

UNIVERSIDAD CATÓLICA SANTO TORIBIO DE MOGROVEJO
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA DE SISTEMAS Y COMPUTACIÓN



**Sistema inteligente para la detección de lesiones de la mucosa oral en un
centro de salud**

**TESIS PARA OPTAR EL TÍTULO DE
INGENIERO DE SISTEMAS Y COMPUTACIÓN**

AUTOR

Mauricio Benjamin Durand Calle

ASESOR

Roger Ernesto Alarcon Garcia

<https://orcid.org/0000-0003-1178-0519>

Chiclayo, 2026

**Sistema inteligente para la detección de lesiones de la mucosa oral en
un centro de salud**

PRESENTADA POR

Mauricio Benjamin Durand Calle

A la Facultad de Ingeniería de la
Universidad Católica Santo Toribio de Mogrovejo
para optar el título de

INGENIERO DE SISTEMAS Y COMPUTACIÓN

APROBADA POR

Miguel Orlando Diaz Vidarte

PRESIDENTE

Gregorio Manuel León Tenorio

SECRETARIO

Roger Ernesto Alarcon Garcia

VOCAL

Dedicatoria

A mi padre Antonio, por su inquebrantable apoyo y sacrificio constante; a mi madre Bertha, que desde el cielo guía mis pasos; y a mi hermano Sebastián, compañero incondicional en este viaje universitario.

Agradecimiento

A mi asesor, Dr. Roger Ernesto Alarcón García, por su orientación, dedicación y valioso apoyo durante el desarrollo del presente proyecto de investigación.

A la vez, agradecer al Centro de Salud "Villa Hermosa" por permitir la implementación de esta tesis en sus instalaciones.

Un agradecimiento especial al Dr. Hans Flores, por su colaboración profesional y aportes desde su experiencia en el campo odontológico, contribuyendo significativamente al éxito de este trabajo.

Sistema inteligente para la detección de lesiones de la mucosa oral en un centro de salud

INFORME DE ORIGINALIDAD

7 %	7 %	1 %	3 %
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	tesis.usat.edu.pe Fuente de Internet	2 %
2	Submitted to Universidad Católica Santo Toribio de Mogrovejo Trabajo del estudiante	1 %
3	hdl.handle.net Fuente de Internet	1 %
4	repositorio.uss.edu.pe Fuente de Internet	<1 %
5	repositorio.ucsm.edu.pe Fuente de Internet	<1 %
6	doaj.org Fuente de Internet	<1 %
7	repositorio.xoc.uam.mx Fuente de Internet	<1 %
8	Submitted to Universidad de Deusto Trabajo del estudiante	<1 %

Índice

Resumen	6
Abstract	7
Introducción.....	8
Revisión de literatura.....	10
Materiales y métodos	14
Resultados y discusión	20
Conclusiones	27
Recomendaciones	27
Referencias.....	28
Anexos	31

Resumen

La investigación abordó la problemática del diagnóstico tardío y el mal diagnóstico de lesiones de la mucosa oral, una situación crítica en países de ingresos medios y bajos donde 3.5 mil millones de personas padecen enfermedades bucodentales. En Perú, el cáncer bucal ocupa el sexto lugar entre las causas de muerte por neoplasias, debido principalmente a la falta de detección oportuna y diagnósticos inadecuados. Por ello se desarrolló un sistema basado en redes neuronales convolucionales para la detección automática de lesiones de la mucosa oral a través del análisis de imágenes. El proyecto se estructuró siguiendo las metodologías SCRUM y CRISP-DM, cubriendo desde la preparación tecnológica hasta la optimización del modelo. Para garantizar la calidad del dataset clínico, se evaluó la concordancia en el etiquetado mediante el índice de Cohen's Kappa, obteniéndose un valor de $\kappa=0.694$ que indica un acuerdo considerable entre evaluadores. Respecto al componente técnico, se implementó el modelo SSD-MobileNet-V2-FPNLite-320 para la detección de gingivitis, entrenado con 362 imágenes, logrando una precisión del 97.3%, sensibilidad del 64.0%, F1-Score de 77.2% y una exactitud global de 62.9%. Complementariamente, se incorporó la detección de aftas orales mediante YOLO11s, empleando 386 imágenes, logrando una precisión del 67.83%, sensibilidad del 82.9%, F1-Score de 74.62% y exactitud de 59.54%. El sistema integral incluye gestión odontológica y modelos predictivos. La validación del sistema, basada en la metodología TAM2, reveló aceptación sobresaliente (98.33%), destacando facilidad de uso percibida (100%) sobre utilidad percibida (96.67%), confirmando su aplicabilidad práctica en entornos clínicos reales.

Palabras clave: Detección de lesiones orales, mucosa oral, redes neuronales convolucionales, SSD-MobileNet, YOLO11s, salud bucodental, sistemas inteligentes de salud.

Abstract

The research addressed the problem of late diagnosis and misdiagnosis of oral mucosal lesions, a critical situation in low- and middle-income countries where 3.5 billion people suffer from oral diseases. In Peru, oral cancer ranks sixth among causes of death from neoplasms, mainly due to a lack of timely detection and inadequate diagnoses. For this reason, a system based on convolutional neural networks was developed for the automatic detection of oral mucosal lesions through image analysis. The project was structured following the SCRUM and CRISP-DM methodologies, covering everything from technological preparation to model optimization. To ensure the quality of the clinical dataset, labeling concordance was evaluated using Cohen's Kappa index, obtaining a value of $\kappa=0.694$, which indicates considerable agreement among evaluators. Regarding the technical component, the SSD-MobileNet-V2-FPNLite-320 model was implemented for the detection of gingivitis, trained with 362 images, achieving an accuracy of 97.3%, sensitivity of 64.0%, F1-Score of 77.2%, and an overall accuracy of 62.9%. In addition, oral ulcer detection was incorporated using YOLO11s, employing 386 images, achieving an accuracy of 67.83%, sensitivity of 82.9%, F1-Score of 74.62%, and accuracy of 59.54%. The comprehensive system includes dental management and predictive models. Validation of the system, based on the TAM2 methodology, revealed outstanding acceptance (98.33%), highlighting perceived ease of use (100%) over perceived usefulness (96.67%), confirming its practical applicability in real clinical settings.

Keywords: Oral lesion detection, oral mucosa, convolutional neural networks, SSD-MobileNet, YOLO11s, oral health, intelligent health systems.

Introducción

El diagnóstico tardío del cáncer oral representa un desafío persistente en salud bucodental, principalmente debido a su naturaleza asintomática inicial y la ausencia de exámenes preventivos en pacientes con factores de riesgo [1]. Simultáneamente, los profesionales odontológicos frecuentemente carecen de recursos para tomar decisiones clínicas adecuadas [2], situación alarmante considerando que la detección temprana resulta fundamental para optimizar el tratamiento y la supervivencia, actualmente cercana al 50% para cánceres orofaríngeos [3].

