



UNIVERSIDAD DE LOS ANDES
FACULTAD DE ODONTOLOGÍA
DEPARTAMENTO DE MEDICINA ORAL

APLICACIÓN DE LA INTELIGENCIA ARTIFICIAL EN EL DIAGNÓSTICO DE LIQUEN PLANO ORAL

Trabajo Especial de Grado para optar al título de Odontólogo

Autores: Br. Laurimar Lara

Tutor: Prof. Andreina Tejada

Cotutor: Prof. Jonathan Hernández

Mérida – Venezuela, Julio 2025

DEDICATORIA

A Dios, por guiar cada uno de mis pasos, por brindarme sabiduría, fortaleza y mantener siempre viva en mí la esperanza.

A mi mamá, por enseñarme que el esfuerzo y el sacrificio son el camino al éxito; por amarme, apoyarme incondicionalmente y por ser siempre mi refugio más seguro.

A mis abuelas Rosa y Aurelia, pilares de mi vida y ejemplos de entrega, resiliencia y amor infinito. Gracias por tantas lecciones valiosas y por cuidar siempre de mí.

A Tito y a Lola, cuya presencia llenó mis días de alegría, ternura y amor sincero. Gracias por acompañarme siempre.

A mi tía Yanis, por ser un ejemplo de lucha constante, apoyo invaluable, y por creer en mis sueños tanto como yo misma.

Y finalmente, a mi Samy, por ser mi compañera incondicional, por brindarme su apoyo, motivación y cariño en cada etapa de este camino.

Gracias por formar parte de este logro tan importante en mi vida.

AGRADECIMIENTOS

A mi alma máter, la ilustre Universidad de Los Andes, por haber sido el espacio donde crecí, aprendí y descubrí mi pasión por la odontología. Gracias por abrirme las puertas del conocimiento y formarme con excelencia.

A todos los profesores de la FOULA, por su vocación, exigencia y entrega, cada clase, consejo y ejemplo marcaron mi formación y despertaron en mí un profundo respeto por esta hermosa profesión.

A mi tutora, la profesora Andreina Tejada, quien me ha acompañado con paciencia, sabiduría y un cariño que trasciende lo académico, gracias por enseñarme con tanto esmero y dedicación, por compartirme su conocimiento con verdadero afecto, esos gestos no tienen precio y siempre los llevaré conmigo.

Al profesor Damian Cloquell, por su apoyo, orientación y valiosos aportes durante el desarrollo de este trabajo.

Gracias por ser parte esencial de este logro y por dejar en mí una huella imborrable.

ÍNDICE DE CONTENIDO

DEDICATORIA	3
AGRADECIMIENTOS	4
ÍNDICE DE CONTENIDO	5
ÍNDICE DE FIGURAS	6
ÍNDICE DE TABLAS	7
ÍNDICE DE GRÁFICOS	7
RESUMEN	8
INTRODUCCIÓN	9
CAPÍTULO I	11
PLANTEAMIENTO DEL PROBLEMA	11
CAPÍTULO II	16
MARCO TEÓRICO	16
CAPÍTULO III	37
MARCO METODOLÓGICO	37
CAPÍTULO IV	42
RESULTADOS	42
CAPÍTULO V	65
DISCUSIÓN	65
CONCLUSIONES	80
RECOMENDACIONES	81
REFERENCIAS	82

ÍNDICE DE FIGURAS

Figura 1. Diagrama de flujo de un ML.	11
Figura 2. Representación de un perceptrón ``neurona artificial``.	13
Figura 3. Red neuronal convolucional	14
Figura 4. Factores etiológicos	16
Figura 5. Papel de las células inmunes en la patogénesis del LPO	20
Figura 6. Patrones clínicos del LPO	22
Figura 7. Histopatología del LPO.	23

www.bdigital.ula.ve

ÍNDICE DE TABLAS

Tabla 1. Descriptores y palabras claves.	31
Tabla 2. Fuentes de información consultadas, estrategias de búsqueda, filtros aplicados y número de artículos obtenidos.	32
Tabla 3. Artículos excluidos	36
Tabla 4. Resumen de los datos clínicos ingresados	43
Tabla 5. Resumen de modelos de IA	50
Tabla 6. Resumen rendimiento de IA en el diagnóstico de LPO	56

ÍNDICE DE GRÁFICOS

Gráfico 1. Sitio de desarrollo de los estudios incluidos	38
Gráfico 2. Distribución de los datos clínicos	39
Gráfico 3. Distribución general de las lesiones	40
Gráfico 4. Tipos de IA	47
Gráfico 5. Sensibilidad y especificidad	54



UNIVERSIDAD DE LOS ANDES
FACULTAD DE ODONTOLOGÍA
DEPARTAMENTO DE MEDICINA ORAL

APLICACIÓN DE LA INTELIGENCIA ARTIFICIAL EN EL DIAGNÓSTICO DE LIQUEN PLANO ORAL

Trabajo Especial de Grado para optar al título de Odontólogo

Autor: Br Laurimar Lara

Tutor: Prof. Andreina Tejada

Mérida – Venezuela, julio 2025

RESUMEN

Introducción: En la intersección entre la complejidad de la salud bucal y la necesidad de diagnósticos precisos, el liquen plano oral (LPO) se presenta como un desafío clínico significativo debido a su naturaleza inflamatoria crónica y potencial malignidad. Estas características subrayan la urgencia de mejorar la precisión en el diagnóstico mediante herramientas innovadoras como la inteligencia artificial (IA).

Objetivo: Describir la aplicación de la inteligencia artificial en el diagnóstico del liquen plano oral.

Metodología: La investigación es de nivel descriptivo y diseño documental, bajo la modalidad de revisión de alcance. Se realizó una búsqueda electrónica en diversas bases de datos científicas, aplicando criterios de inclusión y exclusión preestablecidos. Se analizaron estudios que emplearan modelos de IA en el diagnóstico del LPO.

Resultados: Se incluyeron dieciséis estudios, que utilizaron distintos enfoques de IA, en la mayoría de los estudios se observaron niveles elevados de sensibilidad y especificidad, aunque existieron variaciones metodológicas.

Conclusión: Los modelos de IA demostraron un alto potencial como herramienta de apoyo en el diagnóstico del LPO. Su integración en la práctica clínica podría favorecer la detección temprana y precisa, siempre que se validen adecuadamente y se estandaricen los procedimientos.

Palabras Clave: Inteligencia artificial, Liquen plano oral, Diagnóstico.

INTRODUCCIÓN

En la intersección entre la complejidad de la salud bucal y la necesidad de diagnósticos precisos, surge el Liqueen Plano Oral (LPO) como un enigma clínico. Este trastorno inflamatorio crónico de la mucosa bucal no sólo desafía la comprensión de su etiología multifactorial, sino que también plantea preocupaciones significativas debido a que actualmente se considera un desorden potencialmente maligno, es por esto que existe la necesidad de encontrar una forma más precisa y efectiva de diagnosticar esta enfermedad a través de nuevas herramientas diagnósticas, una de ellas es la Inteligencia Artificial (IA), ya que posee una gran capacidad de analizar grandes volúmenes de información y detectar patrones complejos en diversos datos médicos, esta valiosa herramienta promete revolucionar la práctica clínica en odontología.

Existen estudios que aplican la IA en el diagnóstico de LPO, incluso esta se ha incluido en contexto general en revisiones sistemáticas donde se aborda el uso de la IA en el diagnóstico de úlceras bucales; sin embargo, no hay revisiones que aborden específicamente el uso de la IA en el diagnóstico de LPO. Por ello, esta investigación propone llenar ese vacío, evaluando la eficacia de los modelos de IA en el diagnóstico del LPO y proporcionando una visión integral sobre su implementación en la práctica clínica.

Se trata de una revisión de alcance, enmarcada en un enfoque descriptivo documental, este diseño metodológico permite recopilar, analizar y sintetizar la información existente en fuentes de información electrónica, con el fin de explorar y clarificar conceptos, identificar brechas en la investigación y proporcionar una visión integral de la aplicación de la IA en el diagnóstico del LPO.

Esta investigación está estructurada en cuatro capítulos:

Capítulo I: Planteamiento del Problema, se define y contextualiza el problema de la investigación, se presentan los objetivos generales y específicos, así como la justificación del estudio.

Capítulo II: Marco Teórico

Aquí se aborda la base teórica y conceptual del LPO y la IA, se exploran los fundamentos y aplicaciones de la IA en el diagnóstico médico.

Capítulo III: Metodología

Este capítulo describe el nivel y diseño de la investigación, se detallan los criterios de selección de estudios, las fuentes de información utilizadas, la estrategia de búsqueda y el proceso de cribado y selección de la literatura relevante.

Capítulo IV: Resultados y Discusión

En este capítulo se presentan y analizan los hallazgos de la revisión de alcance. Se discuten los diversos modelos de IA aplicados en el diagnóstico del LPO, los tipos de datos clínicos utilizados, y la sensibilidad y especificidad de estos modelos. Finalmente, se abordan las implicaciones de los resultados y se proponen recomendaciones para futuras investigaciones.

Con esta estructura, la investigación busca proporcionar una comprensión profunda y exhaustiva del potencial de la IA en el diagnóstico del LPO, contribuyendo así a mejorar la práctica clínica y los resultados para los pacientes.

CAPÍTULO I

PLANTEAMIENTO DEL PROBLEMA

1.1 Definición y contextualización del problema

El Liqueen Plano Oral (LPO) es un trastorno inflamatorio crónico de la mucosa bucal, caracterizado por respuestas inmunes mediadas por células T¹. Su prevalencia varía significativamente a nivel mundial debido a diversos factores, como la ubicación geográfica, el género, la edad y las condiciones sistémicas asociadas. A nivel global, se estima que el LPO afecta alrededor del 0,89 % de la población general y al 0,98 % de los pacientes clínicos². En América Latina, la prevalencia es de aproximadamente 1,74% de la población general³. Según estudios epidemiológicos el LPO exhibe una discrepancia de género, con una mayor prevalencia en mujeres que en hombres^{2,4,5}.

