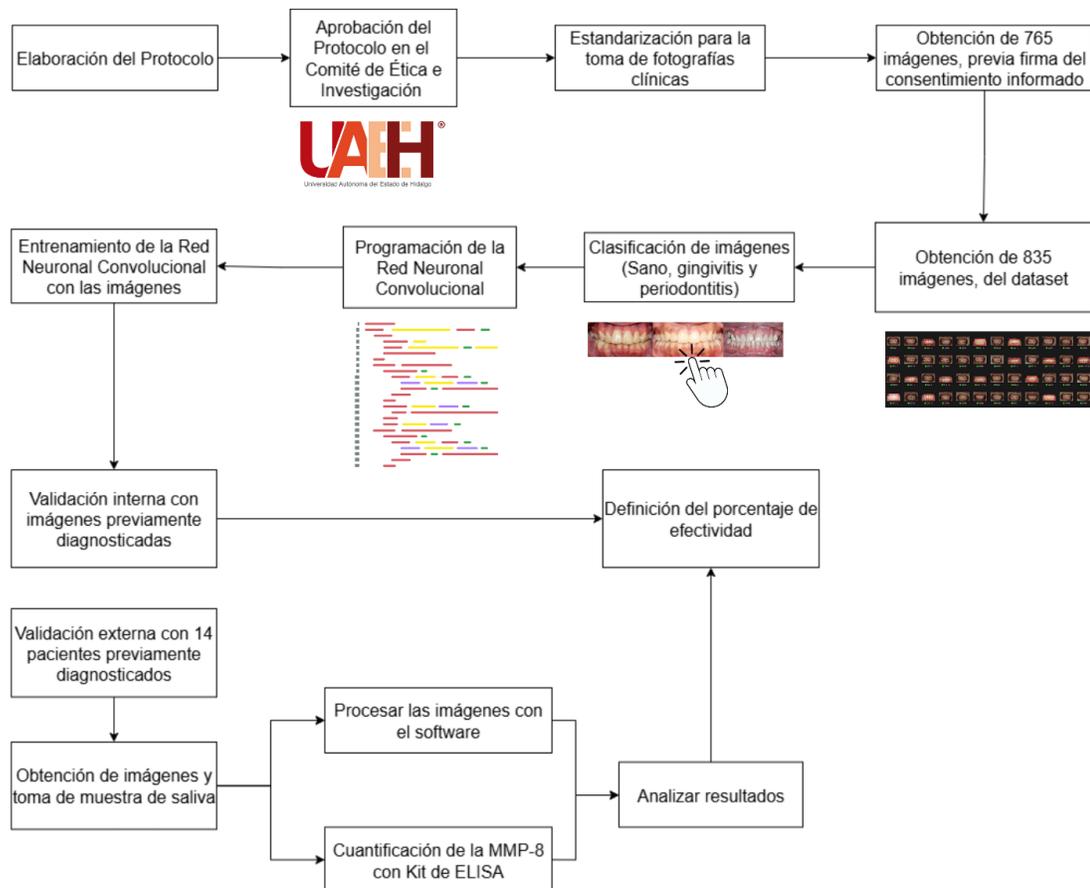
En el presente estudio se incluyó población voluntaria adulta, con un rango de edad entre 18 y 60 años. El protocolo fue previamente revisado y aprobado por el Comité de Ética del Instituto de Ciencias de la Salud (ICSa). Posterior a la firma del consentimiento informado, se llevó a cabo la recolección de datos, la cual consistió en la toma de imágenes clínicas dentales frontales mediante una cámara Canon EOS R50, así como la aplicación de un cuestionario digital a través de la plataforma Google forms.

Los criterios de inclusión fueron: pacientes con dentición completa en el sector anterior, sin presencia de malformaciones periodontales (como exostosis), y que no utilizaran aparatología de ortodoncia y prótesis dental. Los criterios de exclusión incluyeron la presencia de melanositis. Se estableció como criterio de eliminación la omisión en el llenado completo del cuestionario.

6.4 Tamaño de muestra y muestreo

Se realizó un muestreo por conveniencia, obteniendo una muestra de 765 imágenes de pacientes y 835 dataset (<https://data.mendeley.com/datasets/3253gj88rr/1>) dando un total de 1600 imágenes.

6.5 Diagrama de diseño experimental



6.6 Definición de variables

Tabla 3. Definición conceptual y operacional de variables utilizadas en la investigación.

Variable	Definición Conceptual	Definición Operacional	Unidad de Medida
Resolución	Nivel de detalle que contiene una imagen digital, determinado por la cantidad de información visual que se capta.	Tamaño de la imagen en píxeles de la imagen, expresado como ancho por alto	Píxeles o megapíxeles
Iluminación	Cantidad y calidad de luz presente en la imagen. Afecta directamente la visibilidad de los detalles, el contraste y la fidelidad de los colores.	Midiendo el nivel promedio de brillo o luminancia de la imagen.	Lux
Color	Se refiere a la representación y diferenciación de los tonos, saturaciones y matices presentes en la imagen.	Análisis de los componentes de color de la imagen. Esto puede incluir el uso de modelos de color (como RGB o HSV) para extraer valores promedio de cada canal	Valores numéricos para cada canal de color, definidos de 0 - 255, cada canal.
Precisión (Accuracy)	Medida global del desempeño del modelo que indica el porcentaje de predicciones correctas (tanto verdaderos positivos como verdaderos negativos)	Se calcula mediante la fórmula: $Accuracy = \frac{VP + VN}{VP + VN + FP + FN}$	Valor decimal entre 0 y 1

Sensibilidad (Recall)	Mide la capacidad del modelo para identificar correctamente los casos positivos, es decir, aquellos en los que efectivamente está presente la enfermedad periodontal.	Se opera mediante la fórmula: Sensibilidad $Recall = \frac{VP}{VP + FN}$	Valor decimal entre 0 y 1
Especificidad	Capacidad del modelo para identificar correctamente los casos negativos, es decir, aquellos en los que la enfermedad periodontal no está presente	Se calcula mediante la fórmula: $Especificidad = \frac{VN}{VN + FP}$	Valor decimal entre 0 y 1
F1 - Score	Media armónica entre la precisión y la sensibilidad (recall).	Se calcula mediante la fórmula: $F1 = 2 * \frac{Precision * sensibilidad}{Precision + sensibilidad}$	Valor decimal entre 0 y 1

6.7 Procedimiento de implementación del prototipo

En el presente estudio, se estableció el uso del lenguaje de programación Python, junto con la plataforma Anaconda, un entorno especializado para el desarrollo de aplicaciones en ciencias e ingeniería. Esta combinación permitió el desarrollo de un sistema inteligente basado en CNN para la detección de enfermedades inflamatorias del periodonto, como la gingivitis y la periodontitis. Para ello, se realizó una revisión exhaustiva de los métodos existentes para la identificación de afecciones periodontales, lo que permitió determinar que las CNN son una opción adecuada debido a su capacidad para procesar y analizar imágenes médicas con alta precisión. Este enfoque se seleccionó por su eficacia en tareas de clasificación de imágenes y su capacidad para extraer características relevantes de manera

automática.

Los participantes del estudio fueron pacientes adultos que accedieron voluntariamente a participar, previa firma de un consentimiento informado. Cada paciente completó un cuestionario electrónico en el que se registraron datos generales, hábitos de higiene dental y consumo de tabaco. Se obtuvieron un total de 765 imágenes, una por cada paciente. Un periodoncista certificado clasificó las imágenes en tres categorías: control (sin enfermedad), gingivitis y periodontitis. La clasificación se basó en criterios específicos, como coloración, textura, arquitectura gingival y presencia de sangrado. Esta clasificación permite organizar las imágenes en tres grupos, control, gingivitis y periodontitis.

El desarrollo del prototipo de sistema inteligente para la detección de enfermedades inflamatorias del periodonto se basó en un enfoque de aprendizaje profundo utilizando la arquitectura EfficientNet-B2. A continuación, se describe el proceso metodológico implementado, el cual incluye la adquisición y preprocesamiento de datos, la definición del modelo, el entrenamiento y la evaluación del sistema.

1. Adquisición y pre-procesamiento de datos

Se utilizaron dos fuentes de imágenes clínicas intraorales: Fotografías capturadas personalmente (765 imágenes), obtenidas mediante un protocolo estandarizado de toma de imágenes y un dataset (835 imágenes) complementario con imágenes etiquetadas previamente.

Las imágenes fueron clasificadas en tres categorías: Sano (326 imágenes), gingivitis (989 imágenes) y periodontitis (220 imágenes), reservando 65 imágenes para la validación y se guardaron en un directorio específico en el computador.

Como se observa en la Figura 10, las imágenes fueron adjuntadas desde el directorio en una carpeta específica, utilizando la función `cargar_imagenes`, que redimensiona las imágenes a un tamaño de 224x224 píxeles, compatible con la arquitectura EfficientNet-B2, se dividió el 80% de las imágenes para el

entrenamiento del modelo y el 20% de las imágenes para la validación. Durante este proceso, se contabilizó el número de imágenes de cada clasificación para garantizar un conteo inicial.

```
def cargar_imagenes(directorio, img_size):
    imagenes, etiquetas = [], []
    clases = ['SANO', 'GINGIVITIS', 'PERIODONTITIS']
    conteo = {clase: 0 for clase in clases}
    for clase in clases:
        class_dir = os.path.join(directorio, clase)
        for file in os.listdir(class_dir):
            if file.lower().endswith(('.JPG', '.jpg', '.jpeg', '.png')):
                try:
                    img = Image.open(os.path.join(class_dir, file)).convert('RGB')
                    img = img.resize((img_size, img_size))
                    imagenes.append(np.array(img))
                    etiquetas.append(clases.index(clase))
                    conteo[clase] += 1
                except Exception as e:
                    print(f"Error al cargar {file}: {e}")
    print("Conteo de imágenes:", conteo)
    return np.array(imagenes), np.array(etiquetas)
```

Figura 10. Se muestra la acción de adjuntar y redimensionar las imágenes en Python versión 9.2.

Fuente elaboración propia.

2. Transformaciones de imágenes e incremento de datos

Con el objetivo de estandarizar las imágenes utilizadas para el entrenamiento del programa y mejorar la capacidad de generalización del modelo, se aplicaron transformaciones y técnicas de aumento de datos específicas. Esto fue especialmente importante debido a las diferencias en las condiciones de brillo, contraste y calidad de imagen entre el conjunto de datos públicos (<https://data.mendeley.com/datasets/3253gj88rr/1>) y las fotografías clínicas capturadas a pacientes. Las técnicas de aumento implementadas incluyeron el redimensionamiento uniforme de todas las imágenes a un tamaño estándar, seguido de la aplicación aleatoria de volteos horizontales con una probabilidad del 50% y volteos verticales con una probabilidad del 30%. Posteriormente, se aplicaron transformaciones de desplazamiento, escalado y rotación, donde la

rotación de un punto (x,y) respecto al origen, por un ángulo θ , se describe mediante las siguientes expresiones:

$$\begin{aligned}x' &= x\cos(\theta) - y\sin(\theta) \\y' &= x\sin(\theta) + y\cos(\theta)\end{aligned}\tag{5}$$

El desplazamiento de los puntos en los ejes horizontales y verticales se modela como:

$$\begin{aligned}x' &= x + \Delta x \\y' &= y + \Delta y\end{aligned}\tag{6}$$

donde (x,y) representan las coordenadas originales de un píxel en la imagen, $(\Delta x, \Delta y)$ corresponden a los valores de desplazamiento aplicados en cada dirección, y (x', y') son las nuevas coordenadas del píxel desplazado.

El escalado de la imagen, que permite simular efectos de acercamiento (zoom-in) o alejamiento (zoom-out), se representa mediante:

$$\begin{aligned}x' &= s_x * x \\y' &= s_y * y\end{aligned}\tag{7}$$

donde (x,y) corresponden a las coordenadas originales del píxel, (x', y') representan las coordenadas resultantes después del escalado, s_x y s_y son los factores de escala aplicados en los ejes horizontal y vertical, respectivamente.

Un valor de $s > 1$ implica una ampliación de la imagen (zoom-in), mientras que un valor de $0 < s < 1$ genera una reducción (zoom-out).

Adicionalmente, se realizaron ajustes aleatorios de brillo y contraste de las imágenes, los cuales se modelan como una transformación lineal:

$$I' = \alpha I + \beta\tag{8}$$

donde I es el valor original del píxel, α regula el contraste y β ajusta el brillo. Para aumentar la variabilidad del conjunto de datos y robustecer el modelo ante condiciones reales, se aplicó aleatoriamente en un 30% de los casos ruido o desenfoque utilizando técnicas como desenfoque gaussiano, ruido gaussiano y ruido ISO. Posteriormente, las imágenes fueron normalizadas utilizando la fórmula:

$$x_{norm} = \frac{x-\mu}{\sigma} \quad (9)$$

donde μ y σ corresponden a la media y desviación estándar de los valores preentrenados en ImageNet, respectivamente. Finalmente, las imágenes fueron convertidas a tensores para su procesamiento en redes neuronales. Todas las transformaciones fueron implementadas utilizando la biblioteca Albumentations, que proporciona una mayor flexibilidad y eficiencia en la manipulación de imágenes en comparación con torchvision.transforms. Este procedimiento se aplicó a un total de 1535 imágenes (Figura 11), incrementando la diversidad del conjunto de entrenamiento y contribuyendo a la reducción del riesgo de sobreajuste.

```
# ----- TRANSFORMACIONES -----
def get_transforms(img_size):
    train_transform = A.Compose([
        A.Resize(img_size, img_size),
        A.HorizontalFlip(p=0.5),
        A.VerticalFlip(p=0.3),
        A.ShiftScaleRotate(shift_limit=0.05, scale_limit=0.1, rotate_limit=10, p=0.5),
        A.RandomBrightnessContrast(brightness_limit=0.2, contrast_limit=0.2, p=0.5),
        A.OneOf([
            A.GaussianBlur(blur_limit=(3, 5), p=0.3),
            A.GaussNoise(var_limit=(10, 50), p=0.3),
            A.ISONoise(p=0.2)
        ], p=0.3),
        A.Normalize(mean=(0.485, 0.456, 0.406), std=(0.229, 0.224, 0.225)),
        ToTensorV2()
    ])

    test_transform = A.Compose([
        A.Resize(img_size, img_size),
        A.Normalize(mean=(0.485, 0.456, 0.406), std=(0.229, 0.224, 0.225)),
        ToTensorV2()
    ])

    return train_transform, test_transform
```

Figura 11. Comandos utilizados para la transformación de imágenes en Python versión 9.2.

Fuente elaboración propia.

3. Creación del Dataset y DataLoader

Para la gestión eficiente de las imágenes y sus etiquetas, se implementó una clase personalizada denominada CustomDentalDataset (Figura 12), diseñada para

estructurar el conjunto de datos, aplicar las transformaciones correspondientes y realizar un preprocesamiento específico basado en parámetros configurables. Esta clase no solo integra de forma automatizada las transformaciones de aumento de datos, sino que también incluye la opción de aplicar un preprocesamiento adicional sobre las imágenes mediante la técnica de "blackout" en las áreas dentales, utilizando funciones personalizadas denominadas `soft_blackout_teeth` o `blackout_teeth`, según la configuración establecida. De este modo, cada muestra recibe las modificaciones pertinentes antes de ser utilizada en el entrenamiento del modelo, asegurando la consistencia y calidad del conjunto de datos.

Dado que el conjunto de datos presentaba un desbalance de clases —donde la categoría “sano” estaba subrepresentada en comparación con “gingivitis” y “periodontitis”—, se implementaron estrategias específicas para mitigar este problema y favorecer un entrenamiento más equilibrado. Inicialmente, se empleó la técnica de `WeightedRandomSampler`, que ajusta la probabilidad de selección de cada muestra en función de la frecuencia relativa de su clase, otorgando mayor oportunidad de muestreo a las clases minoritarias durante cada época de entrenamiento. La técnica de `WeightedRandomSampler` ajusta la probabilidad de selección de cada muestra en función de un peso asignado, favoreciendo así el muestreo equilibrado de clases. La probabilidad p_i de seleccionar una muestra i se define mediante:

$$p_i = \frac{w_i}{\sum_{j=1}^N w_j} \quad (10)$$

donde w_i es el peso asociado a la muestra i , y N representa el número total de muestras en el conjunto de datos. De esta forma, las clases minoritarias, que reciben mayores valores de w_i , tienen una mayor probabilidad de ser seleccionadas durante el entrenamiento, mitigando así el desbalance original del conjunto.