A nivel mundial, aproximadamente 3,5 mil millones de personas padecen afecciones bucodentales, con mayor prevalencia en países de ingresos medios y bajos [4]. Esta situación se evidencia en países como India, donde el 85% de la población rural carece de servicios odontológicos adecuados [5]; España, con un 85% de adultos presentando al menos un problema bucodental [6]; y Tanzania, con apenas un odontólogo por cada 10,000 habitantes [7].

En el contexto peruano, la caries dental afecta a nueve de cada diez niños [8], mientras que las enfermedades periodontales impactan al 52.5% de escolares entre 10 y 15 años [9]. No obstante, solo el 26.7% de los menores de 12 años recibe atención odontológica, con notables diferencias entre áreas urbanas y rurales [10]. Por consiguiente, el cáncer bucal constituye la sexta causa de muerte por neoplasias, principalmente debido a la falta de concientización pública [11].

La región Lambayeque presenta una situación igualmente preocupante, con nueve de cada diez habitantes sufriendo problemas orales [12]. Particularmente, en el Centro de Salud "Villa Hermosa", donde se encuentran los objetos de estudio de la presente investigación, se ha observado un incremento alarmante en los casos de lesiones orales, duplicándose respecto al año anterior.

Las causas del mal diagnóstico de lesiones de la mucosa oral son multifactoriales, incluyendo anamnesis insuficiente, falta de consideración de factores generales, ausencia de pruebas complementarias y carencia de experiencia profesional [13]. Así pues, estas enfermedades afectan desproporcionadamente a poblaciones vulnerables, existiendo clara correlación entre situación socioeconómica y gravedad de las afecciones [14].

Las consecuencias de las lesiones orales trascienden la salud bucal, asociándose con enfermedades sistémicas graves como diabetes, infartos y Alzheimer [15]. De igual manera, pueden incrementar el riesgo de complicaciones durante el embarazo y disfunción eréctil [15], además de problemas de personalidad relacionados con neuroticismo y extroversión [16].

El Centro de Salud "Villa Hermosa", que atiende semanalmente a aproximadamente 300 pacientes, enfrenta desafíos particulares en el área de Salud Bucal, con una afluencia mínima de 60 pacientes semanales y un equipo reducido de dos odontólogos y un practicante.

Teniendo en cuenta esta situación, el presente estudio plantea: ¿Cómo apoyar en la detección de lesiones de la mucosa oral en un centro de salud con escasez de personal y desafíos profesionales? A través de la implementación de un sistema inteligente que resulta esencial para mejorar el acceso a atención médica oportuna, especialmente considerando las limitaciones de recursos en zonas rurales.

La implementación de este sistema inteligente se justifica desde múltiples perspectivas: científicamente, pionero en aplicación de IA y redes neuronales convolucionales en odontología para revelar patrones invisibles en lesiones de mucosa oral; socialmente, proporciona diagnóstico temprano que mejora la salud bucal de pacientes y optimiza el trabajo médico en zonas rurales con recursos limitados; económicamente, incrementa la eficiencia diagnóstica reduciendo costos por errores y pruebas innecesarias; y tecnológicamente, aprovecha avances en procesamiento de imágenes para mayor precisión y velocidad diagnóstica.

Por consiguiente, el objetivo principal es desarrollar un sistema inteligente basado en redes neuronales convolucionales para la detección automática de lesiones de la mucosa oral a través del análisis de imágenes en un centro de salud. Para alcanzar este propósito, se establecen los siguientes objetivos específicos:

- Establecer un dataset de imágenes clínicas de lesiones de la mucosa oral para entrenamiento y validación del sistema.
- Alcanzar una calidad aceptable del sistema inteligente a través de métricas para garantizar su funcionamiento adecuado.
- Evaluar la usabilidad del sistema para asegurar su aceptación en el servicio odontológico.

Frente a esta problemática, la inteligencia artificial (IA) emerge como herramienta prometedora para diagnósticos más precisos [17], con recientes investigaciones desarrollando modelos de deep learning para detectar caries proximales en radiografías dentales [18] y enfoques de aprendizaje profundo para el diagnóstico de problemas dentales [19]. En cuanto a investigaciones previas, Liyanage et al. [21] desarrollaron modelos basados en MobileNetV3 y EfficientNetV2 para la identificación de lesiones orales, alcanzando precisiones del 80% y 82% respectivamente en lesiones premalignas/malignas, e integrándolos en una aplicación móvil para facilitar el tamizaje remoto. De manera similar, Warin et al. [22] evaluaron diversos modelos de redes neuronales convolucionales para la detección temprana del carcinoma oral,

logrando resultados sobresalientes con DenseNet-169 y ResNet-101 (AUC de 1.00 y 0.98 respectivamente), superando incluso el desempeño de especialistas certificados. Por su parte, Hernandez Olazabal [23] implementó un sistema inteligente basado en reconocimiento de imágenes para la identificación de caries mediante redes neuronales convolucionales, obteniendo un 99% de validación del modelo y un 97% de precisión en entrenamiento.

Con respecto a nuestro estudio, se obtuvo una precisión del 97.3% en la detección de gingivitis y del 67.8% en aftas orales, probando ser un sistema muy efectivo. La aceptación del personal odontológico fue sobresaliente, con una valoración de usabilidad de 98.33% y una facilidad de uso percibida de 100%. Estos hallazgos respaldan que este sistema contribuye a un diagnóstico temprano de lesiones orales, a la vez que ofrece formación continua y reportes al personal médico junto a su análisis clínico.

Revisión de literatura

Esmailyfard et al. [20] experimentaron la eficacia de los algoritmos de aprendizaje profundo para el diagnóstico y la clasificación de la caries dental a partir de imágenes CBCT. Su investigación empleó redes neuronales convolucionales con arquitectura de múltiples entradas en un conjunto de datos de 819 imágenes, clasificando la caries según su ubicación y profundidad. Los resultados fueron significativos, ya que se logró una tasa de precisión del 95,3 % en la detección, una sensibilidad del 92,1 %, una especificidad del 96,3 % y una puntuación F1 del 93,2 %. Es destacable que las caries profundas (D3) fueron identificadas con mayor eficacia, con una precisión del 96,2 %. Este estudio respalda la afirmación de que las tecnologías de aprendizaje profundo son herramientas eficaces para la clasificación y detección de la caries dental.

Liyanage et al. [21] abordaron el problema del acceso limitado a expertos en poblaciones remotas o de alto riesgo. Su estudio comparó dos arquitecturas de redes neuronales profundas, MobileNetV3 y EfficientNetV2, entrenadas con 342 imágenes clasificadas en tres clases: lesiones no neoplásicas, neoplasias benignas y lesiones premalignas/malignas. Los modelos tuvieron una precisión del 80 % y del 82 %, respectivamente, en la detección de lesiones premalignas o malignas, pero tuvieron menos éxito (64 %) en el diagnóstico de lesiones no malignas. Los investigadores incorporaron los modelos a una aplicación móvil, lo cual fue una herramienta eficaz para la detección remota de lesiones orales y resultaría especialmente útil en zonas con recursos limitados.