La etiología del LPO sigue sin estar claramente definida. Aunque se considera multifactorial, no se ha identificado una causa única⁶. Entre los factores propuestos, la desregulación inmunológica parece desempeñar un papel clave en su patogénesis. Esto se caracteriza por la activación de células T citotóxicas y mecanismos no específicos, como la desgranulación de los mastocitos y la activación de las metaloproteinasas de la matriz^{7,8}. Asimismo, la literatura sugiere una asociación entre el LPO y enfermedades sistémicas, especialmente trastornos hepáticos,⁹ diabetes e hipertensión¹⁰; además de factores ambientales como el estrés, la ansiedad y la depresión, lo que sugiere una interacción compleja entre la salud mental y esta afección bucal¹¹.

El diagnóstico temprano y el tratamiento son cruciales debido a la preocupación por la transformación del LPO en cáncer bucal, clasificándose como un trastorno oral potencialmente maligno^{3,12-15}. Según estudios, aproximadamente el 1,43% de los casos de LPO desarrollan cáncer bucal¹⁶. El diagnóstico del LPO se realiza mediante una combinación de examen clínico, historial médico y pruebas de laboratorio.

Durante el examen clínico, se buscan lesiones elementales con características compatibles con el LPO¹⁰, clínicamente se observa como lesiones bilaterales y simétricas, suelen aparecer en ambos lados de la boca, con una distribución simétrica, que es una característica distintiva clave de otras afecciones de la mucosa bucal¹⁷. Los

patrones blancos, de encaje o reticulares característicos de la mucosa bucal, a menudo denominados estrías de Wickham, son distintivos del LPO¹⁸; además, el LPO tiene diferentes subtipos clínicos según la configuración o morfología de las lesiones, en estos se incluyen, reticular, erosivo, atrófico, papular, en forma de placa y ampolloso¹⁹. Cuando se presenta una forma de liquen plano con predominio rojo y lesiones eritemato-descamativas, el diagnóstico diferencial debe realizarse principalmente con otras lesiones vesículo-erosivas, como el eritema multiforme, el pénfigo vulgar o el penfigoide²⁰.

Si el diagnóstico no está claro, se puede realizar una biopsia para confirmar la presencia de la afección, generalmente esta muestra hiperqueratosis y paraqueratosis de las capas superiores, degeneración hidrópica de la capa basal del epitelio y densa infiltración de linfocitos en el corion superior debajo del epitelio²¹. En algunos casos, se pueden requerir pruebas adicionales, como la inmunofluorescencia, que implica la aplicación de tintes fluorescentes para visualizar componentes celulares o moléculas específicas dentro de los tejidos afectados por la afección²².

El diagnóstico del LPO presenta desafíos, como la falta de un marcador específico para su detección, lo que puede dificultar la confirmación definitiva de la enfermedad²³. A pesar de los diversos métodos diagnósticos disponibles, la interpretación de los hallazgos puede ser subjetiva y requerir experiencia para una evaluación precisa. Sin embargo, los avances en IA ofrecen nuevas oportunidades para mejorar la precisión y eficacia de estos diagnósticos.

La IA es un campo emergente en la informática que otorga a las máquinas la capacidad de imitar el comportamiento humano inteligente²⁴ este término fue acuñado en la década de 1950 y se refiere a la idea de construir máquinas que sean capaces de realizar tareas que normalmente realizan los humanos²⁵ para lograr esto se aplican algoritmos para aprender patrones y estructuras estadísticas a partir de los datos, los cuales se procesan mediante neuronas artificiales, se trata de un modelo matemático no lineal inspirado en la neurona humana²⁶. Al apilar y concatenar neuronas artificiales y conectar esas capas mediante operaciones matemáticas, se diseña una red que apunta a

resolver una tarea específica ²⁷ estas redes identifican automáticamente patrones de detección ²⁸.

La IA tiene la capacidad de analizar imágenes médicas con un alto nivel de precisión y exactitud, puede detectar patrones sutiles, anomalías o indicadores de enfermedades que pueden ser difíciles de reconocer a simple vista²⁸. Existen grandes expectativas sobre el impacto de la IA en la asistencia médica en los próximos años. Esto permitiría un enfoque diagnóstico y terapéutico más personalizado y preciso, así como intervenciones más tempranas para mantener la salud del paciente²⁶

La IA se ha utilizado en el diagnóstico del LPO a través de redes neuronales convolucionales (CNN) , demostrando una alta precisión para distinguir el LPO, lo que resalta el potencial de la IA para mejorar los procesos de diagnóstico en odontología y atención de la salud bucal²⁹⁻³². Se ha encontrado una revisión sistemática que incluye al LPO como parte de un estudio sobre el uso de la IA en el diagnóstico de úlceras bucales³³.

A pesar de la existencia de artículos que abordan el uso de la IA para el diagnóstico del LPO, y una revisión sistemática que menciona el LPO en el contexto general del diagnóstico de úlceras bucales, aún no se ha realizado una revisión exhaustiva centrada específicamente en la aplicación de la IA para el diagnóstico del LPO. Por lo tanto, el objetivo de esta investigación es llevar a cabo una revisión de alcance que aborde específicamente la aplicación de la IA en el diagnóstico del LPO.

1.2 Objetivos de la investigación

1.2.1 Objetivo general

Describir la aplicación de la IA en el diagnóstico de LPO.

1.2.2 Objetivos específicos

- Identificar los tipos de datos clínicos que se utilizan como entrada para generar diagnósticos de LPO mediante IA.
- Identificar los diversos modelos de IA utilizados para el diagnóstico del LPO.
- Identificar la sensibilidad y especificidad de los modelos de IA en el diagnóstico del LPO.

1.3 Justificación

A continuación, se presentan las razones que justifican la realización de esta investigación:

En primer lugar, existen estudios que abordan el uso de la IA para el diagnóstico de LPO, pero no se ha encontrado revisiones de alcance que hablen de la aplicación de la IA para el diagnóstico de LPO.

En segundo lugar, a pesar de que hay una revisión sistemática que incluye el LPO dentro del diagnóstico de úlceras bucales, no se ha realizado una revisión de alcance centrada exclusivamente en la IA aplicada al diagnóstico del LPO.

En tercer lugar, la IA es una herramienta tecnológica poderosa que ha demostrado ser capaz de analizar imágenes médicas con gran precisión y exactitud. Esta investigación podría apoyar la implementación de la IA como método diagnóstico para el LPO en la práctica clínica, ayudando a los profesionales de la salud en la toma de decisiones y mejorando la precisión del diagnóstico.

En cuarto lugar, el uso de la IA en el diagnóstico médico está en sus primeras etapas de implementación, aunque se ha mostrado una gran exactitud en estudios realizados, solo han sido validadas de forma limitada, demostrar que la inteligencia está bien entrenada y expone una gran precisión es un primer paso, pero es necesario revisar y comparar métodos y resultados en los estudios disponibles para validar su efectividad en el diagnóstico del LPO.

En quinto lugar, esta investigación puede promover la inclusión de una materia electiva sobre el uso actual de la IA en la odontología. La incorporación de esta materia enriquecerá el currículo educativo y preparará a los estudiantes para explorar un campo en constante evolución, promoviendo la innovación y posicionando a nuestra facultad a la vanguardia de la educación médica.

En sexto lugar, este estudio pretende iniciar una línea de investigación en el área de IA aplicada a la patología oral, que pueda servir de guía para futuros estudios sobre dicha temática.

Finalmente, al incrementar la precisión diagnóstica, el uso de la IA podría permitir una detección más temprana del LPO, lo cual se traduciría en mejores resultados

clínicos, mayor calidad de vida y un impacto positivo en la esperanza de vida del paciente.

www.bdigital.ula.ve

CAPÍTULO II

MARCO TEÓRICO

1.1 Bases conceptuales

1.1.1 Inteligencia artificial.

La Inteligencia Artificial (IA) se refiere a la capacidad de los ordenadores para emplear algoritmos, adquirir conocimientos a partir de datos y aplicar lo que han aprendido en los procesos de toma de decisiones, igual que haría un humano³⁴ en tareas que normalmente requieren inteligencia humana, como la percepción visual, el reconocimiento del habla, la toma de decisiones y la traducción²⁷. La IA representa una forma de inteligencia simulada por la tecnología, orientada a replicar ciertos aspectos del pensamiento humano. Esta disciplina tiene dos objetivos principales: el primero es tecnológico y consiste en utilizar ordenadores para resolver tareas prácticas de forma eficiente; el segundo es científico, y busca emplear conceptos y modelos de IA para comprender mejor cómo funciona la inteligencia en los seres humanos y otros organismos vivos.³⁵

En la actualidad la IA se refiere a cualquier tecnología que sea capaz de imitar las habilidades cognitivas de los humanos²⁴, aunque a diferencia de las personas, los dispositivos basados en IA no necesitan descansar y pueden analizar grandes volúmenes de información a la vez y la proporción de errores es significativamente menor en las máquinas que realizan las mismas tareas que sus contrapartes humanas³⁴. La IA no es una dimensión única, sino un espacio profusamente estructurado de capacidades diversas para procesar la información³⁵ que se utiliza ampliamente en el campo de la salud móvil y la medicina digital³⁶.

La integración de la IA en el diagnóstico y la atención sanitaria tiene el potencial de revolucionar la industria médica, mejorando la precisión y eficiencia del diagnóstico, la planificación del tratamiento, y el descubrimiento de fármacos³⁷. Sin embargo, también presenta varios desafíos éticos que deben abordarse para garantizar la responsabilidad y uso ético de la IA en la atención sanitaria.

Una de las principales cuestiones éticas es la necesidad de tener el consentimiento informado para utilizar los datos de los pacientes en el desarrollo y la formación de la IA. Se debe informar al paciente cómo se utilizarán sus datos y estos deben tener derecho a optar por no participar o retirar su consentimiento en cualquier momento, así como garantizar la privacidad y la seguridad de los datos para evitar el acceso no autorizado o el uso indebido de información confidencial del paciente³⁸. Los sistemas de IA deben garantizar equidad algorítmica ya que estos pueden ser sesgados e injustos si se entrenan con conjuntos de datos que no representan poblaciones diversas, lo que lleva a diagnósticos inexactos o recomendaciones de tratamientos indebidos. Los sistemas de IA deben estar bajo supervisión humana y diseñarse para respetar la autonomía, igualmente los pacientes deben tener derecho a elegir si utilizan tecnologías sanitarias basadas en IA ³⁷.