Además, se aplicó un oversampling manual para la clase “sano”, mediante la generación de copias adicionales de sus imágenes originales, a las cuales se les aplicaron transformaciones de aumento de datos como rotaciones, volteos

horizontales y verticales, cambios en el brillo y contraste, y adición de ruido, incrementando así la variabilidad y diversidad de esta categoría.

La integración de todas estas técnicas se realizó de forma automatizada dentro del flujo de trabajo del modelo, mediante la inicialización de los conjuntos de entrenamiento, validación y prueba con instancias de CustomDentalDataset, cada una configurada con las transformaciones y preprocesamientos adecuados para su función específica. La estrategia conjunta de muestreo ponderado y oversampling permitió balancear efectivamente la representación de clases en los lotes de entrenamiento, reduciendo el riesgo de sesgo hacia las categorías más numerosas y favoreciendo un aprendizaje más robusto y generalizable.

```
class CustomDentalDataset(Dataset):
    def __init__(self, images, labels, transform=None, apply_blackout=False, blackout_soft=True):
        self.images = images
        self.labels = labels
        self.transform = transform
        self.apply_blackout = apply_blackout
        self.blackout_soft = blackout_soft

    def __getitem__(self, idx):
        img = self.images[idx]
        label = self.labels[idx]

        if self.apply_blackout:
            if self.blackout_soft:
                img = soft_blackout_teeth(img)
            else:
                img = blackout_teeth(img)

        if self.transform:
            augmented = self.transform(image=img, label=label)
            img = augmented['image']
        return img, label

    def __len__(self):
        return len(self.images)
```

Figura 12. Comandos utilizados para aplicar la transformación de imágenes en el programa de Python versión 9.2. Fuente elaboración propia.

4. Definición del modelo

Para la implementación del modelo de clasificación de inflamación periodontal, se empleó la arquitectura EfficientNet-B2, una red neuronal convolucional eficiente que equilibra precisión y complejidad computacional mediante un escalado

compuesto de profundidad, ancho y resolución de entrada. En particular, EfficientNet-B2 utiliza imágenes de entrada de 260×260 píxeles, incorpora aproximadamente 9.2 millones de parámetros entrenables, es decir, los pesos y sesgos de todas sus capas convolucionales y totalmente conectadas que se ajustan durante el proceso de entrenamiento para optimizar el rendimiento del modelo, y está construido sobre bloques optimizados MBConv (Mobile Inverted Bottleneck Convolutions), lo que le permite optimizar tanto la eficiencia computacional como la precisión del modelo. Además, integra técnicas de regularización como la normalización por lotes (Batch Normalization) y abandono de unidades (Dropout) en puntos estratégicos para mejorar la estabilidad del entrenamiento.

Cada bloque MBConv realiza una expansión inicial de los canales de características mediante una convolución 1×1, seguida de una convolución separable por profundidad 3×3 o 5×5 aplicada individualmente a cada canal, y finalmente una proyección de reducción de canales mediante otra convolución 1×1, todo ello complementado con conexiones residuales. Esta estructura invertida permite preservar información relevante con un número reducido de parámetros y operaciones computacionales.

El modelo también utiliza la función de activación Swish, definida matemáticamente como:

$$f(x) = x * \text{sigmoid}(\beta x) \quad (11)$$

donde β es un parámetro que modula la curva de activación. Esta función combina de manera multiplicativa la entrada x con un factor suavizado por la sigmoide, lo que provoca que los valores negativos pequeños no se anulen por completo (como sucede en ReLU), sino que se atenúen, y que los valores positivos pasen de forma casi lineal. Debido a esta transición suave y no monótona, Swish puede preservar información útil en rangos negativos, mejorar el flujo de gradientes y, en consecuencia, favorecer la capacidad de generalización y la convergencia del modelo.

El modelo fue inicializado con pesos preentrenados en el conjunto de datos ImageNet, permitiendo aprovechar representaciones visuales generales aprendidas a partir de millones de imágenes. Para adaptar EfficientNet-B2 al problema específico de detección de enfermedades inflamatorias del periodonto, se desarrolló una clase personalizada denominada MyEfficientNetB2, que encapsula la lógica del modelo e implementa modificaciones sobre la arquitectura base. En particular, la capa de clasificación original fue sustituida por una nueva capa totalmente conectada con tres neuronas de salida, correspondientes a las clases sano, gingivitis y periodontitis, permitiendo la asignación de probabilidades a cada clase mediante activación softmax.

Para la implementación del modelo de clasificación de inflamación periodontal, se empleó la arquitectura EfficientNet-B2, una red neuronal convolucional eficiente que equilibra precisión y complejidad computacional mediante un escalado compuesto de profundidad, ancho y resolución de entrada. El modelo fue inicializado con pesos preentrenados en el conjunto de datos ImageNet, permitiendo aprovechar representaciones visuales generales aprendidas a partir de millones de imágenes. Para adaptar EfficientNet-B2 al problema específico de detección de enfermedades inflamatorias del periodonto, se desarrolló una clase personalizada denominada MyEfficientNetB2, que encapsula la lógica del modelo e implementa modificaciones sobre la arquitectura base. En particular, la capa de clasificación original fue sustituida por una nueva capa totalmente conectada con tres neuronas de salida, correspondientes a las clases sano, gingivitis y periodontitis, permitiendo la asignación de probabilidades a cada clase mediante activación softmax.

Con el fin de implementar una estrategia efectiva de transfer learning, las capas iniciales del modelo fueron congeladas durante las primeras etapas del entrenamiento, restringiendo la actualización de sus pesos. Este comportamiento fue gestionado mediante un método específico de la clase MyEfficientNetB2, denominado `unfreeze_all()`, el cual recorre todos los parámetros del modelo y

establece su atributo `requires_grad` en `True`, permitiendo así que todos los pesos de la red neuronal puedan ser actualizados durante la optimización. Esta operación facilita la reactivación progresiva del entrenamiento de toda la arquitectura, permitiendo ajustar finamente el modelo a las características particulares del conjunto de imágenes periodontales.

Adicionalmente, para mejorar la estabilidad y precisión del entrenamiento, se utilizó una tasa de aprendizaje reducida junto con un esquema dinámico de ajuste del *learning rate*, lo cual evitó modificaciones abruptas en los pesos preentrenados y favoreció una convergencia más estable y eficiente del modelo (Figura 13).

```
# ----- MODELO PERSONALIZADO (EFFNET-B0) -----
class MyEfficientNetB2(nn.Module):
    def __init__(self, num_classes=3):
        super(MyEfficientNetB2, self).__init__()
        weights = EfficientNet_B2_Weights.IMAGENET1K_V1
        self.base_model = efficientnet_b2(weights=weights)
        in_features = self.base_model.classifier[1].in_features
        self.base_model.classifier[1] = nn.Linear(in_features, num_classes)

    def forward(self, x):
        return self.base_model(x)

    def unfreeze_all(self):
        for param in self.base_model.parameters():
            param.requires_grad = True
```

Figura 13. Estructura de la red neuronal convolucional realizada en el programa de Python versión 9.2. Fuente elaboración propia

En la figura 14 se observa el flujo de la red neuronal convolucional, implementando el modelo de EfficientNetB2, además de las capas convolucionales que posee la red, y sus filtros.

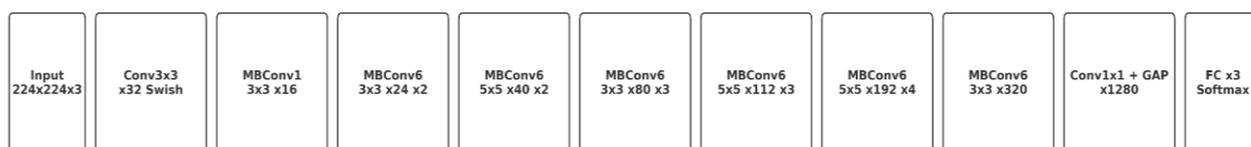


Figura 14. Diagrama de bloques de EfficientNetB2. Fuente elaboración propia.

5. Entrenamiento y validación

El proceso de entrenamiento del modelo se llevó a cabo utilizando la función de pérdida `CrossEntropyLoss`, la cual es ampliamente utilizada para problemas de clasificación multiclase, ya que compara la distribución de probabilidades predicha por el modelo con la distribución verdadera de las etiquetas. Esta función de pérdida penaliza las predicciones incorrectas de manera proporcional al logaritmo de la probabilidad asignada a la clase correcta, promoviendo así ajustes en los pesos que aumenten la probabilidad de las categorías verdaderas.

Matemáticamente, para un problema de clasificación con C clases, la función `CrossEntropyLoss` se define como:

$$CrossEntropyLoss = \sum_{i=1}^C y_i \log(\hat{y}_i) \quad (12)$$

donde y_i representa la etiqueta verdadera codificada como *one-hot* (1 para la clase correcta, 0 en las demás) y \hat{y}_i es la probabilidad predicha por el modelo para la clase i después de la activación `Softmax`.

Para mejorar la precisión en la detección de la clase "sano", que se encontraba subrepresentada en el conjunto de datos, se ajustaron los pesos de la función de pérdida mediante un esquema de ponderación, asignando un valor mayor a esta categoría. Esta estrategia permitió mitigar el desbalance en el conjunto de entrenamiento, reduciendo el sesgo del modelo hacia las clases mayoritarias y favoreciendo una mayor sensibilidad en la detección de casos sanos.

Para la optimización de los parámetros del modelo, se utilizó el algoritmo `AdamW` (Adam with Weight Decay Regularization), una variante mejorada de Adam que separa explícitamente el término de decaimiento de los pesos (*weight decay*) del gradiente, favoreciendo una regularización más efectiva durante el entrenamiento. `AdamW` ajusta de manera adaptativa las tasas de aprendizaje de cada parámetro, ofreciendo actualizaciones estables y eficientes, especialmente adecuadas para arquitecturas profundas como `EfficientNet-B2`.

Se estableció una tasa de aprendizaje inicial baja (1×10^{-5}) con el objetivo de permitir un ajuste progresivo de los parámetros sin provocar oscilaciones abruptas en la actualización de los pesos. Además, para optimizar el proceso de aprendizaje, se implementó un scheduler dinámico, un mecanismo que ajusta automáticamente la tasa de aprendizaje durante el entrenamiento según una estrategia predefinida. Durante la primera fase de entrenamiento, se utilizó CosineAnnealingLR, el cual modifica la tasa de aprendizaje siguiendo una trayectoria en forma de coseno decreciente, comenzando con un valor máximo y disminuyéndolo gradualmente hacia un valor mínimo. Esta estrategia favoreció una exploración amplia al inicio y una convergencia más estable y precisa en las etapas finales.

Posteriormente, en la segunda fase de entrenamiento — tras descongelar todas las capas del modelo mediante el método `unfreeze_all()` — se empleó el scheduler OneCycleLR, el cual ajusta dinámicamente la tasa de aprendizaje siguiendo un patrón de crecimiento y decrecimiento controlado en un solo ciclo, lo que permitió alcanzar una mejor exploración inicial y un fine-tuning más preciso en las etapas finales del entrenamiento.

El entrenamiento completo se realizó en dos fases, sumando un total de 75 épocas: 25 en la fase de ajuste parcial de parámetros congelados y 50 en la fase de ajuste completo del modelo, permitiendo así una adaptación progresiva de EfficientNet-B2 al conjunto de imágenes periodontales (Figura 15).

```
# --- Modelo y función de pérdida ---
model = MyEfficientNetB2(num_classes=3).to(DEVICE)
class_weights = torch.tensor([0.8, 1.8, 1.0], dtype=torch.float32, device=DEVICE)
criterion = FocalLoss(alpha=class_weights, gamma=1.5)

# --- Fase 1: Fine-tuning parcial ---
optimizer1 = AdamW(filter(lambda p: p.requires_grad, model.parameters()), lr=lr_phase1)
scheduler1 = CosineAnnealingLR(optimizer1, T_max=epochs_phase1)

print("\n--- Fase 1: Fine-tuning parcial ---")
_, train_acc_hist1, val_acc_hist1, train_loss_hist1, val_loss_hist1, val_auc_hist1 = train_phase(
    model, train_loader, val_loader, criterion, optimizer1, epochs_phase1, scheduler1, phase=1, mixup_alpha=mixup_alpha
)

# --- Fase 2: Fine-tuning completo ---
model.unfreeze_all()
optimizer2 = AdamW(model.parameters(), lr=lr_phase2)
scheduler2 = OneCycleLR(optimizer2, max_lr=6e-5, epochs=epochs_phase2, steps_per_epoch=len(train_loader))

print("\n--- Fase 2: Fine-tuning completo ---")
best_val_acc, train_acc_hist2, val_acc_hist2, train_loss_hist2, val_loss_hist2, val_auc_hist2 = train_phase(
    model, train_loader, val_loader, criterion, optimizer2, epochs_phase2, scheduler2, phase=2, mixup_alpha=mixup_alpha
)
```

Figura 15. Configuración del modelo, función de pérdida ponderada, optimizadores y schedulers para el entrenamiento en dos fases.

6. Evaluación del modelo

En la Figura 16 se muestran los comandos para evaluar el rendimiento del modelo en la clasificación de imágenes. Se implementó la función *evaluar_metricas*, la cual permite calcular métricas clave de desempeño, como precisión (Precision), sensibilidad o recall (Recall) y F1-score para cada clase. Estas métricas proporcionan una visión detallada de la capacidad del modelo para diferenciar entre las categorías sano, gingivitis y periodontitis, facilitando el análisis de su efectividad y posibles áreas de mejora.

La función establece el modelo en modo de evaluación (*model.eval()*), lo que desactiva ciertos mecanismos internos como la normalización por lotes (Batch Normalization) y la regularización mediante Dropout, asegurando que las predicciones sean consistentes. Se inicializan dos listas vacías (*all_labels* y *all_preds*) para almacenar las etiquetas reales y las predicciones del modelo. Se repite sobre el DataLoader del conjunto de prueba, pasando cada lote de imágenes al modelo. Se calcula la salida del modelo (outputs) y se aplica la función softmax para obtener las probabilidades de cada clase. La clase final es determinada mediante argmax, seleccionando la de mayor probabilidad, y se almacenan tanto las etiquetas reales como las predicciones para su posterior análisis.

Se convierten las listas *all_labels* y *all_preds* en arreglos de NumPy (permiten realizar cálculos eficientes en grandes volúmenes de datos) para facilitar su manipulación. Se calcula la precisión (precision), sensibilidad (Recall) y F1-score para cada clase utilizando las funciones *precision_score*, *recall_score* y *f1_score* de *Scikit-learn*. Cada métrica se imprime en consola, proporcionando una evaluación detallada del rendimiento del modelo en cada categoría.

Es importante considerar para qué sirve cada una de las métricas para los resultados:

- **Precisión (Precision):** Indica cuántas de las imágenes clasificadas en una categoría determinada fueron realmente correctas.

Fórmula:

$$Precisión = \frac{VP}{VP+FP} \quad (13)$$

Donde:

VP (Verdaderos positivos): Cantidad de casos positivos correctamente clasificados.

FP (Falsos positivos): Cantidad de casos negativos que fueron clasificados incorrectamente como positivos.

- **Sensibilidad / Recall (Recall):** Mide la capacidad del modelo para detectar correctamente los casos de una clase en particular. Es especialmente importante en aplicaciones médicas, donde un recall bajo podría significar que el modelo no detecta ciertos casos de enfermedad.

Fórmula:

$$Sensibilidad = \frac{VP}{VP+FN} \quad (14)$$

donde:

VP (Verdaderos positivos): Cantidad de casos positivos correctamente clasificados.

FN (Falsos negativos): Cantidad de casos positivos que fueron clasificados erróneamente como negativos.

- **F1-score:** Representa el equilibrio entre la precisión y el recall, proporcionando una métrica más completa para evaluar el desempeño del modelo en cada categoría.