Warin et al. [22] se enfocaron en mejorar la detección temprana del carcinoma oral de células escamosas (OSCC) y los trastornos potencialmente malignos orales (OPMD), condiciones que

suelen pasar desapercibidas en evaluaciones realizadas por médicos no especialistas. Los investigadores evaluaron diversos modelos de redes neuronales convolucionales profundas, tanto para clasificación (Swin-S, SqueezeNet, ResNet-101 y DenseNet-169) como para detección de objetos (CenterNet2, RetinaNet, YOLOv5 y Faster R-CNN), utilizando 980 imágenes de OSCC, OPMD y tejidos sanos. Los resultados fueron sobresalientes, con los modelos DenseNet-169 y ResNet-101 alcanzando un AUC de 1.00 y 0.98 respectivamente en la clasificación, superando incluso el desempeño de especialistas certificados. En la detección de objetos, Faster R-CNN obtuvo el mejor rendimiento con un AUC de 0.88 para OSCC y 0.64 para OPMD, demostrando el potencial de las CNN como herramientas de asistencia diagnóstica para la detección temprana del cáncer oral.

Hernandez Olazabal [23] abordó la problemática del control insuficiente en el diagnóstico individual de enfermedades bucodentales y la falta de herramientas para la evaluación rápida de la condición oral. Su propuesta consistió en un sistema inteligente basado en reconocimiento de imágenes para la identificación de caries, utilizando redes neuronales convolucionales. Los resultados fueron altamente prometedores, con un 99% de validación del modelo y un 97% de precisión en entrenamiento, confirmando el potencial de estos sistemas para complementar la evaluación clínica tradicional.

Castro Díaz [24] centró su interés en el reto que supone el diagnóstico subjetivo de la periodontitis, una enfermedad crónica que afecta a los tejidos de soporte dental. El investigador propuso un modelo basado en clasificadores difusos que tiene en cuenta diversas variables clínicas, como el sangrado gingival, la movilidad dental y la profundidad de sondaje. Entre los múltiples clasificadores analizados, el modelo de Red Neuronal Fuzzy Min-Max exhibió el rendimiento más destacado, logrando una precisión del 89,58 % y una exactitud del 86,11 %, lo que lo convierte en un recurso significativo para respaldar el diagnóstico clínico de esta enfermedad periodontal.

Bases teóricas

Lesiones de la mucosa oral

Conjunto variado de trastornos. Su diagnóstico diferencial es clave por sus implicaciones pronósticas y los diferentes niveles de benignidad o malignidad, que guían el tratamiento adecuado [25].

Gingivitis

Grupo variado de patologías que se define por su limitación al tejido gingival y tiene múltiples etiologías [26].

Gingivitis generalizada

Se caracteriza por afectar a la encía de todos los dientes, con una inflamación generalizada sin límites definidos [26]. Esta manifestación suele estar asociada a factores sistémicos o a una higiene bucal inadecuada que afecta a toda la cavidad oral.

Gingivitis localizada

Afecta solo a determinadas zonas de la encía, como una zona marginal concreta o una región específica, y se caracteriza por una restricción de la inflamación a esa zona [26]. Su manifestación suele estar asociada a factores etiológicos locales, como traumatismos, depósito de biofilm en una región concreta o restauraciones defectuosas.

Afta oral

Lesiones ulcerosas dolorosas de la mucosa oral, típicamente redondas u ovales, con un centro blanco y bordes rojos. De naturaleza multifactorial, implican estrés, traumatismos, deficiencias nutricionales y alteraciones endocrinas e inmunológicas [27].

Afta menor

Lesiones superficiales pequeñas (<1 cm), que no dejan cicatrices y desaparecen espontáneamente en una o dos semanas [27].

Afta mayor

Lesiones profundas de más de 1 cm, que pueden persistir semanas, causar dolor intenso y dejar cicatriz tras la cicatrización [27].

Inteligencia artificial (IA)

La IA es la habilidad de las máquinas para realizar actividades que normalmente demandan inteligencia humana. Esta tecnología facilita el procesamiento continuo de grandes cantidades de datos con una precisión notablemente superior a la de los humanos [28].

Sistema inteligente

Este concepto hace referencia a la capacidad de una máquina o entidad artificial para realizar actividades cognitivas de manera similar a como lo haría un ser humano, siguiendo los principios propuestos por Alan Turing en su famosa prueba formulada en 1950 [29].

Base de conocimiento

Consiste en una colección estructurada de hechos, reglas, conceptos y relaciones que representan el conocimiento específico sobre un dominio determinado. Este componente contiene la información fundamental que el sistema necesita para razonar adecuadamente y tomar decisiones [30].

Módulo de razonamiento

Se refiere al componente responsable de extraer inferencias y llegar a conclusiones lógicamente válidas a partir de la información ya incorporada a la base de conocimientos del sistema [31].

Machine learning (ML)

Estrategia dentro del campo de la inteligencia artificial, en la que los sistemas informáticos adquieren la capacidad de aprender sin necesidad de una programación explícita para cada tarea. Este método utiliza algoritmos implementados con fines específicos para reconocer patrones de grupos de datos y tomar decisiones basadas en dichos patrones [28].

Datos de entrenamiento

Conjuntos de ejemplos cuidadosamente seleccionados que se utilizan para enseñar al modelo a realizar una tarea específica. La calidad, la cantidad y la representatividad de estos datos son factores críticos para el éxito del modelo obtenido [32].

Algoritmo de aprendizaje

Se entiende en términos matemáticos que permiten a los modelos de aprendizaje automático identificar patrones útiles y realizar predicciones precisas basadas en la información disponible [33].

Modelo de aprendizaje automático

Es la representación matemática de un problema del mundo real. Este modelo se ajusta utilizando datos específicos con el fin de reconocer patrones y luego se utiliza para hacer predicciones o tomar decisiones sin una programación explícita para cada situación [32].

Deep learning (DL)

Rama del aprendizaje automático que implica el uso de sofisticadas redes neuronales para resolver problemas complejos, identificando patrones en cantidades masivas de datos [28].

Redes neuronales artificiales (RNA)

Son sistemas computacionales inspirados en el funcionamiento y la estructura de las neuronas biológicas, diseñados para abordar una amplia gama de problemas. Están formadas por unidades de procesamiento (neuronas) dispuestas en capas: de entrada, ocultas y de salida [33].

Redes neuronales convolucionales (CNN)

Representan una forma sofisticada de redes neuronales basada en el diseño tradicional de la corteza visual animal, con la peculiaridad de demostrar una alta eficiencia en el análisis y procesamiento de imágenes. Son eficaces debido a que cada componente de la red se entrena por separado para realizar una tarea específica, lo que reduce significativamente el número de capas ocultas necesarias y agiliza el proceso de entrenamiento [33].