Dado lo reciente del desarrollo de esta tecnología, aún no se ha establecido un marco ético sólido que regule su diseño, fabricación y uso. Es indispensable construir lineamientos que permitan evaluar los aciertos y errores de las decisiones tomadas por sistemas de inteligencia artificial, especialmente en contextos clínicos. Dicho marco debe fundamentarse en valores, principios y normas éticos que aborden los riesgos tecnológicos potenciales, y que garanticen que la innovación en IA se desarrolle conforme a criterios éticos³⁹. Para ello, se requiere un enfoque integral que combine consideraciones éticas, marcos legales y medidas regulatorias, a fin de asegurar que la inteligencia artificial se aplique de forma responsable en el ámbito de la atención médica.

1.1.1.1 Aprendizaje automático (Machine Learning)

El aprendizaje automático (ML, por sus siglas en inglés) es uno de los enfoques principales de la IA, que depende de algoritmos para predecir resultados basados en un conjunto de datos ²⁸ da a las computadoras la capacidad de aprender sin ser programadas explícitamente ⁴⁰. El propósito del ML es facilitar el aprendizaje de los datos por parte de las máquinas para que puedan resolver problemas sin la intervención humana ²⁸. En el ML no es el humano quien define las reglas que siguen las máquinas

para realizar determinadas tareas, sino que la propia máquina aprende las reglas a partir de los datos²⁶ comienza con un enfoque ascendente entrenando modelos matemáticos con datos derivados de actividades humanas ²⁴ (por ejemplo, miles de imágenes con lesiones cariosas) y la información (por ejemplo, la información de las imágenes), las máquinas aprenden ahora a detectar patrones estadísticos en los datos en un proceso iterativo ²⁶

El ML se puede dividir en aprendizaje supervisado, no supervisado y semisupervisado⁴². En el aprendizaje supervisado, los algoritmos utilizan conjuntos de datos de entrenamiento que han sido previamente etiquetados de forma manual, con el fin de aprender las correlaciones entre las características de entrada y sus respectivas salidas esperadas, generando así resultados deseados y conocidos⁴¹. Este método requiere la intervención humana: una persona, conocida como anotador, se encarga de asignar a cada objeto de datos, una etiqueta que representa su categoría o diagnóstico, de esta forma, el modelo aprende a asociar cualquier entrada con su salida correspondiente²⁶.

En el aprendizaje no supervisado, los algoritmos no usan ningún dato etiquetado u organizado previamente para indicar cómo tendría que ser categorizada la nueva información, sino que tienen que encontrar la manera de clasificarlas ellos mismos. Por tanto, este método no requiere la intervención humana. ⁴².

El aprendizaje semisupervisado combina elementos de los métodos supervisado y no supervisado, permitiendo que el algoritmo analice grandes volúmenes de datos no etiquetados mientras mejora su reconocimiento de patrones con una cantidad reducida de datos etiquetados⁴³.




Figura 1. Diagrama de flujo de un ML supervisado. El algoritmo analiza un conjunto de datos de entrenamiento que contiene datos representativos, así como resultados de interés para identificar patrones o vínculos en los datos presentados para el entrenamiento. El sistema tiene la capacidad de reentrenarse continuamente bajo supervisión para mejorar su precisión. Cuando se ha optimizado con el conjunto de datos de entrenamiento, el algoritmo se puede aplicar a un conjunto de datos de prueba "verdadero" de interés. (b) Diagrama de flujo de ML no supervisado. Se presenta un gran conjunto de datos al algoritmo no supervisado donde los patrones se aclaran y se presentan al usuario para su revisión manual.⁴³

1.1.1.2 Aprendizaje profundo (Deep Learning)

Una de las aplicaciones más poderosas y de mayor crecimiento de la IA es el aprendizaje profundo (DL, por sus siglas en inglés), se trata de un subcampo del aprendizaje automático que se utiliza para resolver problemas muy complejos y que normalmente implican grandes cantidades de datos³⁴. Lo que diferencia el aprendizaje profundo de una red neuronal simple es que el número de capas de nodos aumenta y el tamaño total de la red es mayor, lo que permite representar con mayor precisión las interrelaciones complejas⁴⁴. El DL se produce mediante el uso de redes neuronales, que se organizan en capas para reconocer relaciones y patrones complejos en los datos, su aplicación requiere un enorme conjunto de información y una potente capacidad de procesamiento⁴³. Posee un algoritmo de retropropagación, se utiliza para indicar cómo una máquina debe cambiar sus parámetros internos para calcular la representación en cada capa a partir de la representación en la capa anterior. La aplicación del DL está transformando múltiples ámbitos, entre ellos el análisis de imágenes médicas, el tratamiento oncológico y el procesamiento de imágenes⁴⁵. En el diagnóstico médico, el

DL se emplea de diversas maneras gracias a su capacidad para procesar grandes volúmenes de datos y detectar patrones complejos⁴⁶.

1.1.1.3 Redes neuronales artificiales (Artificial Neural Networks ANN)

Las redes neuronales artificiales (ANN, por sus siglas en inglés) están compuestas por capas de neuronas artificiales conectadas, cada neurona artificial es un modelo matemático compuesto por una unidad lineal y otra no lineal²⁶. Un tipo de neurona artificial o la forma más simple de red neuronal se denomina perceptrón⁴⁷, el cual es un modelo simple de una neurona biológica y se utiliza a menudo para tareas de clasificación binaria, este posee un conjunto de entradas, a estas entradas se les aplica pesos y luego pasan a través de una función de activación para producir una salida⁴⁴.

Al combinar millones de estas neuronas artificiales de forma inteligente y eficaz en términos computacionales, una red neuronal de este tipo es capaz de representar cualquier entrada de datos y asignarla a un resultado o salida²⁶. Las redes intentan utilizar múltiples capas de cálculos para imitar el concepto de cómo el cerebro humano interpreta y saca conclusiones de la información⁴³. El poder computacional de estas redes se basa en la calidad y cantidad de datos.




Figura 2. Representación de un perceptrón "neurona artificial".

1.1.1.4 Redes neuronales convolucionales (Convolutional Neural Networks)

Las redes neuronales convolucionales (CNN, por sus siglas en inglés) son un tipo de red neuronal comúnmente utilizada en tareas de visión por computadora, como clasificación de imágenes, detección de objetos y segmentación⁴⁸. Las redes neuronales de convolución son el resultado de la combinación de un mecanismo de extracción de características basado en convoluciones, con una red neuronal. Son especialmente adecuadas para el análisis de datos de imágenes²⁶. Están diseñados para aprender automáticamente representaciones jerárquicas de datos de entrada, como imágenes, aplicando filtros convolucionales a la entrada y agrupando los resultados.⁴⁸

Se caracteriza por tener múltiples capas de nodos ocultos que aprenden representaciones de datos abstrayéndolos de muchas maneras. Lo que diferencia la red neuronal convolucional de una red neuronal simple es que el número de capas de nodos aumenta y el tamaño total de la red es mayor, lo que permite representar con mayor precisión las interrelaciones complejas⁴⁴




Figura 3. Red neuronal convolucional, se muestran multicapas ocultas. Para procesar imágenes a través de capas de convolución, se aplican filtros para detectar patrones visuales (bordes, texturas, y formas) en diferentes zonas de la imagen, estos rasgos se combinan y se pasan a través de diferentes capas para lograr una reducción de la dimensión, esto consiste en un proceso de reducción del número de variables aleatorias que se trate posteriormente, la red neuronal convolucional que está totalmente conectada clasifica las características extraídas en categorías específicas.⁴⁹

Las imágenes de origen se manipulan para acentuar características y se combinan diferentes combinaciones de ellas para contribuir a la definición de la categoría, lo que permite colocar una imagen novedosa en los algoritmos y clasificarla correctamente en una categoría²³. El propósito de las redes neuronales convolucionales es construir una red que identifique automáticamente patrones de detección²⁸ es utilizado

principalmente para procesar imágenes grandes y complejas y es la más utilizada en Odontología ⁵⁰.

1.1.2 Liquen plano oral

El Liquen Plano Oral (LPO) es una enfermedad inflamatoria crónica de la mucosa bucal^{51,52} mediada por células T⁵² y se caracteriza por una interacción compleja de características clínicas, histopatológicas e inmunológicas.

Se deriva de la palabra griega ``*leichen*`` que significa musgo de árbol y del latín ``*planus*`` que significa plano⁵³

1.1.2.1 Epidemiología

La prevalencia del LPO revela una estimación global entre 0,89%⁵⁴ y 1,0% con mayor prevalencia en América del Sur (1,74%), África (1,43%) y Europa (1,32%) con una prevalencia menor en Asia (0,83%) y América del Norte (0,47%)³. La prevalencia agrupada de LPO por sexo fue del 1,55% para las mujeres y del 1,11% para los hombres mostrando mayor predilección por las mujeres⁵⁴; sin embargo, otros estudios no encontraron una predilección por mujeres, como se ha informado previamente en la literatura⁵⁵.

En cuanto a la edad, a partir de los 40 años la prevalencia del LPO aumenta significativamente y de forma progresiva (56). Se ha reportado que el riesgo es 3,43 veces mayor a esta edad en comparación con pacientes más jóvenes. Además, en pacientes mayores de 50 años, el riesgo de desarrollar LPO es 2,23 veces mayor, y en mayores de 60 años, este riesgo es 2,20 veces mayor. Estos datos confirman una relación clara entre el envejecimiento y la mayor frecuencia de esta patología⁵⁵.

1.1.2.2 Etiología

El LPO es una enfermedad de etiología desconocida; sin embargo, los factores genéticos, las enfermedades inmunológicas, la desnutrición, el estado psicológico y la infección se consideran probables factores causantes⁵⁶




Figura 4. Factores etiológicos implicados en la patogénesis de la LP. La enfermedad afecta al portador de genes predisponentes, en quienes los diversos factores ambientales desencadenan el trastorno de la respuesta inmune que resulta en fenotipos específicos de LP. Las influencias de los factores genéticos, ambientales e inmunológicos en el desarrollo de LP son dependientes y están interconectadas entre sí⁵⁷.

1.1.2.2.1 Factores genéticos

Se han identificado marcadores genéticos específicos y polimorfismos asociados con un mayor riesgo de LPO. Los polimorfismos en los genes que codifican citoquinas desempeñan un papel vital en el manejo de la respuesta inmunológica, influyendo en la progresión de la enfermedad⁵⁸

Actualmente hay 132 genes implicados en la etiopatogenia del LPO, pero sólo unos pocos parecen desempeñar un papel importante. Así, según estudios bioinformáticos, los principales genes implicados en la patogénesis de la LPO son los genes JUN, EGFR, FOS, IL2 e ITGB4⁵⁹

1.1.2.2.2 Factores psicológicos

Los pacientes con LPO presentan niveles más altos de ansiedad, estrés, mayor depresión y mayor vulnerabilidad a los trastornos psicológicos⁶⁰.