Fórmula:

$$F1 = 2 * \frac{Precisión * Sensibilidad}{Precisión + Sensibilidad} \quad (15)$$

```

def evaluar_metricas(model, loader):
    model.eval()
    all_labels, all_preds = [], []
    with torch.no_grad():
        for images, labels in loader:
            images, labels = images.to(DEVICE), labels.to(DEVICE)
            outputs = model(images)
            preds = torch.argmax(torch.softmax(outputs, dim=1), dim=1)
            all_labels.extend(labels.cpu().numpy())
            all_preds.extend(preds.cpu().numpy())
    all_labels = np.array(all_labels)
    all_preds = np.array(all_preds)
    print("Métricas por clase:")
    for i, clase in enumerate(['SANO', 'GINGIVITIS', 'PERIODONTITIS']):
        prec = precision_score(all_labels, all_preds, labels=[i], average=None, zero_division=0)[0]
        rec = recall_score(all_labels, all_preds, labels=[i], average=None, zero_division=0)[0]
        f1 = f1_score(all_labels, all_preds, labels=[i], average=None, zero_division=0)[0]
        print(f"{clase}: Precision={prec:.2f}, Recall={rec:.2f}, F1={f1:.2f}")
    return all_labels, all_preds

```

Figura 16. Comandos para la adquisición de las métricas de evaluación realizada en el programa de Python versión 9.2. Fuente elaboración propia.

7. Interfaz gráfica para predicciones

Para facilitar la interacción con el modelo entrenado y permitir a los usuarios realizar predicciones de manera intuitiva y accesible, se desarrolló una interfaz gráfica basada en Streamlit. Streamlit es una biblioteca de Python orientada al desarrollo de aplicaciones web interactivas para ciencia de datos, lo cual permite desplegar modelos de inteligencia artificial de forma rápida y eficiente.

Streamlit permite la ejecución del sistema directamente en un navegador web, lo cual amplía significativamente su accesibilidad y facilita su uso tanto en entornos clínicos como académicos. El flujo de funcionamiento de la aplicación comienza con la carga del modelo previamente entrenado y optimizado para la clasificación de imágenes clínicas. A través de un cuadro de diálogo interactivo, el usuario puede seleccionar una imagen desde su dispositivo. Una vez cargada, la imagen es visualizada en pantalla y procesada automáticamente mediante una serie de transformaciones: redimensionamiento, normalización y conversión a tensores, adaptándose así a los requisitos de entrada del modelo.

Posteriormente, el modelo realiza la inferencia sobre la imagen procesada, generando una predicción en tiempo real. Se asignan probabilidades a cada una

de las clases posibles (sano, gingivitis o periodontitis), seleccionando la de mayor valor. Finalmente, el resultado es mostrado en la interfaz junto con un mensaje indicativo del diagnóstico estimado y una recomendación adaptada al tipo de enfermedad detectada.

Esta implementación con Streamlit permitió construir una herramienta interactiva, visualmente clara y de fácil uso, alineada con los principios de usabilidad en sistemas de salud asistidos por IA.

```
def main():
    st.set_page_config(page_title="Detección de Enfermedades Periodontales", layout="centered")
    st.title("Detección de Enfermedades Periodontales")
    st.write("Sube una imagen para su análisis y detección de posibles enfermedades periodontales.")

    # Cargar el modelo
    try:
        model = cargar_modelo(r'C:\Users\Sergio Pintado\OneDrive\Documents\Maestria\Programación\DETECTION CNN\best_model_val.pth')
    except FileNotFoundError:
        st.error("El archivo del modelo no se encontró. Asegúrate de que 'best_model_val.pth' esté en la ruta correcta.")
        st.stop()
    except Exception as e:
        st.error(f"Error al cargar el modelo: {e}")
        st.stop()

    # Widget para subir una imagen
    uploaded_file = st.file_uploader("Selecciona una imagen", type=["jpg", "jpeg", "png"])

    if uploaded_file is not None:
        try:
            image = Image.open(uploaded_file)
            st.image(image, caption="Imagen cargada", use_column_width=True)
            st.success("Imagen subida correctamente.")

            # Transformaciones
            transform = get_transforms(224)

            # Realizar la predicción
            if st.button("Iniciar Análisis"):
                with st.spinner("Analizando la imagen..."):
                    prediccion = predecir_imagen(model, uploaded_file, transform)
                    st.success("Análisis completado.")
                    st.write(f"Resultado: {prediccion}")
```

Figura 17. Comandos para la predicción de realizada en el programa de Phyton versión 9.2. Fuente elaboración propia.

6.8 Validación externa del prototipo. Cuantificación de MMP-8 en saliva por ELISA

Para la validación del software, se realizó la cuantificación de la MMP-8 en muestras de saliva de 14 pacientes mediante la técnica de inmunoabsorción ligada a enzimas (ELISA), utilizando un kit comercial de la marca Sigma Aldrich. Los sujetos que participaron en la validación externa firmaron el consentimiento informado correspondiente; se recolectó una muestra de saliva y se tomó una

fotografía clínica correspondiente. Todos los sujetos tuvieron el diagnóstico clínico por especialistas previamente.

Para obtener la muestra de saliva, los individuos no habían realizado un previo aseo bucal con cepillo o hilo dental y no habían mascado chicle 2 horas antes. Se tomó una muestra de saliva de cada individuo sin estimular (5 mL) en tubos de polipropileno nuevos. Las muestras se centrifugaron durante 10 min a 2700 rpm, luego se recolectaron los sobrenadantes en tubos Eppendorf y se almacenaron a -80 °C hasta su procesamiento. Las muestras fueron diluidas usando el diluyente B 1X. Para el ensayo con el kit de ELISA se siguieron las instrucciones del fabricante. Brevemente, los estándares y las muestras se analizaron por duplicado. Se realizó una curva de calibración con un rango de 0 a 6000 pg/mL. Se añadieron 100 µL de cada muestra o estándar y se incubaron durante 2.5 horas a temperatura ambiente con agitación suave. Los pocillos se lavaron cuatro veces con 300 µL de tampón de lavado 1X. Se añadieron 100 µL de anticuerpo de detección biotinilado (dilución 1:80) y se incubó durante 1 hora. Tras el lavado, se añadieron 100 µL de estreptavidina conjugada con HRP (dilución 1:600) y se incubó durante 45 minutos. Posteriormente, se añadieron 100 µL de sustrato TMB y se incubó durante 30 minutos en oscuridad. La reacción se detuvo con 50 µL de solución de paro y se midió inmediatamente la absorbancia a 450 nm utilizando un lector de microplacas. La curva de calibración se ajustó a una ecuación cuadrática $y = -7 \times 10^{-8} x^2 + 0.0007x + 0.1293$, $R^2 = 0.99$.

VII RESULTADOS

A continuación, se muestran los resultados obtenidos a partir del desarrollo e implementación del prototipo de sistema inteligente basado en la IA para la detección de enfermedades inflamatorias del periodonto (Inflamperiodont-IA). Este sistema, basado en inteligencia artificial, fue diseñado para identificar la presencia de patologías periodontales a partir del análisis de imágenes clínicas frontales.

Para el entrenamiento y validación del modelo, se utilizaron dos fuentes de datos: un conjunto de fotografías clínicas frontales de pacientes voluntarios (N=765) y de un dataset (<https://data.mendeley.com/datasets/3253gj88rr/1>) (N=835) con imágenes periodontales previamente clasificadas. La combinación de estos datos permitió mejorar la capacidad del modelo para reconocer patrones asociados con enfermedades inflamatorias del periodonto.

7.1 Comportamiento similar entre el entrenamiento y la validación interna de identificación de los grupos (control, gingivitis y periodontitis) del prototipo

Para evaluar el desempeño del modelo durante el entrenamiento, se registró la métrica de *accuracy* (exactitud) en cada época, tanto para el conjunto de entrenamiento como para el conjunto de validación. Estas métricas permiten analizar cómo el modelo aprende a clasificar correctamente las imágenes a lo largo del proceso.

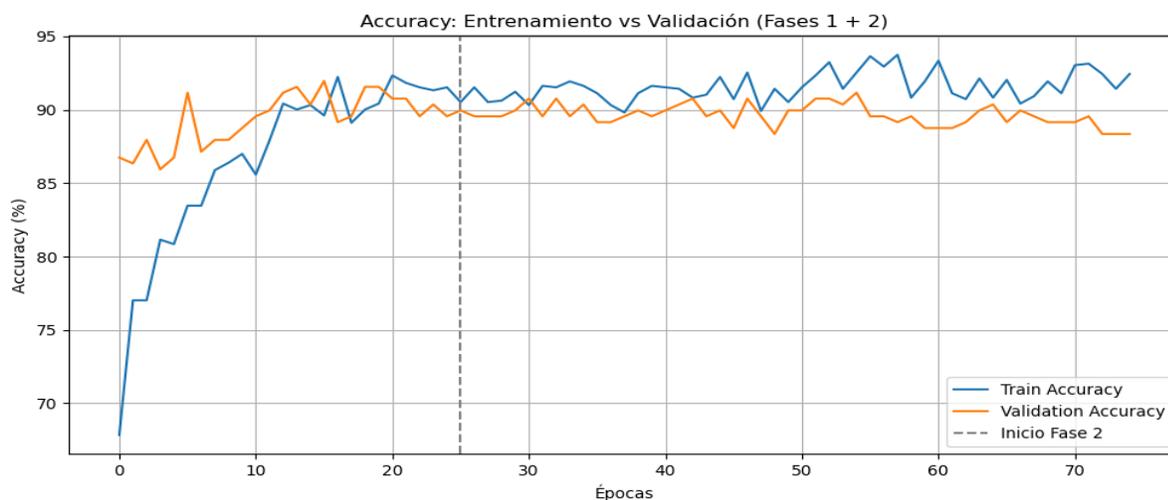


Figura 18. Exactitud del modelo EfficientNet-B2 durante las fases 1 y 2 del entrenamiento

La Figura 18 ilustra la evolución de la exactitud (accuracy) del modelo EfficientNet-B2 a lo largo de 75 épocas, durante las dos fases del proceso de entrenamiento. En la gráfica se presentan las curvas correspondientes al conjunto de entrenamiento (línea azul) y al conjunto de validación (línea naranja). Adicionalmente, se marca con una línea punteada vertical el inicio de la segunda fase de entrenamiento (época 25), correspondiente al ajuste fino de toda la arquitectura (fine-tuning).

Durante la Fase 1 (épocas 0 a 24), el modelo fue entrenado congelando la mayoría de las capas de la red base, permitiendo el entrenamiento únicamente de las capas superiores recién añadidas. En este periodo se observa un incremento rápido y sostenido de la exactitud en el conjunto de entrenamiento, pasando de aproximadamente 68% a más del 90%. La curva de validación muestra un comportamiento similar, con una tendencia ascendente que alcanza niveles cercanos al 90%, lo cual indica que el modelo fue capaz de aprender representaciones generales eficaces desde las primeras etapas del entrenamiento. Al inicio de la Fase 2 (épocas 25 en adelante), se procede a descongelar la totalidad de las capas del modelo para realizar un ajuste fino global. En esta etapa, la exactitud de entrenamiento continúa mejorando de manera gradual, estabilizándose en torno al 93–94 %. Por su parte, la exactitud en el conjunto de validación mantiene una media cercana al 90 %, con pequeñas oscilaciones a lo largo de las épocas. Esta estabilidad en la validación, junto con el ligero incremento en entrenamiento, sugiere que el modelo logró afinar su capacidad de generalización sin incurrir en un sobreajuste significativo.

En conjunto, el comportamiento de ambas curvas refleja una convergencia eficaz del modelo a lo largo de las dos fases, evidenciando que la estrategia de entrenamiento por etapas permitió un aprendizaje progresivo y estable, manteniendo un buen equilibrio entre rendimiento en entrenamiento y capacidad de generalización sobre datos no vistos.

7.2 Índice de error en el prototipo

Para evaluar el índice de error en el prototipo que se refiere a la estabilidad del entrenamiento y la convergencia del modelo, se analizó la evolución de la función de pérdida (*loss*), la cual mide el error cometido por el modelo en cada época. En la figura 20 se muestra la disminución progresiva de la pérdida a lo largo de 75 épocas, reflejando el proceso de aprendizaje del modelo.

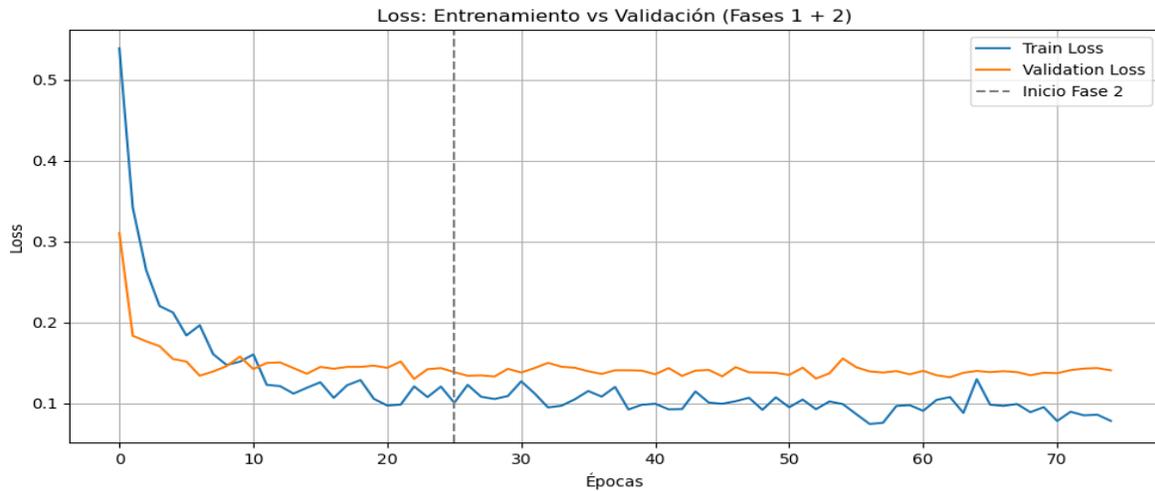


Figura 19. Evolución de la función de pérdida (*loss*) del modelo EfficientNet-B2 durante las fases 1 y 2 del entrenamiento.

La Figura 19 muestra la evolución de la función de pérdida (*loss*) para el conjunto de entrenamiento y el conjunto de validación a lo largo de 75 épocas. Se distinguen claramente las dos fases del entrenamiento, separadas por una línea punteada en la época 25, la cual marca el inicio del ajuste fino (*fine-tuning*) de todas las capas del modelo EfficientNet-B2.

Durante la Fase 1 (épocas 0 a 24), se observa una disminución pronunciada en la pérdida de entrenamiento, descendiendo de un valor inicial superior a 0.5 hasta valores inferiores a 0.12. La pérdida en validación también desciende de manera sostenida en las primeras épocas, estabilizando en torno a 0.13 a partir de la época 10. Este comportamiento indica que el modelo fue capaz de aprender rápidamente patrones representativos en los datos, reduciendo eficazmente el error en ambas particiones sin evidencia de sobreajuste en esta etapa inicial.

A partir de la Fase 2, al habilitar el entrenamiento completo del modelo, la pérdida de entrenamiento continúa disminuyendo ligeramente hasta estabilizarse por debajo de 0.10, mientras que la pérdida de validación se mantiene relativamente constante, con ligeras fluctuaciones en un rango estrecho entre 0.12 y 0.14. Esta estabilidad en la pérdida de validación, sin incremento sustancial, sugiere que el modelo no está sobreajustando los datos y mantiene una buena capacidad de generalización. Las diferencias entre ambas curvas son moderadas, lo que refuerza la idea de un entrenamiento efectivo y controlado.

En conjunto, esta evolución de la función de pérdida respalda los resultados de exactitud observados previamente, confirmando que el modelo logra un aprendizaje profundo y estable, con un desempeño consistente entre las fases de entrenamiento y validación.