Materiales y métodos

Tipo de investigación

El presente estudio se llevó a cabo desde un enfoque aplicado, de acuerdo con las normas estipuladas en el Manual de Frascatti. El estudio se centró en la aplicación de un sistema inteligente que reconociera específicamente las lesiones orales en los pacientes.

Población

La población estuvo constituida por todas las imágenes clínicas de lesiones de la mucosa oral recopiladas en el centro de salud durante el periodo de estudio, así como las imágenes disponibles en bases de datos públicas especializadas en patología oral.

Muestra

Se utilizó un muestreo no probabilístico por conveniencia, seleccionando un conjunto de imágenes que cumplieron con los criterios de inclusión establecidos para el entrenamiento y validación del modelo de inteligencia artificial.

Criterios de selección

Criterios de inclusión:

- Imágenes clínicas de lesiones de la mucosa oral con diagnóstico confirmado
- Imágenes con calidad técnica adecuada (resolución mínima, iluminación apropiada)
- Imágenes debidamente etiquetadas por profesionales especializados

Criterios de exclusión:

- Imágenes con calidad técnica deficiente
- Imágenes sin diagnóstico confirmado
- Imágenes duplicadas o con información incompleta

Variables

Variable independiente

Sistema inteligente basado en redes neuronales convolucionales para la detección de lesiones de la mucosa oral.

Variable dependiente

Nivel de detección de lesiones de la mucosa oral, medido a través de métricas de rendimiento del sistema (precisión, recall, exactitud, F1-score).

Métodos de investigación

TABLA I

MÉTODOS DE INVESTIGACIÓN

Método	Sustento por el cual será empleado en la investigación
Analítico	Es fundamental examinar los diversos factores que puedan influir en la detección de lesiones orales en el entorno del centro de salud.
Deductivo	Es fundamental para establecer estrategias de solución a los problemas identificados
Revisión de la literatura	Es fundamental recopilar información relevante sobre estudios y proyectos relacionados con la detección de lesiones orales
Implementación	Implementación de un sistema inteligente basado en redes neuronales convolucionales para apoyar la detección de lesiones orales

Técnicas e instrumentos de recolección de datos

TABLA II

TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS

Técnicas	Instrumentos
Análisis de literatura	Documentación importante al proyecto
Observación	Reporte o guía de observación
Entrevista	Reporte de entrevista

Procedimientos

TABLA III
PROCEDIMIENTOS

Etapa	Actividad	Descripción
1	Recolección de datos	Obtención de imágenes clínicas de lesiones de la mucosa oral del centro de salud y bases de datos públicas especializadas
2	Preprocesamiento	Normalización, redimensionamiento y preparación de las imágenes para el entrenamiento del modelo
3	Etiquetado y validación	Clasificación de las imágenes por panel de expertos y validación de la calidad del etiquetado mediante Cohen's Kappa
4	Entrenamiento del modelo	Implementación y entrenamiento de la red neuronal convolucional con el dataset preparado
5	Validación del sistema	Evaluación del rendimiento del modelo mediante métricas de precisión, recall, exactitud y F1-score
6	Implementación	Despliegue del sistema inteligente en el entorno clínico del centro de salud
7	Evaluación de usabilidad	Aplicación del Modelo de Aceptación Tecnológica (TAM2) al personal odontológico

Estrategia de análisis de datos

TABLA IV
ESTRATEGIA DE ANÁLISIS DE DATOS

Tipo de análisis	Técnica/Método	Propósito
Análisis descriptivo	Estadística descriptiva del dataset	Caracterizar la distribución de tipos de lesiones y calidad de imágenes
Validación de etiquetado	Índice Kappa de Cohen	Medir la concordancia entre expertos en el etiquetado de imágenes
Evaluación del modelo	Métricas de clasificación	Calcular precisión, recall, exactitud y F1-score del sistema inteligente
Análisis de usabilidad	Modelo TAM2	Evaluar facilidad de uso percibida y utilidad percibida del sistema

Aspectos éticos

TABLA V
ASPECTOS ÉTICOS

Aspecto ético	Descripción	Medida implementada
Anonimización de datos	Protección de identidad de pacientes	Eliminación de datos identificables de todas las imágenes clínicas utilizadas
Confidencialidad	Protección de información sensible	Acceso restringido a los datos y almacenamiento seguro
Uso exclusivo para investigación	Limitación del uso de datos	Compromiso de utilizar los datos únicamente para fines de investigación

Matriz de consistencia

TABLA VI
MATRIZ DE CONSISTENCIA

<u>Formulación del problema</u>	<u>Metodología de investigación</u>	
¿Cómo apoyar en la detección de lesiones de la mucosa oral en un centro de salud con escasez de personal y desafíos profesionales?	<u>Tipo de investigación</u> Investigación aplicada	
<u>Objetivo General</u>	<u>Método</u>	<u>Descripción</u>
Desarrollar un sistema inteligente basado en redes neuronales convolucionales para la detección automática de lesiones de la mucosa oral a través del análisis de imágenes	Analítico	Es fundamental examinar los diversos factores que puedan influir en la detección de lesiones orales en el entorno del centro de salud.
	Deductivo	Es fundamental para establecer estrategias de solución a los problemas identificados
	Revisión de la literatura	Es fundamental recopilar información relevante sobre estudios y proyectos relacionados con la detección de lesiones orales
	<u>Técnicas</u>	<u>Instrumentos</u>
	Análisis de literatura	Documentación importante al proyecto
	Observación	Reporte o guía de observación
	Entrevista	Reporte de entrevista
<u>Objetivos específicos</u>	<u>Medio de verificación</u>	<u>Indicador objetivamente verificable</u>

Establecer un dataset de imágenes clínicas de lesiones de la mucosa oral para entrenamiento y validación del sistema.	Test de validación basado en las métricas de Cohen's Kappa	Índice Kappa de Cohen Porcentaje de concordancia
Alcanzar una calidad aceptable del sistema inteligente a través de métricas para garantizar su funcionamiento adecuado.	Informe de calidad del sistema inteligente	Métricas de evaluación: Recall, Precisión, Exactitud, F1 score
Evaluar la usabilidad del sistema inteligente para asegurar su aceptación en el servicio odontológico del centro de salud	Encuesta de usabilidad del sistema inteligente basada en el Modelo de Aceptación Tecnológica (TAM2)	Nivel de facilidad de uso percibida del sistema inteligente Nivel de utilidad percibida del sistema inteligente

Resultados y discusión

1. En base a la metodología utilizada

Sprints 0 al 2 – Comprensión y preparación de los datos (CRISP-DM: Comprensión del negocio, comprensión de los datos y preparación de datos)

Se definieron los objetivos clínicos y las métricas mínimas del sistema (precisión $\geq 60\%$, tiempo de procesamiento ≤ 10 s). Se recopilaron 261 imágenes clínicas, se evaluó su calidad, se identificaron sesgos, se llevó a cabo una limpieza y etiquetado con validación médica, y se obtuvieron 249 imágenes listas para su uso. Se ejecutó un análisis exhaustivo del conjunto de datos clínicos, que originalmente estaba compuesto por 261 imágenes recopiladas en el centro de salud y otras fuentes, y se detectaron desequilibrios y variaciones en la calidad.