Existe una correlación positiva entre los receptores adrenérgicos salivales $\alpha 1$ y $\beta 1$ y los niveles de estrés en pacientes con LPO, lo que sugiere un vínculo entre el estrés psicológico y la enfermedad¹¹

Se ha descubierto que el neuroticismo, asociado con el estrés, es mayor en pacientes con LPO, lo que afecta su calidad de vida relacionada con la salud bucal⁶¹. Este hallazgo establece una relación definitiva entre la depresión, la ansiedad, el estrés y el cortisol sérico con el LPO.⁶²

1.1.2.2.3 Factores sistémicos

El LPO puede estar asociado con algunas enfermedades sistémicas; sin embargo, sólo algunos de estos factores han sido investigados a fondo.

1.1.2.2.3.1 *Virus de la hepatitis C*

La infección por el Virus de la Hepatitis C (VHC) está fuertemente asociada con el LPO^{63–66}. Los pacientes con LPO tienen un riesgo aproximadamente cinco veces mayor de seropositividad al VHC en comparación con pacientes sanos⁶⁵. El LPO se ha llegado a considerar una manifestación extrahepática de la infección por VHC⁶⁴

Aunque no se ha determinado exactamente la relación entre el LPO y la VHC, se ha planteado una teoría donde explica que se debe a la citotoxicidad mediada por las células inducidas por citocinas y linfocinas de un epítipo compartido por el VHC y los queratinocitos dañados. Los queratinocitos son los principales objetivos del ataque inmunológico en el LPO, y desempeñan un papel crítico mediante la producción de citocinas. Las células mononucleares infiltrantes de tejido se estimulan *in situ* para diferenciarse y producir una variedad de citocinas características de LPO, lo que modula la inflamación del tejido.⁶⁷

1.1.2.2.3.2 *Hipertensión*

Algunos estudios sugieren una prevalencia significativamente mayor de hipertensión en pacientes con LPO, en comparación con pacientes sin LPO, aunque no se ha establecido una relación causal.^{68–71}. Algunos autores no encuentran algún vínculo significativo entre los valores de los pacientes con liquen plano y los de la población general^{72,73}.

Aunque la prevalencia de hipertensión en pacientes con LPO es mayor que en la población general, se necesita profundizar en la naturaleza de esta relación y si es causal o coincidente.

1.1.2.2.3.3 *Diabetes*

La diabetes mellitus se asocia con el LPO porque hay una mayor prevalencia en pacientes con diabetes mellitus tipo 2 que en aquellos sin diabetes. Esta no se asocia significativamente con la edad, el sexo, el nivel de glucosa en sangre, la duración de la diabetes, las complicaciones diabéticas, los métodos de tratamiento, otras enfermedades sistémicas y el historial de medicación⁷⁴; sin embargo, se ha demostrado que el LPO aparece en el segundo año de diabetes establecida, y su prevalencia fue mayor entre los diabéticos tratados con insulina.⁷⁵

A pesar de la fuerte asociación observada, hasta el momento aún se desconoce el mecanismo biológico implicado en la relación entre la diabetes mellitus y LPO. Se ha planteado la hipótesis de un posible vínculo entre la ingesta de medicamentos hipoglucemiantes en pacientes diabéticos y la aparición de LPO⁷⁶.

Asimismo, se ha observado un aumento en el desarrollo de enfermedades autoinmunes en pacientes con diabetes, lo que parece indicar la existencia de un trastorno autoinmune general en estos pacientes⁷⁷

La diabetes y el LPO están moderadamente asociados. El diagnóstico sistemático de diabetes en pacientes con LPO podría resultar útil.⁷⁸

1.1.2.2.3.4 Disfunción tiroidea

Los pacientes con LPO tienen una prevalencia significativamente mayor de enfermedad de la tiroides en comparación con los pacientes sanos⁷⁹ Existe un vínculo positivo y estadísticamente significativo entre el LPO y la enfermedad tiroidea, lo que sugiere que la enfermedad tiroidea puede estar involucrada en la patogénesis del LPO o que el LPO es una manifestación de la enfermedad tiroidea.^{80,81}

1.1.2.3 Fisiopatología

El LPO es una enfermedad inflamatoria crónica caracterizada por la infiltración de linfocitos T CD8⁺ citotóxicos en el epitelio, induciendo la apoptosis de los queratinocitos basales⁸², y resultando en autoinmunidad⁸³. Las células T CD8⁺ son activadas por el complejo mayor de histocompatibilidad en los queratinocitos o indirectamente por células presentadoras de antígenos a través de CD4⁺ (subconjunto Th1)⁸⁴. Los linfocitos T CD4⁺ predominan en la lámina propia y apoyan la respuesta

inflamatoria mediante la producción de citocinas proinflamatorias como el TNF- α y el IFN- γ , que perpetúan la inflamación y el daño tisular^{82,83}.

La fase de iniciación comienza después de la liberación de patrones moleculares asociados al daño que estimulan los receptores tipo Toll. Este proceso desencadena la abundante secreción de interferón tipo I (IFN- α) regula positivamente quimiocinas y activa las células dendríticas dérmicas inflamatorias que luego migran a los ganglios linfáticos regionales. Allí presentan los antígenos a los linfocitos T vírgenes y, al liberar interleucina (IL) -12 o IL-23, promueven la diferenciación y expansión de las subpoblaciones de linfocitos T1 auxiliares y citotóxicos⁵⁷. La interacción de los queratinocitos, las células presentadoras de antígenos y los linfocitos T en la etapa temprana de la enfermedad, da como resultado una mayor producción de citocinas Th1, como el IFN- γ , que es un evento esencial en el LPO⁵².

En la fase de progresión, los linfocitos T1 y T17, que expresan receptores localizados en la piel, abandonan el torrente sanguíneo y migran al sitio de la inflamación, atraídos por citocinas y quimiocinas derivadas de células innatas y facilitados por una mayor expresión de moléculas de adhesión⁵², los linfocitos T de memoria se activan ante estos estímulos y responden mediante una producción abundante de citocinas, es decir, IFN- γ , TNF- α e IL-2 por Th1, o IL-17 e IL-22, junto con IL-6 y TGF- β , IL-17, estimula una expansión adicional de Th17, reforzando así el círculo vicioso de la inflamación⁸⁵.

El efecto final de las citocinas proinflamatorias es la producción de radicales libres de oxígeno que inducen la apoptosis celular⁸⁶, la activación de las células efectoras Tc1 y Tc17 promueve la cascada de caspasas mediante la interacción de TNF- α y TNF- α -R1, Fas y FasL y mediante la descarga de moléculas citotóxicas como perforina, granzima B y granzulina de los gránulos citoplasmáticos, estas potentes partículas líticas median el daño epidérmico inducido por células T, lo que lleva a la apoptosis de los queratinocitos basales y al fenotipo LP característico emergente⁵².




Figura 5. Papel de las células inmunes en la patogénesis del LPO; (A) La infiltración inmune en el LPO, las células T CD8 + mediaron la activación hiperinmune que condujo a la apoptosis de los queratinocitos basales. (B) Posible mecanismo de respuesta hiperinmune en la mucosa bucal, donde las células T CD8 + son activadas por los queratinocitos orales y las células T CD4 +⁸³.

1.1.2.4 Clasificación y características clínicas

El LPO se clasifica según la apariencia clínica y características morfológicas de las lesiones, existiendo seis subtipos clínicos que pueden observarse individualmente o en combinación⁵³:

- LPO reticular:

Esta es la forma más común, a menudo es asintomático y se caracteriza por estrías blancas o lesiones en forma de encaje conocidas como estrías de Wickham en la mucosa bucal. Estas líneas suelen formar un patrón similar a un encaje⁸⁴.

- LPO erosiva (ulcerativa):

Se presenta con eritema causado por adelgazamiento epitelial, también se puede observar en forma de ulceración junto con formación de una pseudomembrana en la periferia de la lesión, rodeada por estrías queratósicas reticulares⁸⁷. Estas ulceraciones son dolorosas se presentan en la mucosa bucal, la lengua y las encías⁵³.

- LPO atrófica:

Se manifiesta como áreas eritematosas, lisas y brillantes con descamación mínima o nula esto se debe al adelgazamiento y atrofia de la piel o membranas mucosas⁸⁸.

Esta variante puede confundirse con otras afecciones como el penfigoide de las mucosas o el pénfigo vulgar debido a su aspecto eritematoso⁵³.

- LPO papular:

Se caracteriza por presentarse en pápulas pequeñas, poligonales, de superficie plana y color violáceo, elevadas que pueden fusionarse en placas más grandes, las pápulas pueden tener una superficie brillante y un patrón de encaje blanco (estrías de Wickham) en la superficie⁸⁹. Esta forma es menos común y son raras en la mucosa bucal¹⁵.

- LPO en forma de placa:

Aparece como placas blancas homogéneas, ligeramente elevada, multifocal y lisa que a menudo se asemeja a la leucoplasia¹⁵. Puede resultar más difícil diferenciarla de otras lesiones blancas de la mucosa bucal⁸⁷.

- LPO ampollosa:

La forma menos común, caracterizada por ampollas sobre una base eritematosa que pueden romperse y dejar erosiones dolorosas. Esta forma puede parecerse a otros trastornos vesiculo/ampollosos⁹⁰.



Figura 8. Patrones clínicos del LPO. a. reticular, b. erosiva/ ulcerosa, c. atrófica y en forma de placa, y d. descamativa²⁵

1.1.2.5 Características histopatológicas

Las características histopatológicas del LPO incluyen hiperqueratosis del epitelio, degeneración por licuefacción de la capa basal acompañada de apoptosis de los queratinocitos. Histiocitos en un patrón denso en forma de bandas a lo largo de la interfaz epitelio- tejido conectivo en la dermis superficial⁸⁷ debido al infiltrado linfocitario en la lámina propia superficial, atrofia de la capa espinosa, epitelio en dientes de sierra y un depósito eosinofílico homogéneo en la unión epitelio-tejido conectivo^{83,91}. Además, el epitelio superficial puede mostrar signos de erosión/ulceración, que normalmente se observan en el LPO erosivo/ulcerativo⁵³.