7.3 Desempeño del modelo EfficientNet-B2: Evolución del AUC y estabilidad en clasificación multiclase

El área bajo la curva ROC (AUC, por sus siglas en inglés) constituye uno de los indicadores claves para evaluar el rendimiento en modelos de clasificación

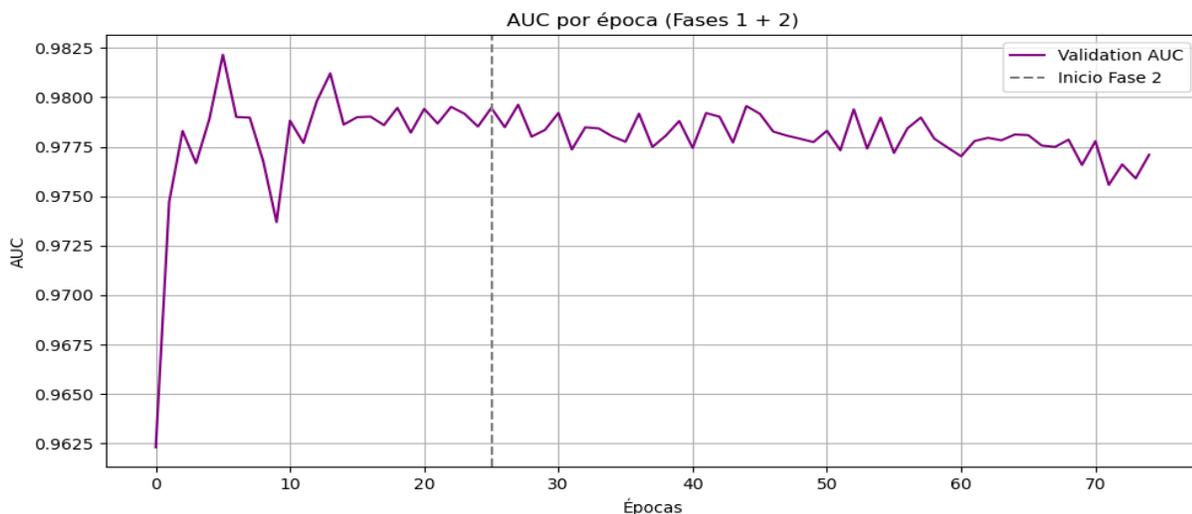


Figura 20. Evolución del AUC en el conjunto de validación a lo largo de las fases 1 y 2 del entrenamiento.

Desde las primeras épocas de la Fase 1, el AUC experimenta una rápida mejora, superando 0.975 en menos de cinco épocas. Aunque presenta pequeñas oscilaciones, se mantiene consistentemente por encima de 0.977 durante esta fase, con picos cercanos a 0.982, lo que refleja una capacidad excepcional para discriminar entre clases desde el inicio del entrenamiento.

En la Fase 2 (a partir de la época 25), el AUC se mantiene en niveles elevados y estables, fluctuando levemente entre 0.975 y 0.980. Esto indica que el ajuste fino no afectó la capacidad discriminativa del modelo, sino que consolidó su rendimiento. A pesar de algunas caídas puntuales, no se observa un descenso significativo, lo que respalda su robustez y capacidad de generalización.

Para complementar este análisis global, se presenta en la Figura 21 un conjunto comparativo de curvas ROC correspondientes a cada una de las clases del problema de clasificación: periodontitis, gingivitis y sano. Esta visualización permite evaluar el desempeño discriminativo del modelo de forma específica para cada categoría, considerando el balance entre sensibilidad (TPR) y 1-especificidad (FPR).

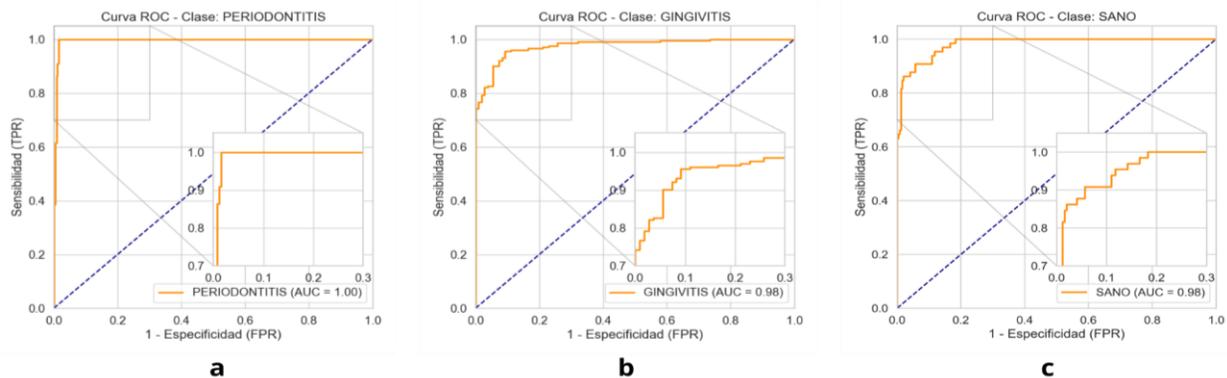


Figura 21. Curvas ROC por clase para el conjunto de validación

La curva correspondiente a la clase periodontitis (Figura 21a) muestra un rendimiento sobresaliente, con un AUC de 1.00, lo que indica una separación perfecta entre esta clase y las demás en el conjunto de validación. La curva alcanza rápidamente el punto (0,1), reflejando máxima sensibilidad y especificidad, sin errores de clasificación. Esto es especialmente importante desde el punto de vista clínico, ya que sugiere una detección precisa de esta condición avanzada.

En la clase gingivitis (Figura 21b), el modelo también alcanzó un rendimiento muy alto, con un AUC de 0.98, evidenciado por una curva ROC que se aproxima al comportamiento ideal. Aunque presenta ligeras oscilaciones, mantiene una excelente sensibilidad y baja tasa de falsos positivos, lo cual demuestra una alta capacidad de detección de esta patología, que en ocasiones puede solaparse con otras condiciones.

Por último, para la clase sano (Figura 21c), el modelo logra también un AUC de 0.98, mostrando una curva con buen comportamiento general, aunque con una ligera tendencia hacia una menor sensibilidad comparada con las otras clases. No obstante, el rendimiento se mantiene dentro de un rango clínicamente aceptable, indicando que el modelo es igualmente competente en identificar correctamente imágenes sin patología.

En conjunto, estas tres curvas respaldan el desempeño sólido y bien balanceado del modelo EfficientNet-B2 en la tarea de clasificación multiclase, en la que cada clase representa un estado clínico distinto del periodonto. La capacidad del modelo para diferenciar con alta precisión entre tejido sano, gingivitis y periodontitis demuestra no solo su eficacia diagnóstica, sino también su estabilidad frente a variaciones entre clases. Este rendimiento consistente sugiere que el modelo podría ser una herramienta útil en entornos clínicos, aportando apoyo en la detección automatizada de enfermedades periodontales mediante imágenes intraorales.

7.4 Validación interna para la evaluación del desempeño del modelo mediante la matriz de confusión

Para evaluar el desempeño del sistema inteligente en la detección de enfermedades periodontales, se empleó una matriz de confusión. Esta herramienta es fundamental para analizar la capacidad del modelo de clasificar correctamente las tres categorías de diagnóstico: Sano, gingivitis y periodontitis. A partir de la matriz de confusión, se calcularon métricas clave como la precisión, *sensibilidad (recall)*,

F1-Score y *especificidad* para cada clase, lo que permite identificar patrones de aciertos y errores en la clasificación.

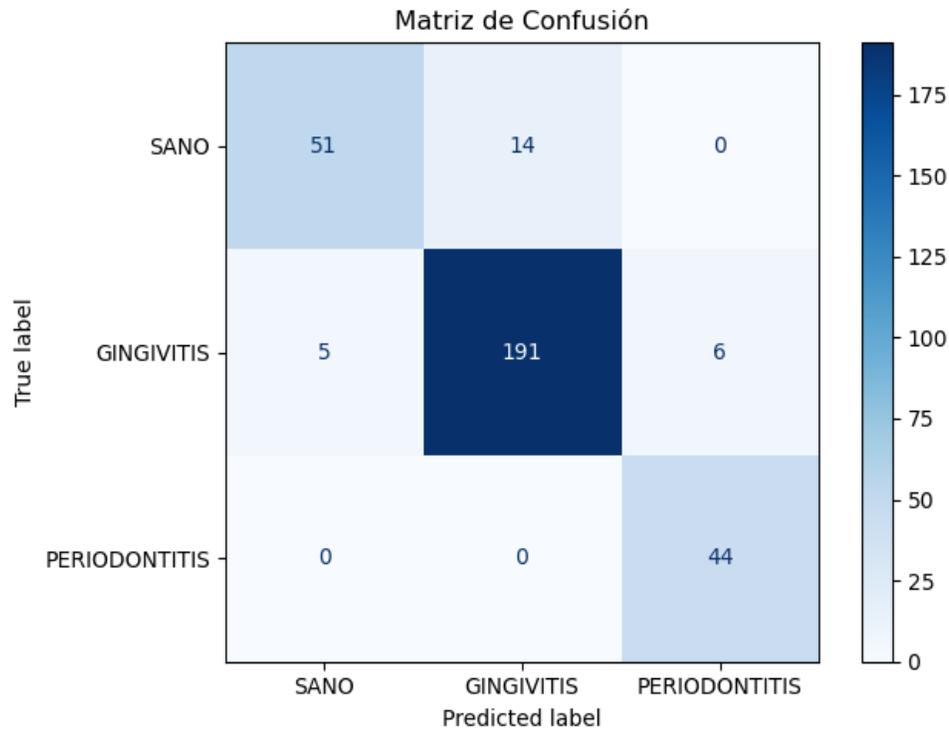


Figura 22. Matriz de confusión del modelo EfficientNet-B2 en el conjunto de prueba.

La Figura 22 muestra la matriz de confusión obtenida tras evaluar el modelo EfficientNet-B2 sobre el conjunto de prueba. En términos generales, se observa un desempeño óptimo del modelo, con una alta tasa de aciertos en las tres clases y un número reducido de errores de clasificación.

En la clase “sano”, el modelo clasificó correctamente 51 casos, aunque presentó 14 errores, al asignarlos a la clase “gingivitis”. Esta mayor confusión respecto a otras clases sugiere que, si bien el modelo logra identificar adecuadamente muchas muestras de tejido sano, aún enfrenta dificultades ante ciertos patrones clínicamente cercanos a estados iniciales de inflamación.

Para la clase “gingivitis”, se obtuvo un desempeño muy favorable, con 191 aciertos, y únicamente 11 errores: 5 confundidos con “sano” y 6 con “periodontitis”. Esta

mejora en la precisión indica que el modelo logró capturar con mayor eficacia las características intermedias de esta condición, a menudo visualmente complejas.

En la clase “periodontitis”, nuevamente se logró una precisión perfecta, con los 44 casos correctamente clasificados, sin registrar errores. Esto refuerza la capacidad del modelo para identificar casos avanzados de enfermedad periodontal, cuyas manifestaciones clínicas suelen ser más evidentes y distintivas.

En conjunto, estos resultados respaldan la solidez diagnóstica del modelo en escenarios clínicos realistas. Si bien existe un margen de mejora en la detección de la clase “sano”, el modelo mantiene una precisión global elevada, especialmente destacable por la ausencia total de falsos negativos en periodontitis, un aspecto crucial en aplicaciones clínicas orientadas a la detección temprana y seguimiento de enfermedades periodontales.

Tabla 4. Métricas de desempeño del modelo EfficientNet-B2 por clase en la clasificación de imágenes periodontales

Clase	Sensibilidad (Recall)	Especificidad	Tasa de Error	ROC AUC	PR AUC
Sano	90.8%	0.951	0.057	0.97	0.913
Gingivitis	91.6%	0.945	0.073	0.96	0.984
Periodontitis	100.0%	0.981	0.016	0.99	0.971

Se reportan la sensibilidad (recall), especificidad, tasa de error, y los valores de área bajo la curva ROC (ROC AUC) y de precisión-recall (PR AUC) para cada categoría: Sano, gingivitis y periodontitis. Estos indicadores permiten evaluar la capacidad del modelo para discriminar correctamente entre las diferentes condiciones periodontales en el conjunto de pruebas.

La Tabla 4 presenta el desempeño del modelo EfficientNet-B2 en la clasificación de las tres clases periodontales: Sano, gingivitis y periodontitis, evaluadas sobre el conjunto de prueba. Se incluyen métricas clave como la sensibilidad (recall), especificidad, tasa de error, así como las áreas bajo las curvas ROC AUC y PR

AUC. Las métricas de sensibilidad y especificidad fueron obtenidas a partir de la matriz de confusión, utilizando los conteos de verdaderos positivos (TP), falsos positivos (FP), verdaderos negativos (TN) y falsos negativos (FN) correspondientes a cada clase.

Para la clase sano, el modelo alcanzó una sensibilidad del 90.8% y una especificidad de 0.951, lo que indica una buena capacidad para identificar correctamente los casos sanos, junto con una baja tasa de falsos positivos. La tasa de error fue de 0.057, mientras que las áreas bajo la curva fueron elevadas: 0.970 para ROC AUC y 0.913 para PR AUC.

En la clase gingivitis, se obtuvo una sensibilidad de 91.6% y una especificidad de 0.945, lo cual refleja un desempeño equilibrado en la detección de esta condición intermedia. La tasa de error fue de 0.073, con valores de 0.960 (ROC AUC) y 0.984 (PR AUC), indicando un buen comportamiento general del modelo.

Para la clase periodontitis, se alcanzó una sensibilidad perfecta (100%) y una especificidad de 0.981, con una tasa de error mínima de 0.016. Estos resultados fueron respaldados por valores de 0.990 en ROC AUC y 0.971 en PR AUC, lo que demuestra un rendimiento sobresaliente en la detección de casos clínicos avanzados.

La tasa de error representa la proporción de predicciones incorrectas sobre el total de casos evaluados para cada clase, y se calcula mediante:

$$Tasa\ de\ error = \frac{FP + FN}{TP + TN + FP + FN} \quad (16)$$

Donde:

- TP = Verdaderos positivos
- TN = Verdaderos negativos
- FP = Falsos positivos
- FN = Falsos negativos

La métrica ROC AUC (*Área bajo la curva Receiver Operating Characteristic*) mide la capacidad del modelo para discriminar entre clases, evaluando la relación entre verdaderos positivos y falsos positivos. Por su parte, la PR AUC (*Área bajo la curva*

Precision-Recall) evalúa la relación entre precisión y recall, siendo especialmente útil en contextos con clases desbalanceadas.

7.5 Validación externa del prototipo mediante detección de MMP-8

Con el objetivo de fortalecer la validación clínica del prototipo basado en inteligencia artificial, se realizó la cuantificación de la metaloproteinasa-8 (MMP-8), un biomarcador salival ampliamente reconocido por su asociación con el proceso de inflamación periodontal. Esta validación biológica se llevó a cabo en un grupo de 14 pacientes con diagnóstico de inflamación del periodonto previo, cuyos niveles de MMP-8 fueron determinados mediante un ensayo inmuno-enzimático (ELISA). La finalidad fue determinar la precisión de respuesta del prototipo INFLAMPERIODONT-IA con una referencia bioquímica objetiva, permitiendo así explorar la concordancia entre el estado inflamatorio real de los tejidos.

Como se observa en la tabla 5, el prototipo INFLAMPERIODONT-IA identificó las 5 imágenes que corresponden a periodontitis, mostrando una alta precisión en los cuadros de inflamación avanzada. En el caso de gingivitis, el modelo acertó en 6 de 9 casos, clasificando

erróneamente 3 como periodonto sano, lo que sugiere una menor sensibilidad para detectar inflamaciones iniciales o de menor intensidad clínica.

Tabla 5. Comparación entre los diagnósticos con Inflamperiodont-IA vs clínico.