Sprints 3, 8 y 11 – Modelado y optimización del modelo (CRISP-DM: Modelado)

Se desarrollaron modelos de detección basados en redes neuronales convolucionales optimizados para cada tipo de lesión: SSD-MobileNet-V2-FPNLite-320 para gingivitis y YOLO11s para aftas orales. Se utilizó Google Colaboratory Pro con entorno A100 para un entrenamiento robusto, con datasets balanceados (80%-10%-10% para entrenamiento, validación y prueba). El modelo SSD-MobileNet-V2 alcanzó una precisión de 97.3%, sensibilidad del 64.0%, F1-score de 77.2% y exactitud del 62.9%. Por su parte, YOLO11s mostró precisión del 67.8%, sensibilidad del 82.98%, F1-score de 74.62% y exactitud del 59.54%. Estas métricas reflejan un desempeño satisfactorio con margen de mejora, especialmente en sensibilidad para lograr una detección más completa.

TABLA VIII

PARÁMETROS DE CONFIGURACIÓN DE LOS MODELOS ENTRENADOS

Parámetro	SSD-MobileNet-V2-FPNLite-320	Justificación técnica	YOLO11s	Justificación técnica
Arquitectura	SSD-MobileNet-V2-FPNLite-320	Optimizada para dispositivos con recursos limitados	YOLO11s	Equilibrio óptimo entre velocidad de inferencia y precisión
Resolución de entrada	320x320 píxeles	Balance de precisión	entre 640x640 y píxeles	Permite detección detallada manteniendo eficiencia

		velocidad de procesamiento			
Batch size	4 imágenes	Actualización frecuente de pesos para mejor convergencia	16 imágenes		Balance entre uso de memoria y estabilidad en el entrenamiento
Pasos de entrenamiento	28,000	Suficientes iteraciones para aprendizaje de patrones complejos	40 épocas		Suficiente para convergencia con dataset especializado
Muestreo parcial	2	Aceleración del proceso de validación	Label Studio		Facilita anotaciones precisas y diferenciación de clases

TABLA IX

MÉTRICAS DE RENDIMIENTO DEL MODELO SSD-MOBILENET-V2

Métrica	Valor obtenido	Interpretación
Pérdida de clasificación	0.0319	Excelente capacidad de clasificación de lesiones
Pérdida de localización	0.0075	Alta precisión en ubicación de lesiones
Pérdida de regularización	0.0525	Control adecuado del sobreajuste
Pérdida total	0.0919	Convergencia exitosa del modelo
Tasa de aprendizaje	0.0336	Optimización estable del algoritmo

TABLA X

MÉTRICAS DE RENDIMIENTO DEL MODELO YOLO11S

Métrica	Valor obtenido	Interpretación
Pérdida de Caja	1.3765	Adecuada localización de cajas delimitadoras
Pérdida de Clasificación	0.8578	Correcta clasificación de clases
Pérdida DFL	1.4259	Control del aprendizaje focal distribuido

Pérdida total	3.6602	Balance general del entrenamiento
Tasa de aprendizaje	6.95e-05	Optimización fina y estable

Sprint 4-7, 10 y 12 - Infraestructura y funcionalidades clínicas

La aplicación web se desarrolló con Flask y MySQL como infraestructura backend, con un robusto sistema de autenticación y gestión de sesiones integrado. Se estableció un CRUD completo para la gestión de fichas odontológicas con capacidad de carga de imágenes y firmas digitales, junto con módulos orientados a la visualización estadística con gráficos interactivos para facilitar el análisis epidemiológico. Se incluyó un odontograma digital interactivo para facilitar el registro gráfico de las condiciones bucodentales y permitir la visualización en tiempo real de los resultados de la detección. También se creó un sistema de seguimiento longitudinal para evaluar la trayectoria dental de los pacientes mediante búsquedas por número de documento de identidad, consolidando el sistema como una herramienta integral para el seguimiento y diagnóstico clínico.

TABLA XI

ARQUITECTURA TECNOLÓGICA IMPLEMENTADA

Componente	Tecnología seleccionada	Justificación
Modelo de predicción	Python + TensorFlow/Keras + YOLO11s	Capacidades avanzadas para procesamiento de imágenes médicas
Entorno de desarrollo	Google Colaboratory Pro (A100)	Mayor capacidad computacional para entrenamiento
Desarrollo web	Flask + HTML/CSS/JavaScript	Framework ligero y eficiente para aplicaciones médicas
Base de datos	MySQL	Integración robusta y seguridad de datos clínicos
Etiquetado de imágenes	LabelImg + Label Studio	Herramienta especializada para anotación de imágenes médicas

Sprint 9 – Evaluación del sistema (CRISP-DM: Evaluación)

La usabilidad y la aceptación del sistema se evaluaron mediante el Modelo de Aceptación de la Tecnología (TAM2), aplicado entre los profesionales odontológicos del centro de salud.

concordancia entre evaluadores considerando el acuerdo más allá del azar. En una muestra representativa de 300 casos seleccionadas de un total inicial de 824 imágenes, se observó una proporción de acuerdo observada (P_o) de 0.9333 y una proporción esperada por azar (P_e) de 0.7796, resultando en un valor de $\kappa = 0.694$, que indica un acuerdo considerable según la escala estándar. En esta muestra, ambos evaluadores detectaron lesión en 240 casos y coincidieron en la ausencia de lesión en 20 casos, mientras que en 40 casos hubo discrepancias que fueron revisadas para consenso con un evaluador experto. Tras este proceso, se depuraron 76 imágenes por baja calidad, dificultades diagnósticas o ausencia de lesiones, quedando un dataset final de 748 imágenes (362 de gingivitis y 386 de aftas orales) con alta calidad y etiquetado confiable, que sirvió para el entrenamiento y validación del sistema.

Objetivo específico 02: Alcanzar una calidad aceptable del sistema inteligente a través de métricas para garantizar su funcionamiento adecuado

Se utilizó una metodología de validación basada en la partición del dataset en subconjuntos de entrenamiento, validación y prueba con distribuciones aproximadas del 80%-10%-10%, ajustadas para cada tipo de lesión: 362 imágenes para gingivitis y 386 para aftas orales. Para la detección de gingivitis se empleó el modelo SSD-MobileNet-V2-FPNLite-320, mientras que para aftas orales se usó YOLO11s, ambos evaluados con métricas estándar de precisión, sensibilidad (recall), F1-Score y exactitud, además del análisis de matrices de confusión.