Figura 9. Histopatología del LPO. a Microfotografía de bajo aumento que muestra paraqueratosis, infiltrado inflamatorio crónico subepitelial en forma de banda y crestas en dientes de sierra (H y E, aumento original X100). b Microfotografía de alta resolución que muestra varios cuerpos coloides (flechas) y degeneración licuefactiva de queratinocitos basales (puntas de flecha) (H y E, aumento original X200)(25)

1.1.2.6 Diagnóstico

El diagnóstico de LPO implica una evaluación de los aspectos clínicos, junto con una biopsia oral con estudio histopatológico para confirmar el diagnóstico clínico y especialmente valorar presencia de displasia y malignidad^{83,92}. Es importante

diferenciarla de otras enfermedades gingivales y mucocutáneas, que incluyen queratosis friccional, reacciones liquenoides, leucoplasia, lupus eritematoso, pénfigo, penfigoide de membranas mucosas, candidiasis eritematosa, estomatitis ulcerosa crónica y enfermedad de injerto contra huésped⁸⁴

En algunos casos el LPO puede ser difícil de diagnosticar y la inmunofluorescencia directa de la mucosa perilesional puede facilitar el diagnóstico. El valor de la inmunofluorescencia directa para la confirmación de la enfermedad está bien aceptado, especialmente con características histopatológicas no diagnósticas⁵³.

1.1.2.7 Tratamiento

Principalmente, el tratamiento inicial debe enfocarse en aliviar los síntomas dolorosos, reducir el riesgo potencial de transformación maligna^{92,93}. Además, es crucial educar al paciente sobre la importancia de mantener una buena higiene bucal y un estado dental óptimo. La eliminación de cualquier causa de traumatismo de la mucosa también puede contribuir significativamente a controlar la gravedad de las lesiones bucales⁹⁴. Se debe evitar todos los alimentos calientes, salados, ácidos o picantes, así como el tabaquismo y la ingesta de alcohol, especialmente en pacientes con lesiones atróficas y erosivas. Controlar el estrés también es importante para ayudar en el tratamiento⁹⁵. La actitud terapéutica depende de los síntomas asociados y la presentación clínica. En lesiones asintomáticas y no ulcerosas del LPO no se requiere intervención farmacológica y está indicado seguimiento^{53,83,95}.

Cuando el LPO es sintomático y no ulceroso está indicado un anestésico tópico clorhidrato de bencidamina (0,15%). También se puede utilizar hidrocloreuro de bencidamina (tamtum), líquido/spray para aplicación tópica o enjuague bucal. La dosis habitual para un adulto es de al menos 15 ml para enjuague bucal, 3 o 4 veces al día, según la gravedad de las lesiones, esta dosis debe administrarse en intervalos superiores a tres horas, con un máximo de ocho dosis en un período de 24 h. El seguimiento está indicado cada 6 meses⁹⁵.

Para lesiones que no son displásicas y no muestran transformaciones malignas, el tratamiento de elección son los corticosteroides tópicos⁵³. Según la gravedad de las

lesiones, se pueden prescribir los medicamentos disponibles: comprimidos de prednisolona soluble, enjuague bucal 3 o 4 veces en 24 h (5 mg disueltos en 15 ml de agua); tabletas de betametasona soluble (500 mg) disueltas en 10-15 ml de agua, utilizadas como enjuague bucal hasta 4 veces al día; dipropionato de beclometasona (100 mcg/inhalación), propionato de fluticasona (50 mcg/inhalación), inhaladores de dosis medidas, utilizados como aerosoles bucales, aplicados sobre las lesiones hasta 3-4 veces al día⁹⁶. Se aplica pomada de clobetasol (0,05%) en las zonas dolorosas afectadas 3-4 veces en 24 h; crema de fluticasona (0,05%) aplicada sobre lesiones dolorosas 3-4 veces al día⁹⁷.

La evidencia también sugiere que los corticosteroides de mayor potencia, como el clobetasol, son probablemente más efectivos⁹² y que la eficacia de los corticosteroides tópicos es mayor que la de los corticosteroides sistémicos; sin embargo, los casos en los que el LPO no responde a los esteroides tópicos o en pacientes con enfermedad mucocutánea, a menudo se recomienda cambiar al uso de corticosteroides sistémicos^{98,99}. El reducido tiempo de adherencia de los corticoides tópicos a la mucosa representa una de sus principales desventajas³.

Si hay falta de respuesta, en el caso de algún LPO grave y sintomático (atrófico/ulceroso), que no responde a las medidas tópicas y no hay contraindicación para los esteroides sistémicos, se debe considerar la inyección intralesional y submucosa de corticosteroides¹⁰⁰. La inyección recomendada es de 0,2-0,4 ml de una solución de 10 mg/ml de acetónido de triamcinolona (kenacort A) una dosis/semana, 2-3 dosis, en asociación con la administración oral de prednisolona (una dosis de 15-30 mg de prednisolona/día durante 2 semanas; la administración oral de prednisolona se reduce progresivamente a 5 mg por día y se suspende en la tercera semana)¹⁰¹.

La administración sistémica de prednisolona está indicada en caso de lesiones multifocales más graves con grandes áreas de ulceración. La dosis habitual para adultos es de 40 mg de prednisolona al día durante los primeros 5 días y luego la dosis se reduce a 10 a 20 mg de prednisolona al día durante los siguientes 7 a 10 días. Este protocolo de tratamiento puede mejorar significativamente la tasa de curación de las lesiones¹⁰².

Varios estudios han informado que los corticosteroides sistémicos son el tratamiento más eficaz para el LPO; sin embargo, un estudio comparativo que involucró a un total de 49 pacientes con LPO no encontró diferencias en la respuesta entre prednisona sistémica (1 mg/kg/día) con clobetasol tópico en base adhesiva y clobetasol tópico después de un seguimiento medio de 36 meses¹⁰³.

Por lo tanto, los corticosteroides sistémicos generalmente se reservan para casos en los que los enfoques tópicos han fallado, cuando hay LPO erosivo o eritematoso y para LPO generalizado cuando también están afectados la piel, los genitales, el esófago o el cuero cabelludo⁹².

No se recomienda mantener la terapia con corticosteroides a largo plazo debido a probables efectos adversos tales como: supresión adrenocortical, hipertensión, hiperglucemia, aumento de peso, alteración del estado de ánimo, insomnio, irritación gastrointestinal, osteoporosis¹⁰⁴.

En casos con contraindicaciones para esteroides sistémicos (lactancia materna, infecciones herpéticas, glaucoma, embarazo, VIH, tuberculosis, diabetes mellitus o hipertensión), están indicados otros inmunosupresores e inmunomoduladores: Inhibidores de la calcineurina (ciclosporina, tacrolimus, pimecrolimus), micofenolato mofetilo, efalizumab⁹⁵.

El ácido hialurónico en administración tópica puede tener un papel importante en el tratamiento de lesiones bucales erosivas dolorosas¹⁰⁵. También existen algunas modalidades terapéuticas no farmacológicas : terapia PUVA, terapia fotodinámica (PDT) o terapia con láser⁹⁵.

La terapia PUVA es una fotoquimioterapia con 8-metoxipsoraleno y luz ultravioleta de onda larga (PUVA). El protocolo terapéutico incluye la administración oral de metoxipsoraleno, seguida de 2 h de irradiación intraoral con luz ultravioleta en las zonas afectadas. Este protocolo ha mostrado resultados alentadores en el tratamiento de casos graves de LPO^{106,107}.

Para lesiones extrabucles asociadas, el patólogo bucal y el dentista se comunicarán con el dermatólogo u otros especialistas, según corresponda⁹⁵.

1.1.3 Pruebas diagnósticas

Las pruebas diagnósticas se basan en la capacidad de separar adecuadamente las personas sanas de las enfermas, y de no producir falsos positivos o negativos. Las propiedades de las pruebas diagnósticas se describen como sensibilidad y especificidad¹⁰⁸.

1.1.3.1 Medición de especificidad

La especificidad es una métrica crucial para evaluar el rendimiento de las técnicas de clasificación en el análisis de datos sanitarios. Mide la proporción de verdaderos negativos que son correctamente identificados como tales por el clasificador^{109,110}.

La alta especificidad es importante en aplicaciones de atención médica para minimizar los falsos positivos y evitar intervenciones innecesarias o pruebas adicionales para pacientes que no tienen la condición de interés¹¹¹.

La especificidad de una prueba se calcula dividiendo el número de verdaderos negativos por el número de verdaderos negativos y falsos positivos, se calcula dividiendo respectivos dígitos¹¹². Por ejemplo, si una prueba tiene una especificidad del 95%, significa que puede identificar correctamente a 19 de cada 20 personas que no padecen la enfermedad. Cuanto más específica es una prueba menor es la probabilidad de obtener un falso negativo, por lo que un resultado positivo en la prueba es muy fiable y nos da una certeza elevada de que el paciente padece la enfermedad, confirmando el diagnóstico¹¹³.

La especificidad es una métrica crítica para evaluar el desempeño de las pruebas diagnósticas y los modelos de clasificación en el cuidado de la salud, ya que cuantifica la capacidad de identificar correctamente a los pacientes sin la enfermedad de interés¹¹². Maximizar la especificidad manteniendo al mismo tiempo una sensibilidad adecuada es un objetivo importante en el desarrollo de pruebas clínicas precisas y confiables¹¹¹.

1.1.3.2 Medición de sensibilidad

Mide la proporción de verdaderos positivos que son identificados correctamente por el clasificador. La alta sensibilidad es importante en aplicaciones de atención

médica para minimizar los falsos negativos y garantizar que no se pase por alto a los pacientes con la condición de interés^{109,112}.

Una prueba altamente sensible puede descartar con precisión una enfermedad cuando el resultado es negativo.

A mayor número de verdaderos positivos, mayor es la sensibilidad y, viceversa, a mayor sensibilidad menor número de falsos negativos. Por tanto, cuanto más sensible es una prueba diagnóstica menor es la probabilidad de obtener falsos negativos, por lo que un resultado negativo es bastante fiable y permite descartar la presencia de enfermedad¹¹⁰.

La sensibilidad de una prueba se calcula dividiendo el número de verdaderos positivos por la suma de verdaderos positivos y falsos negativos. Por ejemplo, si una prueba tiene una sensibilidad del 90%, puede identificar con precisión a 9 de cada 10 personas que padecen la enfermedad¹¹³.