	Diagnóstico de Inflamperiodont-IA	Diagnóstico clínico
Paciente 1	Gingivitis	Gingivitis
Paciente 2	Periodontitis	Periodontitis
Paciente 3	Gingivitis	Gingivitis
Paciente 4	Sano	Gingivitis
Paciente 5	Gingivitis	Gingivitis
Paciente 6	Periodontitis	Periodontitis
Paciente 7	Sano	Gingivitis
Paciente 8	Gingivitis	Gingivitis
Paciente 9	Gingivitis	Gingivitis
Paciente 10	Periodontitis	Periodontitis

Paciente 11	Periodontitis	Periodontitis
Paciente 12	Sano	Sano
Paciente 13	Periodontitis	Periodontitis
Paciente 14	Sano	Gingivitis

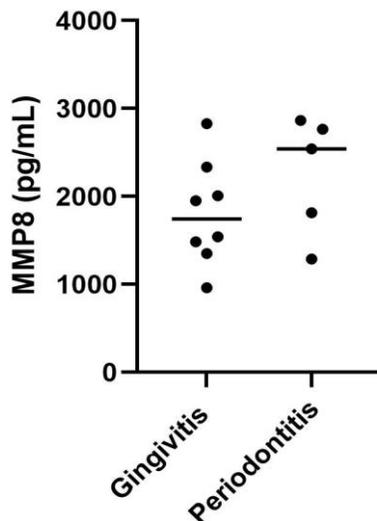


Figura 23. Distribución de los niveles salivales de MMP-8 (pg/mL) en pacientes con diagnóstico de gingivitis y periodontitis.

Cada punto representa el valor individual de un paciente, mientras que la línea horizontal indica la media del grupo. Se observa que los pacientes con periodontitis presentan, en general, niveles más elevados de MMP-8 en comparación con los de gingivitis, aunque existe una leve superposición entre ambos grupos. Esta tendencia respalda el uso de MMP-8 como biomarcador de progresión inflamatoria, ya que los niveles tienden a aumentar conforme avanza la enfermedad periodontal.

Prueba T para Muestras Independientes

Prueba T para Muestras Independientes				
		Estadístico	gl	p
MMP	T de Student	-1.25	11.0	0.237

Nota. $H_a: \mu_1 \neq \mu_2$

Supuestos

Tests of Normality			
		statistic	p
MMP	Shapiro-Wilk	0.963	0.804
	Kolmogorov-Smirnov	0.134	0.950
	Anderson-Darling	0.245	0.703

Nota. Additional results provided by *moretests*

Figura 24. Resultados de la prueba *t* para muestras independientes y verificación de normalidad de los datos. Jamovi versión 2.3.28

Los datos cumplieron con los supuestos de normalidad, según las pruebas de Shapiro-Wilk ($p = 0.804$), Kolmogorov-Smirnov ($p = 0.950$) y Anderson-Darling ($p = 0.703$), lo que justifica el uso de la prueba *t* de Student. Sin embargo, los resultados no mostraron diferencias estadísticamente significativas entre ambos grupos ($t = -1.25$; $p = 0.237$), lo que indica que, pese a la tendencia observada en la Figura 23, los niveles de MMP-8 en saliva no fueron suficientemente distintos entre gingivitis y periodontitis para establecer una diferencia concluyente desde el punto de vista estadístico.

Este hallazgo refuerza la necesidad de integrar múltiples herramientas de evaluación diagnóstica. En este sentido, la tabla 5 previamente presentada muestra cómo el prototipo Inflamperiodont-IA, al combinar el análisis clínico visual con procesamiento inteligente, logra clasificar con mayor precisión los casos avanzados (periodontitis), aunque aún enfrenta retos en distinguir casos moderados (gingivitis) con menor carga inflamatoria.

7.6 Diseño e implementación de la interfaz de usuario

La aplicación desarrollada para la detección de enfermedades periodontales cuenta con una interfaz gráfica intuitiva basada en IA. Diseñada para ser accesible tanto para especialistas como para pacientes, la interfaz permite a los usuarios cargar imágenes dentales y obtener un diagnóstico preliminar sobre posibles condiciones periodontales, como gingivitis o periodontitis.

El diseño de la interfaz se centra en la usabilidad y la claridad, siguiendo una estructura funcional que guía al usuario paso a paso. Los principales elementos de la interfaz incluyen:

1. *Carga de imágenes:* Permite al usuario subir imágenes en formatos compatibles (JPG, JPEG o PNG) para su análisis.

2. *Procesamiento de datos*: Una vez cargada la imagen, el sistema la analiza en tiempo real utilizando modelos de inteligencia artificial entrenados para la clasificación de enfermedades periodontales.
3. *Visualización de resultados*: Muestra un diagnóstico claro y detallado, indicando la condición detectada (sano, gingivitis o periodontitis) junto con información adicional relevante.

A continuación, se presentan capturas de pantalla que ilustran el proceso de uso de la aplicación:

1. Pantalla de Inicio



Figura 25. Captura de pantalla de la interfaz principal donde se permite la carga de imágenes.

La pantalla inicial presenta una opción clara para cargar imágenes, con instrucciones sencillas para el usuario.

2. Selección de imagen

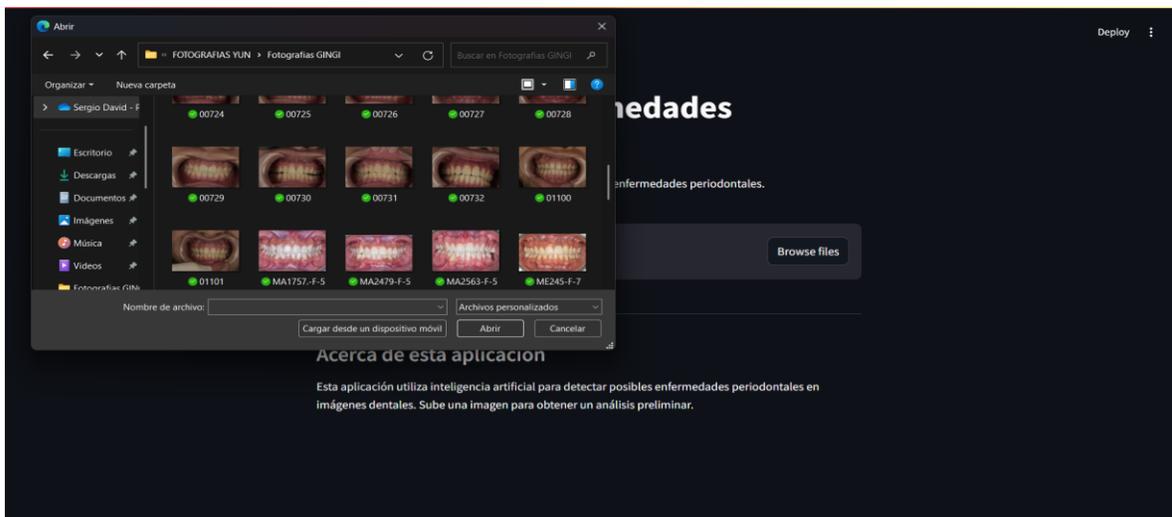


Figura 26. Muestra el explorador de archivos donde el usuario selecciona la imagen a analizar. 100

El usuario selecciona una imagen desde su dispositivo utilizando un explorador de archivos integrado.

3. Imagen cargada

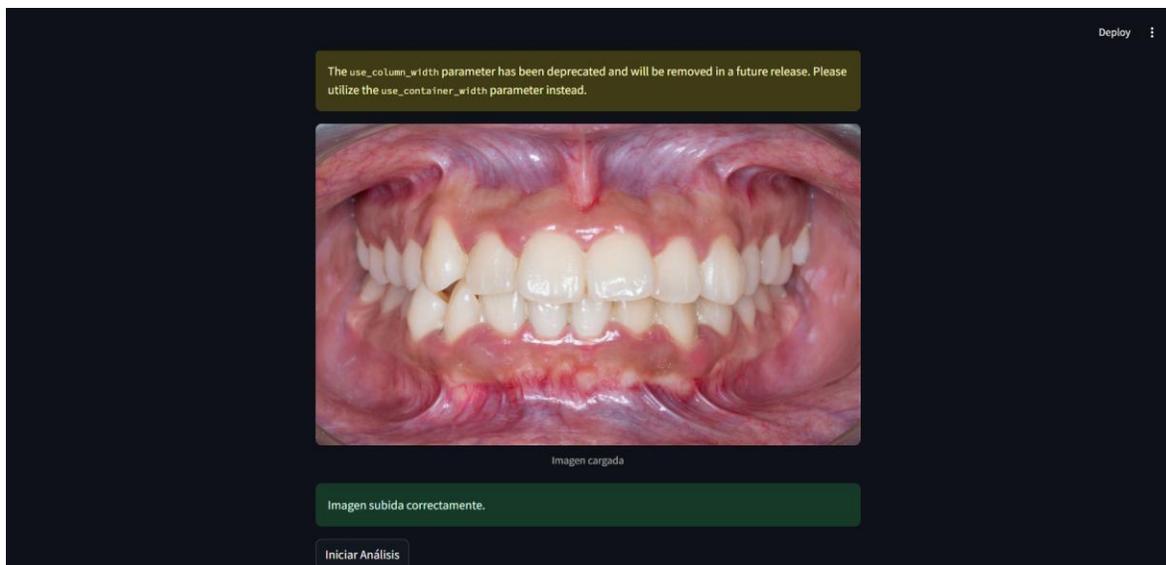


Figura 27. Vista previa de la imagen cargada correctamente con la opción de iniciar el análisis.

Una vez cargada, la imagen se muestra en una vista previa, y el usuario selecciona el botón de iniciar el análisis.

4. Resultados del análisis

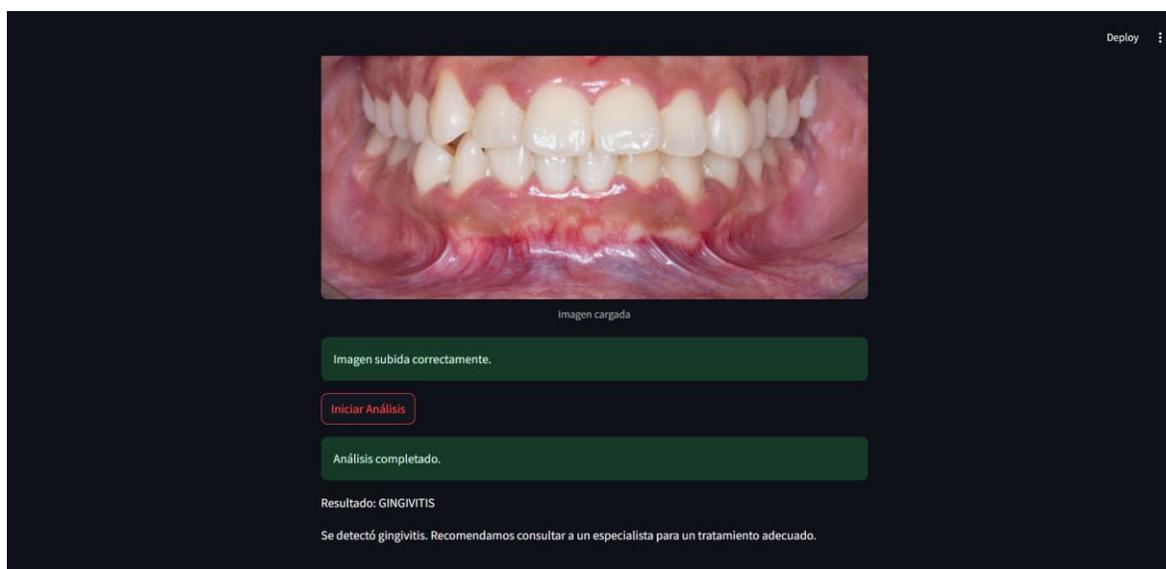


Figura 28. Diagnóstico generado por la IA, con indicaciones sobre la condición detectada.

El sistema muestra el diagnóstico, destacando la condición detectada y proporcionando recomendaciones preliminares.

El diseño de la interfaz de usuario facilita la interacción con el sistema al proporcionar un flujo de trabajo intuitivo y accesible. La posibilidad de cargar imágenes de manera sencilla y obtener resultados en pocos segundos permite un análisis rápido y preciso de imágenes dentales. Además, la interfaz ha sido optimizada para garantizar una experiencia fluida, minimizando la complejidad técnica para los usuarios.

VIII DISCUSIÓN

El presente estudio tuvo como objetivo desarrollar e implementar un prototipo de IA basado en la arquitectura EfficientNet-B2 para la clasificación automática de imágenes clínicas del periodonto en tres categorías: tejido sano, gingivitis y periodontitis. Los resultados obtenidos demuestran un rendimiento alto del modelo, alcanzando una precisión ponderada del 91.3%, un F1-score macro de 90.7% y un AUC promedio de 0.978. Estos valores reflejan una alta capacidad discriminativa del sistema para identificar correctamente tanto tejidos sanos como distintas fases de inflamación periodontal.

8.1 Rendimiento del modelo EfficientNet-B2 en clasificación periodontal

El modelo EfficientNet-B2 desarrollado en este estudio demostró un desempeño excepcional en la clasificación de imágenes periodontales, alcanzando una sensibilidad perfecta del 100%, un F1-score de 0.94 y un AUC-ROC de 0.99 para la detección de periodontitis, sin presentar evidencia de sobreajuste. Estos resultados no solo confirman la utilidad del aprendizaje profundo en periodoncia, sino que representan una mejora sustancial frente a los enfoques reportados en la literatura reciente.

Al compararlo con el estudio del 2021 de Wen et al. [118], quienes emplearon una arquitectura basada en DenseNet con preprocesamiento especializado para eliminar visualmente los dientes, nuestro modelo supera significativamente sus métricas reportadas (AUC de 0.99 vs 0.84 máximo), manteniendo además una precisión global del 91.3%. Esta ventaja es particularmente relevante considerando que nuestro enfoque maneja una tarea más compleja al incluir tres categorías diagnósticas en lugar de un esquema binario, y lo hace sin requerir técnicas avanzadas de preprocesamiento de imágenes.

De igual forma, en el 2020, Alalharith et al. [119] utilizaron Faster R-CNN con ResNet-50, observamos que nuestro modelo triplica la sensibilidad (100% vs 41.75%) en la detección de periodontitis, mientras mantiene una precisión

comparable (91.3% vs 88.02%). Esta mejora es especialmente valiosa en el contexto clínico, donde la capacidad para identificar todos los casos positivos es fundamental para el diagnóstico temprano. Además, nuestro estudio se basó en un conjunto de datos más amplio y diverso (1,581 imágenes), superando la limitación de trabajar con solo 134 imágenes como en el estudio de referencia.

Estas ventajas comparativas posicionan a nuestro modelo como una solución técnica y clínicamente práctica, que combina una alta sensibilidad para la detección de casos, precisión sostenida en un esquema multiclase y viabilidad de implementación al utilizar imágenes intraorales RGB estándar sin requerir de equipamiento especializado. Los resultados obtenidos en este estudio sugieren que EfficientNet-B2 representa un avance significativo en el desarrollo de herramientas de apoyo diagnóstico para la periodoncia, superando las limitaciones de sensibilidad de algunos enfoques anteriores y la complejidad metodológica de otros, al tiempo que ofrece un balance óptimo entre desempeño métrico y aplicabilidad clínica directa.

8.2 Desempeño del modelo EfficientNet-B2 en clasificación multiclase

El modelo EfficientNet-B2 implementado en este estudio mostró un rendimiento excepcional en la clasificación multiclase de imágenes intraorales RGB, logrando una diferenciación precisa entre tejido sano, gingivitis y periodontitis. En particular, destaca su capacidad diagnóstica para la identificación de periodontitis, alcanzando un valor de AUC-ROC de 0.990, un resultado sobresaliente considerando que esta fue la categoría menos representada en el conjunto de datos (N = 122 imágenes). Este desempeño es especialmente significativo, dado que los problemas de clasificación multicategoría suelen presentar desafíos adicionales que comprometen la eficacia predictiva de los modelos de inteligencia artificial, tales como el desbalance entre clases, las variaciones morfológicas sutiles entre estados clínicos adyacentes (por ejemplo, entre encías sanas y gingivitis

incipiente), y la sensibilidad a factores extrínsecos como el ángulo de captura, las condiciones de iluminación o la presencia de artefactos clínicos.

Asimismo, al comparar el prototipo desarrollado en el presente estudio con investigaciones previas que emplearon redes neuronales multitarea (MTL-CNN) sobre un conjunto de 3,932 imágenes de 625 pacientes, donde se reportó un AUC máximo de 87.11% para la identificación de gingivitis, nuestro modelo evidencia una capacidad diagnóstica superior. EfficientNet-B2 logró un AUC promedio de 0.978 y un valor específico de 0.990 para periodontitis. Esta mejora puede atribuirse a la selección de una arquitectura eficiente combinada con técnicas avanzadas de optimización como Focal Loss, Mixup y Oversampling, que contribuyeron significativamente a una discriminación más precisa entre clases, particularmente para las categorías menos representadas [118].