El modelo SSD-MobileNet-V2 para gingivitis alcanzó una precisión del 97.3%, sensibilidad del 64.0%, F1-Score de 77.2% y exactitud de 62.9%, con 144 verdaderos positivos, 4 falsos positivos, 81 falsos negativos y ausencia de verdaderos negativos

TABLA XII

TABLA DE MÉTRICAS DE RENDIMIENTO DEL MODELO SSS-MOBILENET-V2

Métrica	Valor	Interpretación
Precisión	97.3%	Excelente - muy pocos falsos positivos
Sensibilidad (Recall)	64.0%	Moderada - detecta 2/3 de casos positivos
Puntuación F1	77.2%	Balance satisfactorio
Exactitud (Accuracy)	62.9%	Moderada - espacio para mejora

Por su parte, el modelo YOLO11s para aftas orales presentó una precisión de 67.8%, sensibilidad del 82.98%, F1-Score de 74.62% y exactitud de 59.5%, con 78 verdaderos positivos, 16 falsos positivos y 37 falsos negativos.

TABLA XIII

TABLA DE MÉTRICAS DE RENDIMIENTO DEL MODELO YOLO11S

Métrica	Valor	Interpretación
Precisión	67.83%	Moderada - presencia de algunos falsos positivos
Sensibilidad (Recall)	82.98%	Alta - detecta la mayoría de casos positivos
Puntuación F1	74.62%	Balance adecuado entre precisión y sensibilidad
Exactitud (Accuracy)	59.54%	Moderada - requiere optimización para mejorar desempeño

La alta precisión del modelo para gingivitis es crucial para minimizar falsos positivos y evitar tratamientos innecesarios, mientras que la sensibilidad moderada indica espacio para mejorar la detección total. En cuanto a aftas orales, la elevada sensibilidad destaca la capacidad para identificar la mayoría de las lesiones reales, aunque la precisión moderada sugiere la presencia de falsos positivos que deben ser optimizados. En conjunto, estos resultados confirman que el sistema cumple con estándares adecuados para aplicaciones clínicas en entornos con recursos limitados, si bien la exactitud moderada señala la necesidad de ampliar los datos de entrenamiento para mejorar su desempeño general.

Objetivo específico 3: Evaluar la usabilidad del sistema inteligente para asegurar su aceptación en el servicio odontológico del centro de salud

La implementación del Modelo de Aceptación Tecnológica (TAM2) mediante una encuesta ([Anexo 03](#)) estructurada de 12 ítems con escala Likert arrojó resultados excepcionales en ambas dimensiones evaluadas.

TABLA XIV

TABLA DE PUNTUACIONES POR DIMENSIÓN

Dimensión TAM2	Puntuación	Porcentaje	Interpretación
Facilidad de Uso Percibida (FUP)	30/30	100%	Excelente aceptación
Utilidad Percibida (UP)	29/30	96.67%	Muy alta utilidad
Total Sistema	59/60	98.33%	Aceptación casi perfecta

La máxima puntuación en facilidad de uso demuestra que el sistema presenta una navegación intuitiva, simplicidad en la gestión de registros y una curva de aprendizaje favorable, eliminando barreras de entrada tecnológicas. La ligera reducción en utilidad percibida se atribuyó únicamente a un ítem relacionado con la eficiencia en detección de lesiones (4/5 puntos), mientras que aspectos como gestión de registros clínicos, precisión diagnóstica y automatización de procesos recibieron puntuación máxima. Estos resultados confirman que el sistema no solo es técnicamente viable, sino que cuenta con alta predisposición del personal

odontológico para su adopción, cumpliendo con las expectativas tanto en usabilidad como en utilidad práctica para el contexto clínico específico.

Discusiones

Las investigaciones de Esmailyfard et al. [20], Liyanage et al. [21] y Warin et al. [22] constituyen contribuciones significativas al desarrollo actual de las redes neuronales convolucionales, ya que operan en el ámbito de la identificación de enfermedades bucodentales, aunque cada uno propone métodos clínicos y tecnológicos diferentes. Esmailyfard et al. se centran en la clasificación de la caries mediante imágenes CBCT de alta resolución, mientras que Liyanage et al. abordan la clasificación de neoplasias benignas y premalignas a través de imágenes bibliográficas, con especial atención a la prevención del cáncer oral en poblaciones remotas. Warin et al. se ocupan de la clasificación y la detección multiclase de carcinomas de células escamosas y trastornos potencialmente malignos de la cavidad oral basándose en imágenes de biopsias con patologías neoplásicas como patrón de referencia. Aunque instructivos, este tipo de estudios se centran en gran medida en patologías avanzadas y se basan en técnicas de imagen especializadas, lo que limita su aplicación en entornos con escasos recursos.

Por el contrario, esta investigación se centró en afecciones inflamatorias y ulcerosas prevalentes y reversibles, como la gingivitis y las aftas bucales, con la ayuda de imágenes clínicas estándar que están fácilmente disponibles para el sistema en centros de atención médica con recursos tecnológicos y humanos limitados. El modelo SSD-MobileNet-V2-FPNLite-320 demuestra una precisión superior al 97 % en la identificación y localización de la gingivitis, mientras que el modelo YOLO11s alcanza una sensibilidad superior al 80 % en la detección de aftas orales. Del mismo modo, Hernández Olazábal [23] aplicó un método basado en CNN para la clasificación de caries dentales con alta precisión y niveles de entrenamiento, pero nuestro método se diferencia al ofrecer información espacial detallada sobre las lesiones gingivales y ulcerosas en imágenes clínicas. Esta combinación de dos modelos optimizados permite un diagnóstico precoz, no invasivo y más completo, que incluye tanto las lesiones inflamatorias como las ulcerosas, un tema que rara vez se aborda en el diagnóstico automatizado.

En comparación, investigaciones como la de Castro Díaz [24], que utiliza clasificadores difusos basados en variables clínicas para diagnosticar la periodontitis, implican enfoques más tradicionales y organizados en función de los datos clínicos. La propuesta presentada en esta investigación destaca por su énfasis en la búsqueda de patrones visuales directamente en imágenes clínicas, lo que facilita la obtención de resultados espaciales precisos y permite una

evaluación instantánea durante la consulta dental. Además, la amplia colección de imágenes de casos y la aplicación de técnicas de aprendizaje profundo de vanguardia superan los inconvenientes en los niveles de representación y clasificación directa que se descubrieron en investigaciones anteriores.

Conclusiones

Tras desarrollar un sistema inteligente basado en redes neuronales convolucionales para la detección automática de lesiones en la mucosa oral en un centro de salud, se obtuvieron excelentes resultados:

- Se formó un conjunto de imágenes representativas clínicamente y seguras de lesiones en la mucosa oral, mediante un proceso de etiquetado por expertos validado. El índice Kappa de 0,694 reflejó una concordancia considerable, garantizando la integridad de los datos empleados para validar y entrenar.
- El modelo SSD-MobileNet-V2 tuvo una precisión del 97,3 %, una exactitud del 62,9 %, una sensibilidad del 64,0 % y una puntuación F1 del 77,2 %, lo que indica un buen equilibrio entre precisión y recuperación. El modelo YOLO11s tuvo una sensibilidad del 82,98 %, una exactitud del 67,83 %, una precisión del 59,54 % y una puntuación F1 del 74,62 %, lo que indica eficiencia en la detección de aftas, pero con margen de mejora en la reducción de los falsos positivos.
- La evaluación realizada a través del modelo TAM2 mostró una alta aceptación entre el personal dental, con una puntuación global del 98,33 %. Lo más destacable es la facilidad de uso percibida, con un 100 %, y la utilidad percibida, con un 96,67 %. Estos resultados respaldan el sistema como una herramienta eficaz, fácil de usar y útil en entornos clínicos reales.