La sensibilidad es una métrica fundamental para evaluar la precisión de las pruebas de diagnóstico y los modelos de clasificación en la atención sanitaria. Cuantifica la capacidad de identificar correctamente a los pacientes con la enfermedad o condición de interés, maximizar la sensibilidad manteniendo al mismo tiempo una especificidad adecuada es un objetivo importante en el desarrollo de pruebas clínicas confiables.

CAPÍTULO III

MARCO METODOLÓGICO

2.1 Nivel y diseño de investigación.

Tomando en cuenta las clasificación propuesta por Arias-Odón en el 2023¹¹⁴, la presente investigación presenta un nivel exploratorio con diseño documental en línea del tipo revisión de alcance, cuyo marco metodológico sigue la propuesta de Arksey y O'Malley¹¹⁵, orientada a la recopilación y análisis crítico, sistemático y riguroso de la literatura existente, con la finalidad de identificar y “mapear” la cantidad de evidencia disponible, clarificar conceptos, examinar el alcance de la evidencia, detectar brechas o vacíos de conocimiento y descubrir tópicos asociados al tema en cuestión^{116, 117}.

2.2 Criterios de selección

2.2.1 Criterios de inclusión

- Estudios directamente relacionados con el objetivo de esta investigación, que haga referencia a los modelos de IA, datos clínicos ingresados, sensibilidad y especificidad aplicados en el diagnóstico de LPO.
- Artículos científicos, tesis de grado, maestría, y doctorado.
- Investigaciones primarias: ensayos clínicos, estudios de cohorte, reporte de casos, series de casos, estudios de casos y controles y estudios experimentales; investigaciones secundarias como: revisiones narrativas de la literatura, revisiones de alcance, revisiones sistemáticas y metaanálisis.
- Estudios en español, inglés y portugués.
- Estudios desde el año 2013 hasta el año 2024.

2.2.2 Criterios de exclusión

- Estudios no relevantes con la pregunta de investigación.
- Artículos que no tengan el texto completo disponible.
- Estudios que no describan la metodología de las revisiones de investigación utilizada.

2.3 Fuentes de información

2.3.1 Búsqueda electrónica

La búsqueda se realizó desde el 21 de abril del año 2024 hasta el 31 de mayo del año 2024 en diversas fuentes de información científica: base de datos Medline (a través de PubMed); Biblioteca Virtual en Salud y buscadores de acceso abierto como Google Académico.

2.3.2 Estrategia de búsqueda

Se utilizó una combinación de descriptores de ciencias de la salud (DeCS y MeSH) y palabras clave tanto en español, inglés y portugués (ver tabla 1), junto con los operadores lógicos “AND” y “OR” para establecer las estrategias de búsqueda empleadas en las fuentes de información previamente descritas (ver tabla 2).

Tabla 1. Descriptores y palabras clave organizados por categoría.

<i>Categoría</i>		<i>Español</i>	<i>Inglés</i>	<i>Portugués</i>
<i>Inteligencia Artificial</i>	De scriptores	● Inteligencia artificial ● Algoritmos ● Aprendizaje Automático ● Aprendizaje Profundo	● Artificial Intelligence ● Algorithms ● Machine Learning ● Deep Learning	● Inteligência Artificial ● Algoritmos ● Aprendizado de Máquina ● Aprendizado Profundo
	Palabras clave	● Red neuronal convolucional ● Redes neuronales	● Convolutional neural network ● Neural networks	● Rede neural convolucional ● Redes neurais
<i>Liquen Plano Oral</i>	De scriptores	● Liquen Plano Oral	● Lichen Planus, Oral	● Líquen Plano Bucal
<i>Diagnostico</i>		● Diagnóstico	● Diagnosis	● Diagnóstico

Tabla 2. Fuentes de información consultadas, estrategias de búsqueda, filtros aplicados y número de artículos obtenidos.

<i>Fuentes consultadas</i>	<i>Estrategias de búsqueda.</i>	<i>Filtros aplicados</i>	<i>Nº de artículos</i>
<i>PubMed</i> <i>Medline</i>	("Artificial Intelligence" OR "Algorithms" OR "Machine Learning" OR "Deep Learning") AND ("Lichen Planus, Oral") AND ("Diagnosis")	2013-2025	13
<i>Google Académico</i>	(Artificial Intelligence) OR (Algorithms) OR (Machine Learning) OR (Deep Learning) OR (Convolutional neural network) OR (Neural networks) AND (Lichen Planus, Oral)	2013-2025	648
	(Inteligencia Artificial) OR (Aprendizaje Automático) OR (Aprendizaje Profundo) OR (Red neuronal convolucional) OR (Redes neuronales) AND (Liquen Plano Oral)	2013-2025	7
	(Inteligência Artificial) OR (Aprendizado de Máquina) OR (Aprendizado Profundo) AND (Líquen Plano Bucal)	2013-2025	97
<i>BVS</i>	(Artificial Intelligence) OR (Algorithms) OR (Machine Learning) OR (Deep Learning) OR (Convolutional neural network) OR (Neural networks) AND (Lichen Planus, Oral)	2013-2025	5
<i>BVS</i>	(Inteligencia Artificial) OR (Aprendizaje Automático) OR (Aprendizaje Profundo) OR (Red neuronal convolucional) OR (Redes neuronales) AND (Liquen Plano Oral)	2013-2025	1
	(Inteligência Artificial) OR (Aprendizado de Máquina) OR (Aprendizado Profundo) AND (Líquen Plano Bucal)	2013-2025	1

2.4 Cribado y selección de los estudios

Una vez realizada la búsqueda en las fuentes de información, se seleccionaron los artículos de acuerdo a los criterios de inclusión y exclusión a través de un proceso de revisión individual que constó de tres cribados:

1. **Primer cribado:** lectura del título para determinar si el artículo tenía o no relación con la temática en estudio.

2. **Segundo cribado:** lectura del resumen para obtener información sobre el contenido del artículo, tipo de estudio, objetivo, la relevancia en cuanto al presente tema de investigación y la revisión de ciertos aspectos metodológicos.

3. **Tercer cribado:** lectura del texto completo a través de la técnica de lectura *Skimming* y *Scanning* para determinar si cumplía con los criterios para ser incluido en la revisión.

Luego de realizar los cribados y la selección de los estudios, se llevó a cabo una búsqueda manual en dos etapas: la primera constó de la revisión de las listas de referencias de los artículos seleccionados, y la segunda se fundamentó en la búsqueda de nuevos estudios que hayan citado los artículos seleccionados mediante una búsqueda en Google Académico, PubMed.


Estos artículos identificados a través de referencias cruzadas o búsqueda manual, también estuvieron sujetos a los tres cribados de lectura de título, resumen y texto completo para posteriormente, ser incluidos en la presente revisión.

www.bdigital.ula.ve

CAPÍTULO IV

RESULTADOS

Los resultados del cribado y la selección de los artículos que fueron incluidos en esta revisión, son representados en el diagrama de flujo PRISMA-ScR¹¹⁵ modificado:



Artículos excluidos de la lectura a texto completo

En la tabla 3 se mencionan los artículos que fueron excluidos en el cribado de lectura de texto completo. A continuación, se enumeran las razones de la exclusión, a modo de leyenda: texto completo no disponible (1), estudios que no corresponden con

el objetivo de esta investigación (2), estudios que no describan la metodología de la investigación utilizada (3).

Tabla 3. Artículos excluidos tras la lectura de texto completo y razones de exclusión.

Autores y año	Razón
<i>Thirumal Raj (2017)</i> ¹¹⁶	2
<i>Li et al. (2018)</i> ⁷⁹	2
<i>Lee et al. (2024)</i> ⁴⁴	2
<i>Ali y Saudi (2014)</i> ¹¹⁷	2
<i>Naji y El Abbadi(2022)</i> ¹¹⁸	2
<i>Li Pomi et al. (2024)</i> ¹¹⁹	2
<i>Özçift y Gülten(2013)</i> ¹²⁰	2
<i>Rahman, Mahanta(2024)</i> ¹²¹	2
<i>Pinho (2022)</i> ¹²²	2
<i>Ridao (2017)</i> ¹²³	2
<i>Torra(2017)</i> ¹²⁴	2
<i>Qing et al. (2023)</i> ¹²⁵	1
<i>McRae et al. (2024)</i> ¹²⁶	1
<i>Chegani et al. (2023)</i> ¹²⁷	1
<i>Rokhshad et al. (2024)</i> ¹²⁸	1
<i>Adeoye et al. (2021)</i> ¹²⁹	2
<i>Rai et al (2024)</i> ¹³⁰	1
<i>Ye et al. (2024)</i> ¹³¹	1
<i>Lu et al.(2024)</i> ¹³²	1
<i>Cuevas-Nunez et al. (2025)</i> ¹³³	1
<i>Xu et al. (2022)</i> ¹³⁴	2
<i>Ju et al. (2024)</i> ¹³⁵	2

<i>Guner et al. (2013)</i> ¹³⁶	2
<i>Rajendran et al. (2021)</i> ¹³⁷	3
<i>Dubuc (2024)</i> ¹³⁸	2
<i>Mira et al. (2024)</i> ¹³⁹	2
<i>La Mantia et al. (2024)</i> ¹⁴⁰	2
<i>Ramani et al. (2025)</i> ¹⁴¹	2

En el cribado de texto completo se excluyeron 28 artículos, de los cuales 19 se excluyeron por no responder la pregunta de investigación, 8 artículos por no tener texto completo disponible y 1 artículo porque no describe la metodología de la investigación utilizada.

Resultados

En cuanto al diseño de estudio, de los 16 artículos incluidos, se identificaron ocho estudios descriptivos^{29,30,32,142–146}, dos estudios descriptivos retrospectivos^{147,148}, un estudio descriptivo transversal¹⁴⁹, cuatro estudios comparativos^{31,150–152}, y un estudio experimental¹⁵³. La distribución geográfica de las investigaciones fue la siguiente: ocho estudios (50%) fueron realizados en países asiáticos, distribuidos de la siguiente manera: cinco en China^{32,146,151–153}, uno en Corea del Sur¹⁴², uno en Tailandia²⁹ y uno en Pakistán¹⁴³. Tres investigaciones (18,75%) se llevaron a cabo en Oriente Medio: dos en Turquía^{147,149} y una en Arabia Saudita¹⁵⁰. A su vez, tres estudios (18,75%) fueron realizados en Europa: uno en Suiza¹⁴⁴, uno en Alemania¹⁴⁸ y uno en Francia¹⁴⁵. Finalmente, dos estudios (12,5%) fueron desarrollados en Oceanía, específicamente en Australia^{30,31}. No se encontraron investigaciones provenientes del continente americano ni del continente africano dentro del conjunto de artículos incluidos en esta revisión.