Nuestro enfoque también ofrece ventajas prácticas considerables al emplear imágenes intraorales RGB, que son más accesibles y fáciles de obtener en entornos clínicos convencionales, en comparación con los requisitos técnicos de estudios basados en radiografías panorámicas o segmentaciones radiográficas complejas. En ese sentido, estudios previos que utilizaron imágenes radiográficas lograron un AUC de 0.91 para la identificación de pérdida ósea [124]. En contraste, el presente estudio implementó una solución de clasificación multiclase que no solo supera estos resultados métricos, sino que además proporciona un diagnóstico más específico y diferenciado entre gingivitis y periodontitis, alcanzando un AUC macro de 0.978. Esto permite un abordaje clínico más preciso y efectivo para la detección temprana y el tratamiento oportuno de enfermedades periodontales.

La combinación estratégica de la arquitectura EfficientNet-B2 con técnicas avanzadas de aprendizaje profundo orientadas a mitigar desafíos como el desbalance de clases, el procesamiento de imágenes de alta resolución y la categorización múltiple, consolidan la contribución metodológica de este estudio, posicionando al modelo desarrollado como una solución robusta, precisa y clínicamente viable frente a las aproximaciones reportadas anteriormente.

8.3 Comparación del modelo EfficientNet-B2 con estudios previos basados en imágenes clínicas y radiográficas

A diferencia de los modelos aplicados sobre imágenes radiográficas —donde las condiciones de captura suelen ser controladas y homogéneas—, el presente estudio se desarrolló en un entorno visual considerablemente más desafiante. Las imágenes clínicas RGB utilizadas presentan variaciones en iluminación, textura, enfoque y presencia de estructuras anatómicas blandas, lo cual eleva la complejidad del problema de clasificación. En este contexto, el rendimiento alcanzado por EfficientNet-B2 adquiere mayor relevancia, ya que demuestra no solo una capacidad discriminativa sólida, sino también una estabilidad frente a la variabilidad natural del entorno clínico real.

Al contrastar el modelo propuesto con investigaciones que han aplicado variantes de EfficientNet en el ámbito odontológico, se observan resultados consistentes, pero en contextos menos complejos. Por ejemplo, Hasnain et al. [125] (n = 2,400) en 2024, evaluaron las versiones B0 a B7 de EfficientNet en imágenes panorámicas y periapicales, alcanzando un AUC de 99.21% y una precisión del 98.32% con EfficientNet-B5. De manera similar, Chen et al. [126] (n = 2,826) en 2023, utilizaron EfficientNet-B0 para la detección conjunta de caries y periodontitis en imágenes periapicales, logrando AUCs de 98.31% y 98.67%, respectivamente. Aunque estos resultados son elevados, deben interpretarse dentro del contexto de imágenes radiográficas en escala de grises, capturadas bajo condiciones altamente controladas y homogéneas.

En contraste, el presente estudio se desarrolló utilizando imágenes clínicas RGB capturadas en condiciones reales de consultorio, con variabilidad inherente en iluminación, textura, enfoque y estructuras anatómicas. A pesar de este entorno visual más exigente, el modelo EfficientNet-B2 alcanzó un AUC de 0.990 para la detección de periodontitis y una precisión ponderada del 91.3%. Este desempeño refleja no solo la capacidad discriminativa de la arquitectura, sino también su

adaptabilidad diagnóstica frente a la heterogeneidad del contexto clínico. Además, el uso de fotografías clínicas posiciona a esta propuesta como una solución accesible y práctica en escenarios donde la disponibilidad de imágenes radiológicas es limitada.

Un estudio adicional se empleó una red neuronal convolucional multitarea (MTL-CNN) sobre un conjunto extenso de 3,932 imágenes clínicas RGB de 625 pacientes. A pesar del volumen considerable de datos, su modelo logró un AUC de solo 87.11% para la detección de gingivitis. En contraste, el modelo propuesto en esta tesis alcanzó un AUC promedio de 0.978 y un valor específico de 0.990 para periodontitis, lo que sugiere que la arquitectura EfficientNet-B2, combinada con técnicas de entrenamiento avanzadas como Focal Loss, Mixup y fine-tuning, permitió una discriminación más precisa incluso en clases menos representadas [118].

A diferencia de los enfoques anteriores, el presente trabajo se enfocó en la predicción temprana de condiciones periodontales —gingivitis y periodontitis— a partir de fotografías intraorales convencionales, entrenando al modelo para identificar patrones visuales característicos entre estas clases. En conjunto, los estudios analizados confirman que EfficientNet constituye una arquitectura versátil y potente para tareas diagnósticas. No obstante, el enfoque adoptado en esta investigación, que combina accesibilidad clínica (uso de imágenes RGB), eficiencia computacional (versión B2 de EfficientNet) y estrategias de entrenamiento especializadas, posiciona al modelo propuesto como una solución práctica, efectiva y escalable para su integración en sistemas de apoyo al diagnóstico periodontal.

8.4 Interpretabilidad del modelo mediante visualizaciones Grad-CAM

Una de las limitaciones habituales en modelos de inteligencia artificial aplicados a imágenes médicas es su carácter de "caja negra", lo cual dificulta la validación clínica y la confianza en su uso asistencial. Para abordar este desafío, en el presente

estudio se incorporó la técnica Gradient-weighted Class Activation Mapping (Grad-CAM) como herramienta de explicabilidad visual. Esta técnica permite identificar qué regiones específicas de la imagen fueron más relevantes para la predicción del modelo, generando mapas térmicos superpuestos que indican el grado de atención asignado por la red neuronal a distintas zonas anatómicas.

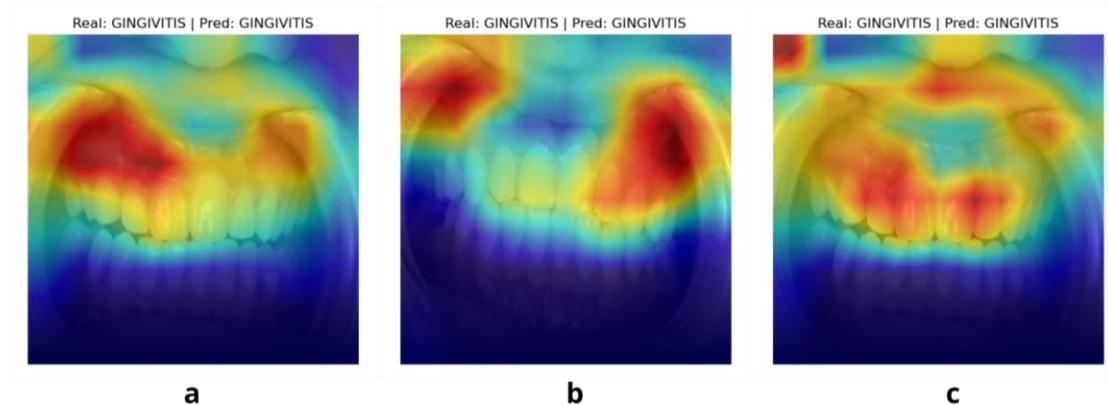


Figura 29. Visualización Grad-CAM en imágenes correctamente clasificadas como gingivitis.

En la Figura 29, se presentan ejemplos de imágenes correctamente clasificadas como gingivitis, donde el modelo EfficientNet-B2 se enfocó principalmente en la región de las encías marginales y el área perigingival, zonas coherentes con las manifestaciones clínicas de esta condición. Este patrón de activación ha sido también reportado en estudios recientes como los de Chau et al. [116] en 2023 y Khaleel et al. [127] en 2021, quienes identificaron un comportamiento similar en redes convolucionales aplicadas a imágenes intraorales.

A pesar de la complejidad del entorno clínico (iluminación variable, presencia de estructuras blandas y diferencias angulares), los mapas Grad-CAM muestran un foco de atención congruente con las regiones afectadas. Esto sugiere que el modelo no solo aprendió a diferenciar clases a partir de patrones globales, sino que desarrolló una forma de atención localizada sobre características visuales relevantes, como el enrojecimiento o engrosamiento gingival, sin requerir segmentación previa ni eliminación de estructuras dentales.

Estudios como el de Khan et al. [119] han enfatizado la necesidad de modelos explicables en odontología digital, argumentando que una predicción debe ir acompañada de una justificación visual que pueda ser validada por el clínico. En este sentido, las visualizaciones generadas en este estudio no solo fortalecen la interpretabilidad del modelo, sino que también permiten identificar posibles errores sistemáticos o sesgos atencionales cuando se comparan aciertos y errores de predicción.

Por tanto, la integración de Grad-CAM como parte del flujo de validación contribuye tanto a la transparencia diagnóstica, como a la adopción clínica de herramientas basadas en aprendizaje profundo, alineándose con las recomendaciones actuales para el uso responsable de inteligencia artificial en entornos médicos.

8.5 Limitaciones del modelo y del estudio

A pesar de los resultados prometedores obtenidos con la implementación del modelo EfficientNet-B2 en la clasificación multiclase de enfermedades periodontales a partir de imágenes clínicas RGB, es importante reconocer una serie de limitaciones que podrían influir en la generalización, aplicabilidad y comparación del sistema con otros enfoques previamente reportados en la literatura.

En primer lugar, uno de los principales desafíos enfrentados fue el desbalance en el conjunto de datos, particularmente en la clase “sano”. Aunque se implementaron estrategias como oversampling y la utilización de WeightedRandomSampler para ajustar la frecuencia de muestreo, la distribución original pudo haber generado cierta inclinación del modelo hacia las clases mayoritarias. Esta situación también se ha observado en estudios previos, como el de Li et al. [118], en donde se enfatiza la importancia de balancear los datos para obtener modelos robustos.

Otro aspecto relevante fue la variabilidad en la calidad y condiciones de captura de las imágenes. A diferencia de los estudios basados en imágenes radiográficas, donde las condiciones de adquisición son homogéneas y controladas, las imágenes utilizadas en este estudio fueron tomadas en entornos clínicos reales.

Esto implicó diferencias en iluminación, ángulo, enfoque y presencia de estructuras no periodontales. Si bien esto representa una fortaleza en términos de realismo, también añade complejidad al proceso de aprendizaje y puede introducir ruido en las predicciones.

En términos de volumen de datos, aunque el estudio utilizó 1,581 imágenes, este número es inferior al de otros trabajos similares como el de Chen et al. [126], quienes emplearon más de 2,800 imágenes, o el de Li et al. [118], con más de 3,900 muestras. Esta diferencia en el tamaño y diversidad del dataset puede limitar la capacidad del modelo para generalizar a poblaciones clínicas más amplias o con características demográficas distintas.

Asimismo, el modelo no empleó técnicas de segmentación anatómica para aislar específicamente las regiones de interés, como las encías o los dientes. A diferencia de estudios como el de Alalharith et al. [119], que utilizaron Faster R-CNN con enfoque en regiones específicas, el presente modelo trabajó con la imagen completa, lo que puede haber introducido señales no relevantes en el proceso de clasificación, y eventualmente influido en la atención del modelo hacia zonas no diagnósticas.

Por otro lado, aunque se observaron altos valores de AUC y F1-score en la clasificación de periodontitis, la comparación directa con estudios basados en imágenes radiográficas debe tomarse con cautela. Investigaciones como las de Hasnain et al. [125] y Chen et al. [126] lograron métricas elevadas, pero bajo condiciones muy distintas: imágenes en escala de grises, sin estructuras blandas visibles y con una homogeneidad que facilita la extracción de características. En contraste, las imágenes RGB utilizadas en este estudio representan un contexto visual más complejo y variable.

En cuanto a la explicabilidad del modelo, si bien se implementó la técnica Grad-CAM para visualizar las regiones más relevantes en la toma de decisiones del modelo, esta herramienta aún presenta limitaciones. Grad-CAM ofrece una visualización cualitativa, pero no permite una interpretación cuantitativa ni asegura

con precisión que las regiones destacadas sean clínicamente relevantes. Tal como señalan Khaleel y Aziz [127], se requiere continuar desarrollando enfoques interpretables más robustos para favorecer la confianza clínica en sistemas automatizados.

Finalmente, aunque el modelo demostró un desempeño sobresaliente incluso en condiciones clínicas reales, sería recomendable, en futuros trabajos, validar el sistema con imágenes de diferentes dispositivos, poblaciones y entornos clínicos, así como evaluar su desempeño en escenarios de uso real asistido por profesionales de la salud.

En conjunto, estas limitaciones no invalidan los resultados obtenidos, pero sí representan áreas de mejora que deben ser consideradas para fortalecer la aplicabilidad clínica del modelo y su eventual integración en herramientas diagnósticas de apoyo en periodoncia.

IX CONCLUSIONES

Este estudio evidenció el desarrollo de un prototipo de sistema inteligente, basado en inteligencia artificial y redes neuronales convolucionales, capaz de identificar con precisión enfermedades inflamatorias del periodonto (gingivitis y periodontitis) a partir de imágenes clínicas intraorales.

El modelo EfficientNet-B2, entrenado con técnicas como Focal Loss, Mixup, entrenamiento en dos fases y preprocesamiento especializado, alcanzó métricas destacadas, como un AUC de 0.990 para periodontitis y una precisión ponderada del 91.3%. Las visualizaciones Grad-CAM confirmaron que el modelo enfoca su atención en las zonas periodontales relevantes, fortaleciendo su confiabilidad clínica.

Se desarrolló también una interfaz gráfica en Streamlit que facilita el uso del sistema, haciéndolo accesible, intuitivo y de bajo costo, lo que lo perfila como una herramienta viable para el diagnóstico oportuno y la prevención de enfermedades periodontales.

Además, la validación externa se reforzó mediante la cuantificación salival de MMP-8. Aunque no se observaron diferencias estadísticamente significativas entre gingivitis y periodontitis, los niveles fueron más altos en esta última, mostrando una tendencia coherente con los resultados del prototipo y sugiriendo su utilidad como complemento diagnóstico.

En conjunto, este trabajo representa una contribución relevante para la integración de soluciones basadas en IA en odontología, con potencial para desarrollarse como un sistema híbrido que combine imágenes clínicas y biomarcadores.

X RECOMENDACIONES

Los resultados presentados en este trabajo constituyen un primer acercamiento al desarrollo de herramientas basadas en inteligencia artificial para la detección automatizada de enfermedades inflamatorias del periodonto. Si bien el prototipo demostró un desempeño prometedor en condiciones clínicas reales, aún persisten desafíos importantes que deben atenderse para garantizar su aplicabilidad amplia, segura y confiable.

Aunado a lo anterior, debe reconocerse que el uso de imágenes clínicas RGB — tomadas en contextos diversos y con variaciones inherentes en iluminación, enfoque y composición anatómica— implica una complejidad adicional frente a otros métodos de diagnóstico estandarizado, como la radiografía. Por ello, resulta necesario continuar fortaleciendo el modelo mediante estrategias de validación externa, balance de clases, mejoras en interpretabilidad y mayor integración con herramientas clínicas ya existentes.

Con base en estas consideraciones, se recomienda:

- **Realizar una validación externa del modelo:** Es recomendable evaluar el desempeño del sistema con imágenes provenientes de otros centros clínicos, diferentes cámaras y poblaciones variadas, para comprobar su capacidad de generalización en entornos heterogéneos.
- **Ampliar y balancear la base de datos:** Se sugiere incrementar el número de imágenes, particularmente en la clase “sano”, para mejorar el equilibrio entre categorías y optimizar la sensibilidad diagnóstica del modelo, especialmente en etapas tempranas de la enfermedad.
- **Incorporar segmentación anatómica automatizada:** La integración de técnicas que delimiten de forma precisa las regiones gingivales permitiría reducir la influencia de estructuras no relevantes y aumentar la especificidad del diagnóstico.

- **Explorar métodos avanzados de interpretabilidad:** Complementar Grad-CAM con técnicas como LIME o SHAP podría ofrecer explicaciones más detalladas y cuantificables, facilitando la validación clínica y aumentando la confianza del profesional en los resultados.