Recomendaciones

- Se recomienda ampliar la investigación a otras lesiones de la mucosa oral, tales como liquen plano, leucoplasia, candidiasis oral y lesiones precancerosas, con el fin de desarrollar líneas de investigación complementarias sobre temas específicos de patologías y sus características diferenciales, enriqueciendo así el conocimiento científico en el diagnóstico automatizado de patologías orales.
- Se recomienda probar nuevas arquitecturas de aprendizaje profundo y técnicas de procesamiento de imágenes en futuras investigaciones destinadas a maximizar la

sensibilidad diagnóstica. El estudio futuro puede especializarse en comparaciones de modelos y su aplicabilidad según el tipo de lesión.

- Por último, es recomendable llevar a cabo estudios de validación externa en diversos entornos clínicos y poblacionales para determinar la generalización y flexibilidad del sistema, siendo esta vía de investigación fundamental para crear protocolos de implementación y procedimientos de certificación en una variedad de entornos sanitarios.

Referencias

- [1] Rocha-Buelvas, «Cáncer oral: el papel del odontólogo en la detección temprana y control», vol. 21, dic. 2009.
- [2] Regidor E., «INTELIGENCIA ARTIFICIAL EN ODONTOLOGÍA: DEMOCRATIZACIÓN DE LA ATENCIÓN BUCODENTAL», 2024.
- [3] M. Mateo-Sidrón y M. Somacarrera Pérez, Cáncer oral: Genética, prevención, diagnóstico y tratamiento. Revisión de la literatura, vol. Vol. 31. 2015. Accedido: 31 de marzo de 2024. [En línea]. Disponible en: <https://scielo.isciii.es/pdf/odonto/v31n4/original1.pdf>
- [4] OMS, «La OMS destaca que el descuido de la salud bucodental afecta a casi la mitad de la población mundial», 2022. Accedido: 25 de marzo de 2024. [En línea]. Disponible en: <https://www.who.int/es/news/item/18-11-2022-who-highlights-oral-health-neglect-affecting-nearly-half-of-the-world-s-population>
- [5] Chan, «Crisis de salud bucodental en India: Desafíos y soluciones | RECURSOS DENTALES ASIA», DENTAL RESOURCE ASIA. Accedido: 8 de abril de 2025. [En línea]. Disponible en: <https://dentalresourceasia.com/es/oral-health-crisis-in-india-challenges-and-solutions/>
- [6] Kern Pharma, «La salud bucodental», Kern Pharma. Accedido: 8 de abril de 2025. [En línea]. Disponible en: <https://www.kernpharma.com/es/blog/la-salud-bucodental>
- [7] OurWorldInData, «Dentistry personnel per 10,000 population», Our World in Data. Accedido: 8 de abril de 2025. [En línea]. Disponible en: <https://ourworldindata.org/grapher/dentistry-personnel-per-1000>
- [8] MINSA, «Minsa: Caries dental, gingivitis y periodontitis son enfermedades bucales con mayor prevalencia en menores entre 3 y 15 años», 2021. Accedido: 25 de marzo de 2024. [En línea]. Disponible en: <https://www.gob.pe/institucion/minsa/noticias/567307-minsa-caries-dental-gingivitis-y-periodontitis-son-enfermedades-bucuales-con-mayor-prevalencia-en-menores-entre-3-y-15-anos>
- [9] Minsa, «Minsa: la caries dental es la enfermedad más común entre la población infantil». Accedido: 8 de abril de 2025. [En línea]. Disponible en: <https://www.gob.pe/institucion/minsa/noticias/741092-minsa-la-caries-dental-es-la-enfermedad-mas-comun-entre-la-poblacion-infantil%20>
- [10] P. S. Campó, «Solo el 26.7% de los niños peruanos menores de 12 años va al dentista: cuáles son las principales enfermedades bucales», infobae. Accedido: 8 de abril de 2025. [En línea]. Disponible en: <https://www.infobae.com/peru/2024/10/09/solo-el-267-de-los-ninos-peruanos-menores-de-12-anos-va-al-dentista-cuales-son-las-principales-enfermedades-bucales/>
- [11] EsSalud, «EsSalud resalta importancia de consultas odontológicas para detectar el Cáncer Bucal», Essalud. Accedido: 5 de mayo de 2024. [En línea]. Disponible en:

- <http://noticias.essalud.gob.pe/?inno-noticia=essalud-resalta-importancia-de-consultas-odontologicas-para-detectar-el-cancer-bucal>
- [12] RedacciónRPP, «Chiclayo: nueve de cada diez personas sufren de caries | RPP Noticias». Accedido: 25 de marzo de 2024. [En línea]. Disponible en: <https://rpp.pe/peru/lambayeque/chiclayo-nueve-de-cada-diez-ciudadanos-sufre-de-caries-y-problemas-bucales-noticia-973042>
- [13] W. Bengel, «Estudio diagnóstico de patologías de la mucosa oral. Parte 1: Exploración básica», Quintessence (ed. esp.), vol. 23, n.º 10, pp. 500-509, dic. 2010.
- [14] OMS, «Salud bucodental». Accedido: 25 de marzo de 2024. [En línea]. Disponible en: <https://www.who.int/es/news-room/fact-sheets/detail/oral-health>
- [15] CuidatePlus, «Lo que ocurre en la boca afecta (y mucho) a la salud general», CuidatePlus. Accedido: 25 de marzo de 2024. [En línea]. Disponible en: <https://cuidateplus.marca.com/bienestar/2022/05/17/ocurre-boca-afecta-salud-general-179776.html>
- [16] H. Zheng, Q. Shi, W. Du, y F. Lin, «The Psychosocial Impact of Dental Esthetics in Undergraduates with Borderline Malocclusion», Computational and Mathematical Methods in Medicine, vol. 2022, pp. 1-6, mar. 2022, doi: 10.1155/2022/2399323.
- [17] W. J. Park y J.-B. Park, «History and application of artificial neural networks in dentistry», Eur J Dent, vol. 12, n.º 4, pp. 594-601, 2018, doi: 10.4103/ejd.ejd_325_18.
- [18] J. Pérez de Frutos, R. Holden Helland, S. Desai, L.C. Nymoen, T. Lango, T. Remman, A. Sen, «AI-Dentify: deep learning for proximal caries detection on bitewing x-ray - HUNT4 Oral Health Study», BMC Oral Health, vol. 24, n.º 1, 2024, doi: 10.1186/s12903-024-04120-0.
- [19] K.-C. Li et al., «Detection of Tooth Position by YOLOv4 and Various Dental Problems Based on CNN With Bitewing Radiograph», IEEE Access, vol. 12, pp. 11822-11835, 2024, doi: 10.1109/ACCESS.2023.3348788.
- [20] R. Esmailyfard, H. Bonyadifard, y M. Paknahad, «Dental Caries Detection and Classification in CBCT Images Using Deep Learning», International Dental Journal, vol. 74, n.º 2, pp. 328-334, abr. 2024, doi: 10.1016/j.identj.2023.10.003.
- [21] V. Liyanage, M. Tao, J. S. Park, K. N. Wang, y S. Azimi, «Malignant and non-malignant oral lesions classification and diagnosis with deep neural networks», Journal of Dentistry, vol. 137, 2023, doi: 10.1016/j.jdent.2023.104657.
- [22] K. Warin, W. Limprasert, S. Suebnukarn, S. Jinaporntham, P. Jantana, y S. Vicharueang, «AI-based analysis of oral lesions using novel deep convolutional neural networks for early detection of oral cancer», PLoS ONE, vol. 17, n.º 8 August, 2022, doi: 10.1371/journal.pone.0273508.
- [23] Hernandez Olazabal, «Sistema inteligente para el apoyo en la identificación de enfermedades bucodentales basado en el reconocimiento de imágenes», 2023, Accedido: 25 de abril de 2024. [En línea]. Disponible en: <http://tesis.usat.edu.pe/handle/20.500.12423/5931>
- [24] E. Castro Diaz, «Implementación de un Modelo Basado en Clasificadores Difusos para el Diagnóstico de Periodontitis en las Personas Adultas», Universidad Señor de Sipan, Pimentel, Perú, 2024. Accedido: 30 de abril de 2025. [En línea]. Disponible en: <https://repositorio.uss.edu.pe/bitstream/handle/20.500.12802/12912/Elvis%20Castro%20D%c3%adaz.pdf?sequence=14&isAllowed=y>
- [25] S. González Otero, F. García Marín, y J. L. Cebrián Carretero, Capítulo 4: Lesiones de la mucosa oral.
- [26] P. MATESANZ-PÉREZ, R. MATOS-CRUZ, y A. BASCONES-MARTÍNEZ, «Enfermedades gingivales: una revisión de la literatura». 2008.

- [27] Rioboo Crespo, M., y A. Bascones Martínez. «Aftas de la mucosa oral». *Avances en Odontoestomatología* 27, n.º 2 (abril de 2011). <https://doi.org/10.4321/S0213-12852011000200002>.
- [28] L. Rouhiainen, *Inteligencia Artificial - 101 cosas que debes saber hoy sobre nuestro futuro*. España, Madrid: Alienta Editorial.
- [29] J. C. Ponce Gallegos et al., *Inteligencia Artificial. Iniciativa Latinoamericana de Libros de Texto Abiertos (LATIn)*, 2014.
- [30] M. Negnevitsky, *Artificial Intelligence - A Guide to Intelligent Systems*, Segunda Edición. Inglaterra, 2005.
- [31] S. J. Russell y P. Norvig, *Artificial Intelligence: A Modern Approach*, 3rd ed. Prentice Hall, 2010.
- [32] IBM, «¿Qué es un algoritmo de aprendizaje automático? | IBM». Accedido: 5 de mayo de 2024. [En línea]. Disponible en: <https://www.ibm.com/mx-es/topics/machine-learning-algorithms>
- [33] F. Alba Centeno, *DEEP LEARNING*. Sevilla, España: Universidad de Sevilla, 2019.

Anexos**ANEXO N° 01. CARTA DE ACEPTACIÓN POR PARTE DEL CENTRO DE SALUD****CARTA DE ACEPTACIÓN DE LA ORGANIZACIÓN**

Chiclayo 3 de junio de 2024

Dr. Ing. Maximiliano Arroyo Ulloa
Decano (e) de la Facultad de Ingeniería
Universidad Santo Toribio de Mogrovejo - USAT

Presente .-

Tengo el agrado de dirigirme a usted con la finalidad de hacer de su conocimiento que el estudiante **MAURICIO BENJAMÍN DURAND CALLE** identificado con DNI N° **73041489**, alumno de la **Escuela de Ingeniería de Sistemas y Computación** de la Universidad Santo Toribio de Mogrovejo, ha sido admitido para realizar su proyecto de tesis titulada "Sistema inteligente para la detección de lesiones de la mucosa oral en un centro de salud" en nuestra organización Centro de Salud Villa Hermosa ubicada en Cuadra 5, Av. Chiclayo, José Leonardo Ortiz identificada con R.U.C. 20163833094. Aprovecho la oportunidad para expresarle mi consideración y estima personal.

Atentamente,



R. Med. Per. Suárez
MÉDICO CIRUJANO
C.M.P.: 67043

ANEXO N° 02. VISITA AL ÁREA DE SALUD BUCAL DEL CENTRO DE SALUD
“VILLA HERMOSA”



ANEXO N° 03. ENCUESTA DE USABILIDAD DEL SISTEMA INTELIGENTE BASADA
EN EL MODELO DE ACEPTACIÓN TECNOLÓGICA (TAM2)

**Encuesta de Usabilidad del Sistema Inteligente para
Detección de Lesiones de la Mucosa Oral**

Por favor, responda a las siguientes afirmaciones utilizando un aspa (X) en base a una escala del 1 al 5, donde:

- 5 = Totalmente de acuerdo
4 = De acuerdo
3 = Neutral
2 = En desacuerdo
1 = Totalmente en desacuerdo

Facilidad de Uso Percibida

	Totalmente de acuerdo	De acuerdo	Neutral	En desacuerdo	Totalmente en desacuerdo
El sistema es fácil de usar	X				
La interfaz del sistema es clara e intuitiva	X				
Es fácil registrar nuevas fichas de evaluación odontológica en el sistema	X				
Editar y eliminar fichas existentes es un proceso sencillo	X				
La función de detección de gingivitis a través de imágenes es fácil de utilizar	X				
Aprender a usar el sistema fue rápido y sencillo	X				

Utilidad Percibida

	Totalmente de acuerdo	De acuerdo	Neutral	En desacuerdo	Totalmente en desacuerdo
El sistema mejora mi eficiencia en la detección de lesiones de la mucosa oral		X			
La detección automática de gingivitis es útil para mi práctica clínica	X				
El sistema me ayuda a mantener un mejor registro de las evaluaciones odontológicas de mis pacientes.	X				
La capacidad de editar y actualizar fichas mejora mi seguimiento de los casos	X				
El sistema me permite realizar diagnósticos más precisos	X				
En general, el sistema es útil para mi práctica odontológica	X				

Gracias por su tiempo y retroalimentación.



C.S. VILLA HERMOSA
 Hans E. Flores Torres
 CIRUJANO DENTISTA
 C. O. P. 23554

Firma del odontólogo