En cuanto a la procedencia de los datos clínicos utilizados en los estudios incluidos, se evidenció una marcada predominancia de estudios desarrollados en instituciones académicas, especialmente en facultades de odontología^{29,145,147,149} y hospitales universitarios^{142,144,146,148,151–153}. En menor proporción, se identificaron

estudios basados en bases de datos transcriptómicas públicas, simulaciones clínicas diseñadas por expertos¹⁵⁰, clínicas privadas¹⁴³ (ver gráfico 1).




Gráfico 1. Sitio de desarrollo de los estudios incluidos

En cuanto a los datos clínicos utilizados como entrada para generar los diagnósticos, se identificó un total de 8.818 casos, entre ellos predominó ampliamente el uso de fotografías clínicas de lesiones bucales. Aunque en menor medida, también se identificaron otros tipos de datos como imágenes histológicas³⁰, citologías³¹ e inmunofluorescencia directa¹⁴⁴ (ver gráfico 2).




Gráfico 2. Distribución de los datos clínicos ingresados como entrada para generar diagnósticos

El número de datos clínicos ingresados varió significativamente entre los estudios analizados, oscilando entre 12 y 4.161 casos por trabajo, con una media aproximada de 535 muestras por estudio. En varios estudios, las muestras fueron divididas en grupos con diagnóstico confirmado de LPO y otros con lesiones compatibles dentro del diagnóstico diferencial, tales como displasia epitelial, leucoplasia, pénfigo vulgar, mucositis crónica no específica, candidiasis, carcinoma escamoso oral y lupus eritematoso^{29,30,142,143,145,146,148-150,152,153}.

En cuanto a las características demográficas de los pacientes, cuatro estudios reportaron de manera detallada la edad y el sexo de los casos analizados, en el primer estudio se incluyeron tanto casos de LPO como otras patologías bucales, informando una edad promedio general de $59,8 \pm 14,1$ años y una mayoría de pacientes femeninas (63,8%)³⁰. El segundo estudio consideró tanto pacientes con LPO como controles sanos, con una edad media global de $65,78 \pm 11,1$ años; en este grupo, participaron 43 mujeres (52,4%) y 39 hombres (47,6%)³¹. El tercer estudio se proporcionaron datos separados para tres grupos: pacientes con LPO, pacientes con mucositis crónica no específica (no LPO) y sujetos sanos. Específicamente, el grupo con LPO estuvo conformado por 38 individuos con una edad media de $48,27 \pm 10,82$ años, de los cuales 24 eran mujeres y 14 hombres¹⁴². El último estudio incluyó exclusivamente casos con diagnóstico confirmado de LPO, se analizaron 128 pacientes, con edades medias entre 45,76 y 51,17 años, y una proporción de 73 mujeres (57%) y 55 hombres (43%)¹⁵¹.

En cuanto a la localización anatómica de las lesiones, uno de los estudios reportó que el sitio más comúnmente afectado fue la mucosa bucal, seguida por la superficie lateral de la lengua y la mucosa queratinizada, incluyendo encía y paladar³⁰. En otra investigación, las muestras se distribuyeron en 70 casos en mucosa bucal, 35 en lengua, 10 en encía, siete en surco vestibular y seis en labios¹⁵¹. Por su parte, un tercer estudio reportó que 33 de los casos se localizaban en la mucosa bucal, un caso en la lengua y cuatro casos en otras regiones como encía, vestíbulo o paladar¹⁴² (ver gráfico 3).




Gráfico 3. Distribución general de las lesiones según su localización anatómica en los estudios que reportaron esta variable.

En cuanto a la confirmación diagnóstica de los casos incluidos en los estudios analizados, cuatro de los 16 artículos reportaron el uso de biopsia con diagnóstico histopatológico como estándar de referencia^{29,30,32,147}, otros estudios complementaron la histopatología con otras técnicas diagnósticas, como la inmunofluorescencia directa^{31,144}, o el uso de criterios diagnósticos reconocidos internacionalmente, como los de Van Der Meij¹⁴². Por otro lado, ocho estudios emplearon como criterio confirmatorio la evaluación clínica por expertos, sin referencia explícita al uso de biopsia como *gold standard*^{143,146,148–153}. Un trabajo no reportó confirmación diagnóstica¹⁴⁵.

En los estudios que emplearon imágenes clínicas, se aplicaron diversas técnicas de preprocesamiento destinadas a mejorar la calidad y consistencia de los datos. Las estrategias más frecuentes incluyeron el recorte manual o automático de las imágenes, seguido del redimensionamiento a tamaños estándar como 256×256, 512×512 o 600×600 píxeles, acompañado en la mayoría de los casos por aumento de datos mediante rotación, traslación, escalado o ajuste de brillo e iluminación^{29,146,152,153}. Algunos estudios complementaron estas técnicas con normalización del color o de la

intensidad de píxeles y estandarización visual con herramientas como Photoshop para ajustar resolución y eliminar elementos distractores^{143,151}. En un caso, se aplicó exclusivamente el redimensionamiento a 1024×1024 píxeles, sin otras transformaciones¹⁴⁷, mientras que otro trabajo empleó extracción automática de características visuales mediante el algoritmo SURF¹⁴⁵. También se identificó un estudio que implementó segmentación manual a nivel de píxel validada por observadores expertos para la creación de anotaciones precisas¹⁴⁸.

Entre los estudios basados en imágenes histopatológicas o citológicas, uno estandarizó digitalmente el color de las láminas con QuPath®, y otro empleó sistemas automatizados para identificar regiones con más de 500 células inmunoteñidas, extrayendo variables cuantificables como el H-score^{30,31}. En otro trabajo, los datos clínicos e inmunopatológicos fueron codificados en variables binarias y categóricas, convirtiéndose posteriormente en matrices numéricas para el entrenamiento del modelo¹⁴⁴.

En el caso de los estudios transcriptómicos, uno aplicó filtros estadísticos para eliminar genes de baja expresión y seleccionó variables relevantes mediante pruebas estadísticas, mientras que otro utilizó directamente los valores de expresión génica sin transformación adicional^{32,142}.

Finalmente, los estudios que emplearon datos clínicos redactados en texto estructurado o en formato de casos simulados no reportaron preprocesamiento computacional, ya que los datos fueron ingresados directamente según su redacción original^{149,150}.

Tabla 4. Resumen de los datos clínicos ingresados

Autor y año.	Tipo de datos clínicos	Fuente	Forma de recolección	Formato de los datos	Número de casos	Variedad de lesiones incluidas
Achararit, <i>et al.</i> ²⁹ (2023)	Imágenes clínicas	<i>College of Dental Medicine, Rangsit University</i>	Recolección retrospectiva de archivo clínico	Digitales	1.089	LPO / No LPO (hiperqueratosis, displasia epitelial, carcinoma in situ, úlceras traumáticas, aftas, pénfigo vulgar, penfigoides, membrana mucosas, lupus eritematoso, candidiasis eritematosa)
Albagieh, <i>et al.</i> ¹⁵⁰ (2024)	Casos clínicos simulados	No aplica	Elaborados por consultor en Medicina Oral y Patología Oral	Formato de pregunta opción múltiple A- D o A-E	20 casos clínicos sólo 1 caso de LPO	Diversas patologías bucales incluyendo LPO
Bian, <i>et al.</i> ³² (2024)	Expresión génica	Base de datos pública <i>Gene Expression Omnibus</i> (GEO)	Muestras transcriptómicas obtenidas a partir de biopsias de mucosa bucal	Formato tabular correspondientes a la expresión génica	14	LPO / Mucosa bucal sana

Idrees, <i>et al.</i> ³⁰ (2021)	Histopatología digital	No reportado	Recolección retrospectiva por patólogo	Imágenes histopatológicas digitalizadas (WSI)	130	LPO / lesiones liquenoides bucales, displasia epitelial oral y queratosis sin displasia
Idrees, <i>et al.</i> ³¹ (2022)	Citología e inmunohistoquímica obtenidas de cepillado oral en base líquida	No reportado	Laminillas citológicas escaneadas	Digitalizadas	82	LPO / lesiones liquenoides bucales, lesiones clínicas liquenoides con displasia epitelial
Jeon, <i>et al.</i> ¹⁴² (2015)	Expresión génica (qPCR)	Departamento de Patología Bucal del Hospital Dental de la Universidad Nacional de Seúl	Tejidos incluidos en parafina (FFPE)	Expresión génica por qRT-PCR	81	LPO/ No- LPO/ Mucosa bucal sana
Keser, <i>et al.</i> ¹⁴⁷ (2023)	Imágenes clínicas	Facultad de Odontología de la Universidad de Eskisehir Osmangazi Turquía	Recolección retrospectiva de archivo clínico	Digitales	137	LPO / Mucosa bucal sana

Osipowicz, <i>et al.</i> ¹⁴⁴ (2024)	Datos clínicos + Inmunofluorescencia directa	Hospital Clínico de Universidad Médica de Gdansk, Polonia	Recolección retrospectiva archivos entre 2014 y 2022	Datos tabulados extraídos de informes de inmunofluorescencia directa	80	LPO / mucosa bucal sana
Rashid, <i>et al.</i> ¹⁴³ (2024)	Imágenes clínicas	Clínicas dentales privadas	Fotografías clínicas	Digitales	517	LPO, aftas bucales, herpes labial, gingivostomatitis, cáncer oral y candidiasis
Soltani y Jaouadi ¹⁴⁵ (2022)	Imágenes clínicas	Universidad Ciencias Médicas Gilan	Fotografías clínicas	Digitales	210	LPO, leucoplasia, carcinoma oral de células escamosas, mucosa sana
Su, <i>et al.</i> ¹⁴⁶ (2025)	Imágenes clínicas	Departamento de Estomatología del Hospital Universitario Nacional Cheng Kung- Taiwán	Fotografías clínicas	Digitales	506	LPO, aftas bucales, candidiasis oral, fúngica submucosa oral
Uranbey, <i>et al.</i> ¹⁴⁹ (2024)	Casos clínicos	Departamento de Cirugía Oral y Maxilofacial de la Facultad de Odontología de la Universidad de Gazi- Turquía	Recolección retrospectiva de archivo clínico	Texto	12	Un caso de LPO + otras

Vinayahalingam, <i>et al.</i> ¹⁴⁸ (2024)	Imágenes clínicas	Departamento de Cirugía Oral y Maxilofacial Universidad Charité Berlín- Alemania	Recolección retrospectiva de archivo clínico	Digitales	4161	LPO, leucoplasia, carcinoma oral de células escamosas, mucosa sana
Xie, <i>et al.</i> ¹⁵³ (2024)	Imágenes clínicas	Hospitales colaboradores	Recolección retrospectiva de archivo clínico	Digitales	813	LPO, leucoplasia oral, úlceras bucales
Yu, <i>et al.</i> ¹⁵¹ (2024)	Imágenes clínicas	Hospital estomatológico de la Universidad Médica de Anhui	Recolección retrospectiva de archivo clínico	Digitales	128	LPO
Zhang, <i>et al.</i> ¹⁵² (2024)	Imágenes clínicas	Hospital Universitario de Zhejiang	Recolección retrospectiva de archivo clínico	Digitales	838	LPO, leucoplasia y fibrosis submucosa oral

--	--	--	--	--	--	--

www.bdigital.ula.ve

En cuanto a los diversos modelos de IA utilizados, se emplearon distintos enfoques, agrupables en cuatro grandes categorías: aprendizaje automático clásico (*machine learning*), redes neuronales artificiales (ANN), redes neuronales convolucionales (CNN), y modelos de aprendizaje profundo (*deep learning*) más avanzados como Transformers o modelos de lenguaje.