XI REFERENCIAS

1. Yang B, Pang X, Li Z, Chen Z, Wang Y. Immunomodulation in the Treatment of Periodontitis: Progress and Perspectives. *Front Immunol.* 2021; 19:12:781378.
2. Rajendiran M, Trivedi HM, Chen D, Gajendrareddy P, Chen L. Recent Development of Active Ingredients in Mouthwashes and Toothpastes for Periodontal Diseases. *Molecules.* 2021; 26(7):2001.
3. Ossowska A, Kusiak A, Świetlik D. Artificial Intelligence in Dentistry-Narrative Review. *Int J Environ Res Public Health.* 2022; 19(6):3449.
4. Lindhe J, Karring T, Lang NP. *Periodontologia Clinica E Implantologia Odontologica.* Argentina: Médica Panamericana; 2009.
5. Gutiérrez, J Anatomía macroscópica de la mucosa bucal. *Odontoesiomología.* Agosto 1990. Vol. 3 N° 3 p.13-26. [Internet]. 1990.
6. Salvi GE, Rocuzzo A, Imber J-C, Stähli A, Klinge B, Lang NP. Clinical periodontal diagnosis. *Periodontology 2000.* 2023;00:1-19
7. Ferraris MEG de, Muñoz AC. *Histología, Embriología E Ingeniería Tisular.* Argentina: Editorial Médica Panamericana; 2009.
8. Maeda H. Mass acquisition of human periodontal ligament stem cells. *World J Stem Cells.* 2020. 12(9):1023–1031.
9. Welsch U. *Histología.* Argentina: Ed Médica Panamericana; 2008.
10. Barrancos Mooney J, Barrancos PJ. *Operatoria dental: integración clínica.* 4^a ed. Buenos Aires: Editorial Médica Panamericana; 2006.
11. Galler KM, Weber M, Korkmaz Y, Widbiller M, Feuerer M. Inflammatory

Response Mechanisms of the Dentine–Pulp Complex and the Periapical Tissues. *Int J Mol Sci.* 2021; 22(3):1480.

12. Huang X, Xie M, Xie Y, Mei F, Lu X, Li X, et al. The roles of osteocytes in alveolar bone destruction in periodontitis. *J Transl Med.* 2020; 18:479.
13. Landay MA, Schroeder HE. Differentiation in normal human buccal mucosa epithelium. *J Anat.* 1979; 128(Pt 1):31-51.
14. Hajishengallis G. Periodontitis: from microbial immune subversion to systemic inflammation. *Nat Rev Immunol.* 2015; 15(1):30-44.
15. Guimarães LM, Valeriano AT, Pontes HAR, Gomez RS, Gomes CC. Manifestations of hyperparathyroidism in the jaws: Concepts, mechanisms, and clinical aspects. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology.* 2022; 133(5):547-555.
16. Botelho J, Machado V, Leira Y, Proença L, Chambrone L, Mendes JJ. Economic burden of periodontitis in the United States and Europe: An updated estimation. *Journal of Periodontology.* 2022; 93(3):373-379.
17. Hajishengallis G. Interconnection of periodontal disease and comorbidities: evidence, mechanisms, and implications. *Periodontol 2000.* 2022; 89(1):9-18.
18. Nazir MA. Prevalence of periodontal disease, its association with systemic diseases and prevention. *Int J Health Sci (Qassim).* 2017; 11(2):72-80.
19. Kwon T, Lamster IB, Levin L. Current Concepts in the Management of Periodontitis. *Int Dent J.* 2021; 71(6):462-476.
20. Xu X, Zhou Y, Liu C, Zhao L, Zhang L, Li H, et al. Effects of water flossing on gingival inflammation and supragingival plaque microbiota: a 12-week randomized controlled trial. *Clin Oral Invest.* 2023;27(8):4567-4577.

21. Trombelli L, Farina R, Silva CO, Tatakis DN. Plaque-induced gingivitis: Case definition and diagnostic considerations. *Journal of Periodontology*. 2018; 89(S1):S46-S73.
22. Fischer RG, Lira Junior R, Retamal-Valdes B, Figueiredo LC de, Malheiros Z, Stewart B, et al. Periodontal disease and its impact on general health in Latin America. Section V: Treatment of periodontitis. *Braz oral res*. 2020; 34:e026.
23. Haque MM, Yerex K, Kelekis-Cholakis A, Duan K. Advances in novel therapeutic approaches for periodontal diseases. *BMC Oral Health*. 2022; 22:492.
24. Sylenko HM, Skrypnykov PM, Sylenko YI, Pisarenko OA. Features of development of generalized periodontitis in persons with secretory immunoglobulin a deficiency and its treatment (literature review). *Wiad Lek*. 2021; 74(6):1510-1514.
25. Hajishengallis G, Chavakis T. Local and systemic mechanisms linking periodontal disease and inflammatory comorbidities. *Nat Rev Immunol*. 2021; 21(7):426-440.
26. Di Stefano M, Polizzi A, Santonocito S, Romano A, Lombardi T, Isola G. Impact of Oral Microbiome in Periodontal Health and Periodontitis: A Critical Review on Prevention and Treatment. *Int J Mol Sci*. 2022; 23(9):5142.
27. Highfield J. Diagnosis and classification of periodontal disease. *Australian Dental Journal*. 2009; 54(s1):S11-S26.
28. Sanz M, Marco del Castillo A, Jepsen S, Gonzalez-Juanatey JR, D'Aiuto F, Bouchard P, et al. Periodontitis and cardiovascular diseases: Consensus report. *Journal of Clinical Periodontology*. 2020; 47(3):268-288.

29. Yoshida A, Bouziane A, Erraji S, Lakhdar L, Rhissassi M, Miyazaki H, et al. Etiology of aggressive periodontitis in individuals of African descent. *Jpn Dent Sci Rev.* 2021; 57:20-26.
30. AlSharief M, Alabdurubalnabi E. Periodontal Pathogens and Adverse Pregnancy Outcomes: A Narrative Review. *Life (Basel).* 2023; 13(7):1559.
31. Pan W, Wang Q, Chen Q. The cytokine network involved in the host immune response to periodontitis. *Int J Oral Sci.* 2019; 11(3):30.
32. Stephens MB, Wiedemer JP, Kushner GM. Dental Problems in Primary Care. *afp.* 2018; 98(11):654-660.
33. Chen J, Luo Z, Tseng H, Wang L, Liu B, Li W. Multi-disciplinary treatment of severe palatal radicular groove of maxillary lateral incisor: A case report and literature review. *Zhong Nan Da Xue Xue Bao Yi Xue Ban.* 2023; 48(2):302-310.
34. Darby I. Risk factors for periodontitis & peri-implantitis. *Periodontol* 2000. 2022; 90(1):9-12.
35. Hung M, Kelly R, Mohajeri A, Reese L, Badawi S, Frost C, et al. Factors Associated with Periodontitis in Younger Individuals: A Scoping Review. *J Clin Med.* 2023; 12(20):6442.
36. Stöhr J, Barbaresko J, Neuenschwander M, Schlesinger S. Bidirectional association between periodontal disease and diabetes mellitus: a systematic review and meta-analysis of cohort studies. *Sci Rep.* 2021; 11:13686.
37. Ko T-J, Byrd KM, Kim SA. The Chairside Periodontal Diagnostic Toolkit: Past, Present, and Future. *Diagnostics (Basel).* 2021; 11(6):932.
38. Cardaropoli D. Cirugía periodontal plástica y regenerativa. Madrid: Edra;

2023.

39. Bonilla–Gutiérrez M, Delgado–Rodríguez CE, Camargo–Huertas H. Protocolo estandarizado para la observación de la imagen tomográfica en endodoncia. *Acta Odontológica Colombiana*. 2021; 11(2):66–85.
40. Alshomrani F. Cone-Beam Computed Tomography (CBCT)-Based Diagnosis of Dental Bone Defects. *Diagnostics (Basel)*. 2024; 14(13):1404.
41. Patel S, Durack C, Abella F, Shemesh H, Roig M, Lemberg K. Cone beam computed tomography in Endodontics – a review. *International Endodontic Journal*. 2015; 48(1):3-15.
42. Frąckiewicz W, Jankowska A, Machoy ME. CBCT and modern intraoral scanners as tools for developing comprehensive, interdisciplinary treatment plans. *Adv Clin Exp Med*. 2024; 33(11):1267-1276.
43. Hasturk H, Kantarci A. Activation and Resolution of Periodontal Inflammation and Its Systemic Impact. *Periodontology 2000*. 2015; 69(1):255.
44. Luan X, Zhou X, Fallah P, Pandya M, Lyu H, Foyle D, et al. MicroRNAs: Harbingers and Shapers of Periodontal inflammation. *Semin Cell Dev Biol*. 2022; 124:85-98.
45. Bendek MJ, Canedo-Marroquín G, Realini O, Retamal IN, Hernández M, Hoare A, et al. Periodontitis and Gestational Diabetes Mellitus: A Potential Inflammatory Vicious Cycle. *Int J Mol Sci*. 2021; 22(21):11831.
46. Luan X, Zhou X, Trombetta-eSilva J, Francis M, Gaharwar AK, Atsawasuan P, et al. MicroRNAs and Periodontal Homeostasis. *J Dent Res*. 2017; 96(5):491-500.
47. Dongiovanni P, Meroni M, Casati S, Goldoni R, Thomaz DV, Kehr NS, et al.

Salivary biomarkers: novel noninvasive tools to diagnose chronic inflammation. *Int J Oral Sci.* 2023; 15:27.

48. FDA-NIH Biomarker Working Group. BEST (Biomarkers, EndpointS, and other Tools) Resource: Harmonizing biomarker terminology. Bethesda (MD): U.S. Dept of Health & Human Services, National Institutes of Health; 2016.
49. Noh J, Jang J-H, Yoon H-S, Kim K-B, Heo M-H, Jang H, et al. Evaluation of Salivary Biomarkers of Periodontal Disease Based on Smoking Status: A Systematic Review. *Int J Environ Res Public Health.* 2022; 19(21):14619.
50. Khijmatgar S, Yong J, Rübsamen N, Lorusso F, Rai P, Cenzato N, et al. Salivary biomarkers for early detection of oral squamous cell carcinoma (OSCC) and head/neck squamous cell carcinoma (HNSCC): A systematic review and network meta-analysis. *Jpn Dent Sci Rev.* 2024; 60:32-39.
51. Lumbikananda S, Srithanyarat SS, Mattheos N, Osathanon T. Oral Fluid Biomarkers for Peri-Implantitis: A Scoping Review. *Int Dent J.* 2023; 74(3):387-402.
52. Zhang Z, Yang X, Zhang H, Liu X, Pan S, Li C. The role of extracellular matrix metalloproteinase inducer glycosylation in regulating matrix metalloproteinases in periodontitis. *J Periodontal Res.* 2018; 53(3):391-402.
53. Cabral-Pacheco GA, Garza-Veloz I, Castruita-De la Rosa C, Ramirez-Acuña JM, Perez-Romero BA, Guerrero-Rodriguez JF, et al. The Roles of Matrix Metalloproteinases and Their Inhibitors in Human Diseases. *Int J Mol Sci.* 2020; 21(24):9739.
54. Cui N, Hu M, Khalil RA. Biochemical and Biological Attributes of Matrix Metalloproteinases. *Prog Mol Biol Transl Sci.* 2017; 147:1-73.

55. Radzki D, Negri A, Kusiak A, Obuchowski M. Matrix Metalloproteinases in the Periodontium–Vital in Tissue Turnover and Unfortunate in Periodontitis. *International Journal of Molecular Sciences*. 2024; 25(5):2763.
56. Visse R, Nagase H. Matrix metalloproteinases and tissue inhibitors of metalloproteinases: structure, function, and biochemistry. *Circ Res*. 2003; 92(8):827-839.
57. Luchian I, Goriuc A, Sandu D, Covasa M. The Role of Matrix Metalloproteinases (MMP-8, MMP-9, MMP-13) in Periodontal and Peri-Implant Pathological Processes. *Int J Mol Sci*. 2022; 23(3):1806.
58. Fatemi K, Rezaee SA, Banihashem SA, Keyvanfar S, Eslami M. Importance of MMP-8 in Salivary and Gingival Crevicular Fluids of Periodontitis Patients. *Iran J Immunol*. 2020; 17(3):236-243.
59. Caimi G, Hopps E, Montana M, Urso C, Carollo C, Canino B, et al. The function of matrix metalloproteinase-9 (MMP-9) and its tissue inhibitor (TIMP-1) in several clinical conditions: Results and analysis of our survey. *Clin Hemorheol Microcirc*. 2021; 78(4):401-416.
60. Franco C, Patricia H-R, Timo S, Claudia B, Marcela H. Matrix Metalloproteinases as Regulators of Periodontal Inflammation. *Int J Mol Sci*. 2017; 18(2):440.
61. Hawkins CL, Davies MJ. Role of myeloperoxidase and oxidant formation in the extracellular environment in inflammation-induced tissue damage. *Free Radical Biology and Medicine*. 2021; 172:633-651.
62. Guerrero Hernández JM, Pajares G, Guijarro Mata-García M. Técnicas de procesamiento de imágenes estereoscópicas. *Rev CES Felipe II*. 2011;(13).

63. Marcaccini AM, Meschiari CA, Zuardi LR, Sousa TS de, Taba M, Teofilo JM, et al. Gingival crevicular fluid levels of MMP-8, MMP-9, TIMP-2, and MPO decrease after periodontal therapy. *J Clin Periodontol*. 2010; 37(2):180-190.
64. Patil S, Albogami S, Hosmani J, Mujoo S, Kamil MA, Mansour MA, et al. Artificial Intelligence in the Diagnosis of Oral Diseases: Applications and Pitfalls. *Diagnostics (Basel)*. 2022; 12(5):1029.
65. Niño-Sandoval TC, Guevara Pérez SV, González FA, Jaque RA, Infante-Contreras C. Use of automated learning techniques for predicting mandibular morphology in skeletal class I, II and III. *Forensic Sci Int*. 2017; 281:187.e1-187.e7.
66. Jung S-K, Kim T-W. New approach for the diagnosis of extractions with neural network machine learning. *Am J Orthod Dentofacial Orthop*. 2016; 149(1):127-133.
67. Saghiri MA, Garcia-Godoy F, Gutmann JL, Lotfi M, Asgar K. The reliability of artificial neural network in locating minor apical foramen: a cadaver study. *J Endod*. 2012; 38(8):1130-1134.
68. Ozden FO, Özgönenel O, Özden B, Aydogdu A. Diagnosis of periodontal diseases using different classification algorithms: a preliminary study. *Niger J Clin Pract*. 2015; 18(3):416-421.
69. Nakano Y, Suzuki N, Kuwata F. Predicting oral malodour based on the microbiota in saliva samples using a deep learning approach. *BMC Oral Health*. 2018; 18(1):128.
70. Gu Y, Bai Y, Xie X. Bite Force Transducers and Measurement Devices. *Front Bioeng Biotechnol*. 2021; 9:665081.

71. Arakawa T, Kuroki Y, Nitta H, Chouhan P, Toma K, Sawada S, et al. Mouthguard biosensor with telemetry system for monitoring of saliva glucose: A novel cavitas sensor. *Biosensors and Bioelectronics*. 2016; 84:106-111.
72. Bornes R, Montero J, Correia A, Marques T, Rosa N. Peri-implant diseases diagnosis, prognosis and dental implant monitoring: a narrative review of novel strategies and clinical impact. *BMC Oral Health*. 2023; 23:183.
73. Heikkinen AM, Nwhator SO, Rathnayake N, Mäntylä P, Vatanen P, Sorsa T. Pilot Study on Oral Health Status as Assessed by an Active Matrix Metalloproteinase-8 Chairside Mouthrinse Test in Adolescents. *J Periodontol*. 2016; 87(1):36-40.
74. Bhalla N, Di Lorenzo M, Pula G, Estrela P. Protein phosphorylation analysis based on proton release detection: Potential tools for drug discovery. *Biosensors and Bioelectronics*. 2014; 54:109-114.
75. Bhalla N, Jolly P, Formisano N, Estrela P. Introduction to biosensors. *Essays Biochem*. 2016; 60(1):1-8.
76. Lee JM, Garon E, Wong DT. Salivary diagnostics. *Orthod Craniofac Res*. 2009; 12(3):206-211.
77. Dong T, Matos Pires NM, Yang Z, Jiang Z. Advances in Electrochemical Biosensors Based on Nanomaterials for Protein Biomarker Detection in Saliva. *Adv Sci (Weinh)*. 2022; 10(6):2205429.
78. Kumari S, Samara M, Ampadi Ramachandran R, Gosh S, George H, Wang R, et al. A Review on Saliva-Based Health Diagnostics: Biomarker Selection and Future Directions. *Biomed Mater Devices*. 2023; 1-18.
79. Janik-Karpinska E, Ceremuga M, Niemcewicz M, Podogrocki M, Stela M,

- Cichon N, et al. Immunosensors-The Future of Pathogen Real-Time Detection. *Sensors (Basel)*. 2022; 22(24):9757.
80. Shetty V, Yamaguchi M. Salivary Biosensors for Screening Trauma Related Psychopathology. *Oral Maxillofac Surg Clin North Am*. 2010; 22(2):269-278.
 81. Goldoni R, Dolci C, Boccalari E, Inchingolo F, Paghi A, Strambini L, et al. Salivary biomarkers of neurodegenerative and demyelinating diseases and biosensors for their detection. *Ageing Research Reviews*. 2022; 76:101587.
 82. Gug IT, Tertis M, Hosu O, Cristea C. Salivary biomarkers detection: Analytical and immunological methods overview. *TrAC Trends in Analytical Chemistry*. 2019; 113:301-316.
 83. Thévenot DR, Toth K, Durst RA, Wilson GS. Electrochemical biosensors: recommended definitions and classification¹International Union of Pure and Applied Chemistry: Physical Chemistry Division, Commission I.7 (Biophysical Chemistry); Analytical Chemistry Division, Commission V.5 (Electroanalytical Chemistry).¹ *Biosensors and Bioelectronics*. 2001; 16(1):121-131.
 84. Bard AJ, Faulkner LR. *Electrochemical methods: fundamentals and applications*. 2nd ed. New York: John Wiley & Sons; 2001.
 85. Cesewski E, Johnson BN. Electrochemical biosensors for pathogen detection. *Biosensors & Bioelectronics*. 2020; 159:112214.
 86. Nilsson NJ. *The Quest for Artificial Intelligence*. 2009 Oct 30.
 87. Hebb DO. Animal and physiological psychology. *Annu Rev Psychol*. 1950; 1:173-188.
 88. Yuan G, Lv B, Hao C. Application of artificial neural networks in reproductive

medicine. *Hum Fertil (Camb)*. 2023; 26(5):1195-1201.

89. Hung KF, Ai QYH, Wong LM, Yeung AWK, Li DTS, Leung YY. Current Applications of Deep Learning and Radiomics on CT and CBCT for Maxillofacial Diseases. *Diagnostics (Basel)*. 2022; 13(1):110.
90. Ramirez Zegarra R, Ghi T. Use of artificial intelligence and deep learning in fetal ultrasound imaging. *Ultrasound in Obstetrics & Gynecology*. 2023; 62(2):185-194.
91. Theodoropoulos P, Spandonidis CC, Giannopoulos F, Fassois S. A Deep Learning-Based Fault Detection Model for Optimization of Shipping Operations and Enhancement of Maritime Safety. *Sensors*. 2021; 21(16):5658.
92. Manickam P, Mariappan SA, Murugesan SM, Hansda S, Kaushik A, Shinde R, et al. Artificial Intelligence (AI) and Internet of Medical Things (IoMT) Assisted Biomedical Systems for Intelligent Healthcare. *Biosensors (Basel)*. 2022; 12(8):562.
93. Visaggi P, Bortoli N de, Barberio B, Savarino V, Oleas R, Rosi EM, et al. Artificial Intelligence in the Diagnosis of Upper Gastrointestinal Diseases. *J Clin Gastroenterol*. 2022; 56(1):23-35.
94. Crossnohere NL, Elsaid M, Paskett J, Bose-Brill S, Bridges JFP. Guidelines for Artificial Intelligence in Medicine: Literature Review and Content Analysis of Frameworks. *J Med Internet Res*. 2022; 24(8):e36823.
95. Liu P, Lu L, Zhang J, Huo T, Liu S, Ye Z. Application of Artificial Intelligence in Medicine: An Overview. *CURR MED SCI*. 2021; 41(6):1105-1115.

96. Porta J. Redes neuronales recurrentes; aprendizaje no supervisado. En: Curso de Redes Neuronales 2019; 2019; Córdoba, Argentina. FAMAFA, UNC.
97. Villafañe J, Mínguez Arranz N. Principios de teoría general de la imagen. Madrid: Ediciones Pirámide; 2002.
98. Celeghin A, Borriero A, Orsenigo D, Diano M, Méndez Guerrero CA, Perotti A, et al. Convolutional neural networks for vision neuroscience: significance, developments, and outstanding issues. *Front Comput Neurosci*. 2023; 17:1153572.
99. Kugunavar S, Prabhakar CJ. Convolutional neural networks for the diagnosis and prognosis of the coronavirus disease pandemic. *Vis Comput Ind Biomed Art*. 2021; 4:12.
100. Naranjo-Torres J, Mora M, Hernández-García R, Barrientos RJ, Fredes C, Valenzuela A. A Review of Convolutional Neural Network Applied to Fruit Image Processing. *Applied Sciences*. 2020; 10(10):3443.
101. Krichen M. Convolutional Neural Networks: A Survey. *Computers*. 2023; 12(8):151.
102. Vakalopoulou M, Christodoulidis S, Burgos N, Colliot O, Lepetit V. Deep Learning: Basics and Convolutional Neural Networks (CNNs). In: Colliot O, editor. *Machine Learning for Brain Disorders* [Internet]. New York, NY: Humana; 2023; 77–115.
103. Lu TC. CNN convolutional layer optimisation based on quantum evolutionary algorithm. *Connection Science*. 2021; 33(3):482-94.
104. Jie HJ, Wanda P. RunPool: A Dynamic Pooling Layer for Convolution Neural Network. *Int J Comput Intell Syst*. 2020; 13(1):66-76.

105. Ouyang W, Xu B, Hou J, Yuan X. Fabric Defect Detection Using Activation Layer Embedded Convolutional Neural Network. *IEEE Access*. 2019; 7:70130-70140.
106. Setiawan W. Character Recognition using Adjustment Convolutional Network with Dropout Layer. *IOP Conf Ser: Mater Sci Eng*. 2021; 1125(1):012049.
107. Zheng T, Wang Q, Shen Y, Lin X. Gradient rectified parameter unit of the fully connected layer in convolutional neural networks. *Knowledge-Based Systems*. 2022; 248:108797.
108. Schwendicke F, Samek W, Krois J. Artificial Intelligence in Dentistry: Chances and Challenges. *J Dent Res*. 2020; 99(7):769-774.
109. Chang H-J, Lee S-J, Yong T-H, Shin N-Y, Jang B-G, Kim J-E, et al. Deep Learning Hybrid Method to Automatically Diagnose Periodontal Bone Loss and Stage Periodontitis. *Sci Rep*. 2020; 10(1):7531.
110. Lee C-T, Kabir T, Nelson J, Sheng S, Meng H-W, Van Dyke TE, et al. Use of the deep learning approach to measure alveolar bone level. *J Clin Periodontol*. 2022; 49(3):260-269.
111. Geetha V, Aprameya KS, Hinduja DM. Dental caries diagnosis in digital radiographs using back-propagation neural network. *Health Inf Sci Syst*. 2020; 8(1):8.
112. Abdalla-Aslan R, Yeshua T, Kabla D, Leichter I, Nadler C. An artificial intelligence system using machine-learning for automatic detection and classification of dental restorations in panoramic radiography. *Oral Surg Oral Med Oral Pathol Oral Radiol*. 2020; 130(5):593-602.
113. Bianchi J, Oliveira Ruellas AC de, Gonçalves JR, Paniagua B, Prieto JC,

- Styner M, et al. Osteoarthritis of the Temporomandibular Joint can be diagnosed earlier using biomarkers and machine learning. *Sci Rep.* 2020; 10:8012.
114. Kim BS, Yeom HG, Lee JH, Shin WS, Yun JP, Jeong SH, et al. Deep Learning-Based Prediction of Paresthesia after Third Molar Extraction: A Preliminary Study. *Diagnostics (Basel).* 2021; 11(9):1572.
115. Liu Z, Liu J, Zhou Z, Zhang Q, Wu H, Zhai G, et al. Differential diagnosis of ameloblastoma and odontogenic keratocyst by machine learning of panoramic radiographs. *International Journal of Computer Assisted Radiology and Surgery.* 2021; 16(3):415.
116. Chau RCW, Li G-H, Tew IM, Thu KM, McGrath C, Lo W-L, et al. Accuracy of Artificial Intelligence-Based Photographic Detection of Gingivitis. *Int Dent J.* 2023; 73(5):724-730.
117. Tobias G, Spanier AB. Using an mHealth App (iGAM) to Reduce Gingivitis Remotely (Part 2): Prospective Observational Study. *JMIR Mhealth Uhealth.* 2021; 9(9):e24955.
118. Li W, Liang Y, Zhang X, Liu C, He L, Miao L, et al. A deep learning approach to automatic gingivitis screening based on classification and localization in RGB photos. *Sci Rep.* 2021; 11:16831.
119. Alalharith DM, Alharthi HM, Alghamdi WM, Alsenbel YM, Aslam N, Khan IU, et al. A Deep Learning-Based Approach for the Detection of Early Signs of Gingivitis in Orthodontic Patients Using Faster Region-Based Convolutional Neural Networks. *International Journal of Environmental Research and Public Health.* 2020; 17(22):8447.
120. Aberin STA, Goma JC de. Detecting Periodontal Disease Using Convolutional

Neural Networks. 2018 IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM). 2018; :1-6.

121. Tabatabaei Balaei A, Chazal P de, Eberhard J, Domnisch H, Spahr A, Ruiz K. Automatic detection of periodontitis using intra-oral images. 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). 2017; :3906–3909.
122. Bravo Pérez M. Epidemiología de las enfermedades gingivo-periodontales. RCOE: Rev Ilustre Consejo General Colegios Odontólogos Estomatólogos España. 2018;23(Supl 1):6–8.
123. Secretaría de Salud. Resultados del Sistema de Vigilancia Epidemiológica de Patologías Bucales (SIVEPAB) 2018. Ciudad de México: Secretaría de Salud, Subsecretaría de Prevención y Promoción de la Salud, Dirección General de Epidemiología; 2019.
124. Ryu J, Lee D-M, Jung Y-H, Kwon O, Park S, Hwang J, et al. Automated Detection of Periodontal Bone Loss Using Deep Learning and Panoramic Radiographs: A Convolutional Neural Network Approach. Applied Sciences. 2023; 13(9):5261.
125. Hasnain MA, Ali Z, Maqbool MS, Aziz M. X-ray Image Analysis for Dental Disease: A Deep Learning Approach Using EfficientNets. VFAST Transactions on Software Engineering. 2024; 12(3):147-165.
126. Chen IDS, Yang C-M, Chen M-J, Chen M-C, Weng R-M, Yeh C-H. Deep Learning-Based Recognition of Periodontitis and Dental Caries in Dental X-ray Images. Bioengineering (Basel). 2023; 10(8):911.

127. Khaleel BI, Aziz MS. Using Artificial Intelligence Methods For Diagnosis Of Gingivitis Diseases. J Phys: Conf Ser. 2021; 1897(1):012027.

ANEXOS

Consentimiento informado

San Agustín Tlaxiaca, a _____ de _____ de 2024

CARTA DE CONSENTIMIENTO INFORMADO

Título de la Investigación: Prototipo de software para la detección de enfermedades inflamatorias del periodonto

Nombre del Investigador Principal: Dra. Jeannet Izquierdo Vega

Nombre del estudiante que está a cargo del proyecto de investigación: Sergio David Pintado Brito

Yo,

manifiesto que fui informado(a) del propósito, procedimientos y tiempo de participación y en pleno uso de mis facultades, es mi voluntad participar en esta investigación. A través de este documento doy mi consentimiento para el uso de las imágenes e información adicional de historia clínica dental, el cual será utilizada para los objetivos del presente proyecto. Comprendo que no se publicará mi nombre y que se mantendrá el anonimato de la identidad en el texto y en las imágenes. Esta autorización incluye la publicación en revistas científicas con idioma español y/o su versión traducida en inglés, impresa, en formato electrónico en el sitio web de la revista.

No omito manifestar que he leído y he sido informado(a) en forma clara, precisa y amplia, respecto al procedimiento solicitado en esta investigación, el cual no representan ni implican ningún tipo de riesgo. Adicionalmente todas mis preguntas e inquietudes han sido respondidas de manera clara y a mi entera satisfacción.

FIRMA DEL CONSENTIMIENTO

NOMBRE Y
FIRMA DEL PARTICIPANTE

NOMBRE Y
FIRMA DEL INVESTIGADOR PRINCIPAL
E:mail ivega@uaeh.edu.mx

TESTIGOS

NOMBRE Y FIRMA

NOMBRE Y FIRMA

Nota: Los datos personales contenidos en la presente Carta de Consentimiento Informado, serán protegidos conforme a lo dispuesto en las Leyes Federal de Transparencia y Acceso a la Información Pública, General de Transparencia y Acceso a la Información Pública y General de Protección de Datos Personales en Posesión de Sujetos Obligados y demás normatividad aplicable en la materia.

San Agustín Tlaxiaca, a _____ de _____ de 2025.

Consentimiento informado

CARTA DE CONSENTIMIENTO INFORMADO

Título de la Investigación: Presencia de metaloproteasa 8 en la identificación de enfermedades inflamatorias del periodonto, validación de prototipo de software.

Nombre del Investigador Principal: Dra. Jeannet Alejandra Izquierdo Vega.

Nombre del estudiante que está a cargo del proyecto de investigación: Ing. Sergio David Pintado Brito.

Yo, _____, manifiesto que he sido debidamente informado(a) sobre el propósito del proyecto de investigación. En pleno uso de mis facultades, consiento voluntariamente participar en este estudio. A través de este documento, autorizo expresamente la toma de una muestra de saliva, mediante un procedimiento rápido, no invasivo y cuya valoración sobre la inflamación del periodonto se llevará a cabo por un especialista capacitado, garantizando las condiciones adecuadas de higiene y seguridad. Se me ha informado que la saliva permite identificar enzimas, marcadores inflamatorios y otros elementos cuya presencia puede estar relacionada con diferentes grados de enfermedad periodontal. En particular, se analizará en la saliva la metaloproteasa de matriz tipo 8 (MMP-8), una enzima cuya elevación ha sido asociada con procesos inflamatorios periodontales. Este análisis constituye una herramienta valiosa para el diagnóstico clínico.

Asimismo, autorizo el uso de imágenes intraorales y de información complementaria de mi historia clínica dental, exclusivamente para los fines de esta investigación. Se me ha asegurado que mi identidad será protegida en todo momento: no se publicará mi nombre y se garantizará el anonimato tanto en el texto como en las imágenes. Esta autorización incluye la posibilidad de publicación de los resultados en revistas científicas (en español y/o inglés), ya sea en formato impreso o electrónico.

Declaro haber recibido información clara, suficiente y comprensible sobre el procedimiento, el cual no representa ningún riesgo para mi salud. Todas mis preguntas e inquietudes han sido atendidas y respondidas satisfactoriamente.

FIRMA DEL CONSENTIMIENTO

NOMBRE
Y
FIRMA DEL PARTICIPANTE

NOMBRE Y
FIRMA DEL INVESTIGADOR PRINCIPAL

E:mail ivega@uaeh.edu.mx

TESTIGOS

NOMBRE Y FIRMA

NOMBRE Y FIRMA

Nota: Los datos personales contenidos en la presente Carta de Consentimiento Informado, serán protegidos conforme a lo dispuesto en las Leyes Federal de Transparencia y Acceso a la Información Pública, General de Transparencia y Acceso a la Información Pública y General de Protección de Datos Personales en Posesión de Sujetos Obligados y demás normatividad aplicable en la materia.