Entre los modelos de IA empleados en los estudios analizados, los más utilizados fueron las redes neuronales convolucionales (CNN), aplicadas principalmente al procesamiento de imágenes clínicas para tareas de clasificación o segmentación. Estas redes trabajaron con arquitecturas como Xception, InceptionV3, InceptionResNetV2 y otras variantes entrenadas sobre bases como ImageNet, permitiendo detectar patrones visuales característicos del LPO u otras lesiones bucales^{29,143,146,147,153}.

En segundo lugar, destacaron los modelos de aprendizaje profundo, que incorporaron arquitecturas más avanzadas como Transformers, algoritmos de segmentación semántica y plataformas de lenguaje natural. Algunos estudios utilizaron modelos como SegFormer o Mask R-CNN combinados con Swin Transformer para segmentar lesiones a nivel de píxel, mientras que otros integraron sistemas conversacionales como ChatGPT, GPT-4 o Claude Opus para interpretar textos clínicos e imágenes con fines diagnósticos¹⁴⁸⁻¹⁵².

También se emplearon modelos de aprendizaje automático clásico, particularmente máquinas de vectores de soporte (SVM), aplicadas sobre matrices de datos estructurados como perfiles transcriptómicos o biomarcadores inmunohistoquímicos^{31,32}.

En menor proporción, algunos estudios utilizaron redes neuronales artificiales (ANN) de tipo multicapa, integradas a plataformas estadísticas como Statistica o programas de análisis histológico como QuPath, con el fin de clasificar datos inmunopatológicos, citológicos o transcriptómicos^{30,142,144}.

Finalmente, un estudio aplicó un enfoque híbrido, combinando aprendizaje automático clásico con algoritmos metaheurísticos como colonia de abejas artificiales (ABC) y colonia de hormigas (ACO), los cuales fueron utilizados para optimizar un clasificador SVM y mejorar su rendimiento diagnóstico¹⁴⁵ (ver gráfico 4).




Gráfico 4. Tipos de IA utilizados en los estudios analizados, clasificados en cuatro grandes grupos: aprendizaje automático clásico, redes neuronales artificiales (ANN), redes neuronales convolucionales (CNN) y modelos de aprendizaje profundo avanzado.

Los estudios revisados aplicaron diversas estrategias para entrenar sus modelos de IA. Algunos desarrollaron modelos desde cero, utilizando los datos clínicos recopilados como insumo principal para el entrenamiento. Las redes neuronales convolucionales (CNN) fueron entrenadas con imágenes clínicas preprocesadas, en proporciones variables del *dataset*, alcanzando desde el 60% hasta más del 90% de las muestras disponibles^{29,143,146–148,152,153}.

En cuanto al aprendizaje automático clásico, se entrenaron máquinas de vectores de soporte (SVM) con perfiles transcriptómicos y variables morfométricas derivadas de imágenes clínicas, mediante validación cruzada y divisiones porcentuales del conjunto de datos^{32,145}. También se utilizaron modelos de regresión aplicados sobre biomarcadores inmunohistoquímicos, entrenados con el 80% de los datos disponibles³¹.

Tres estudios implementaron redes neuronales artificiales (ANN) sobre distintos tipos de datos clínicos. Uno 24 regiones de interés extraídas de láminas histológicas teñidas³⁰, otro integró datos transcriptómicos y clínicos del paciente sin detallar los algoritmos aplicados¹⁴², y otro más entrenó el modelo con datos clínicos e inmunopatológicos tabulados¹⁴⁴.

Algunos estudios no realizaron entrenamiento adicional en el caso de los modelos de lenguaje natural o IA conversacional, se emplearon directamente sistemas preentrenados como ChatGPT o Claude Opus sin procesos de ajuste ^{149–151}.

Varios estudios optaron por utilizar modelos preentrenados como base para sus sistemas de IA, aprovechando arquitecturas previamente ajustadas con grandes volúmenes de datos. En el procesamiento de imágenes se reportó el uso de arquitecturas como InceptionResNetV2¹⁴³, Mask R-CNN y Swin Transformer preentrenados en el conjunto COCO¹⁴⁸, así como modelos como SegFormer e InceptionNet basados en el dataset ImageNet^{152,153}. Estos modelos fueron posteriormente ajustados o integrados a flujos de segmentación y clasificación clínica.

La mayoría de los estudios restantes desarrollaron sus modelos desde cero o no reportaron el uso de preentrenamiento en sus metodologías^{29–32,142,144–147,149–151}

www.bdigital.ula.ve

Tabla 5. Resumen modelos de IA

<i>Autor y año</i>	Tipo de IA	Aplicación clínica	Datos de entrada	Entrenamiento del modelo
Achararit, <i>et al.</i> ²⁹ (2023)	CNN (Xception, ResNet152V2, EfficientNetB3)	Diferenciar lesiones LPO y no-LPO	Imágenes clínicas	90% de las imágenes clínicas
Albagieh, <i>et al.</i> ¹⁵⁰ (2024)	Modelos de aprendizaje profundo (GPT 3.5, Stable Diffusion, PopAI)	Evaluar la capacidad diagnóstica en comparación con residentes en Medicina Oral y Patología	Texto clínico simulado	Sin entrenamiento adicional
Bian, <i>et al.</i> ³² (2024)	Aprendizaje automático clásico ML, SVM (LASSO)	Clasificación de muestras transcriptómicas LPO y controles sanos	Perfiles de expresión génica	Entrenamiento con 80% de perfiles transcriptómicos
Idrees, <i>et al.</i> ³⁰ (2021)	ANN (QuPath)	Clasificación de LPO vs no-LPO mediante recuento de células inflamatorias	Imágenes histológicas teñidas con Hematoxilina y Eosina	Entrenado con 24 ROI Clasificación nuclear para identificar células inflamatorias
Idrees, <i>et al.</i> ³¹ (2022)	Aprendizaje automático clásico	Diferenciación entre LPO, OLL, OEDL	Imágenes de biomarcadores IHQ cuantificados con H-Score	80% de los datos clínicos

Jeon, <i>et al.</i> ¹⁴² (2015)	Aprendizaje automático/ ANN	Clasificación basada en expresión génica	Expresión de genes en muestras FFPE (IL2RB2, TNFRSF8) y datos clínicos del paciente	Entrenamiento de clasificadores con expresión génica y datos clínicos.
Keser, <i>et al.</i> ¹⁴⁷ (2023)	CNN (Google Net Inception V3)	Clasificación de imágenes bucales	Imágenes clínicas	Entrenado con múltiples iteraciones sobre imágenes clínicas
Osipowicz, <i>et al.</i> ¹⁴⁴ (2024)	ANN (Statistica 13)	Clasificación automática de LPO vs mucosa sana	Datos de inmunofluorescencia directa + edad y sexo	Con datos clínicos e inmunopatológicos
Rashid, <i>et al.</i> ¹⁴³ (2024)	CNN (InceptionResNetV2)	Clasificación de lesiones bucales incluido LPO	Imágenes clínicas	Entrenamiento supervisado 3.087 imágenes clínicas
Soltani y Jaouadi ¹⁴⁵ (2022)	Aprendizaje automático clásico (SVM) optimizado con algoritmos metaheurísticos ABC y ACO	Clasificación diferencial de LPO, leucoplasia, carcinoma oral de células escamosas y mucosa bucal sana.	Conjuntos de 30 características numéricas extraídas de imágenes clínicas	210 muestras divididas por validación cruzada.
Su, <i>et al.</i> ¹⁴⁶ (2025)	CNN	Diagnóstico diferencial automatizado de lesiones de la mucosa bucal	Imágenes clínicas	384 imágenes para entrenamiento, se aplicó aumento de datos

Uranbey, <i>et al.</i> ¹⁴⁹ (2024)	Modelo de aprendizaje profundo (ChatGPT 3.5)	Evaluación de Dx clínico comparando con el Dx confirmado por especialista	Texto clínico completo con detalles del caso	Sin reentrenamiento adicional
Vinayahalingam, <i>et al.</i> ¹⁴⁸ (2024)	Modelo de aprendizaje profundo (Mask R-CNN + Swin Transformer)	Detección y clasificación de LPO, leucoplasia, carcinoma oral de células escamosas y mucosa sana	Imágenes clínicas anotadas pixel por pixel	Entrenado con 3.337 imágenes.
Xie, <i>et al.</i> ¹⁵³ (2024)	CNN	Clasificación de LPO, leucoplasia y úlceras bucales	Imágenes clínicas	532 imágenes aumentadas a 2128 p aumento de datos (rotación, traslaci y escalado)
Yu, <i>et al.</i> ¹⁵¹ (2024)	Modelos de aprendizaje profundo (GPT 4o, GPT con plugin Diagrams y Claude Opus)	Diagnóstico asistido de LPO	Imágenes clínicas	Descripción detallada de LPO antes de mostrar las imágenes
Zhang, <i>et al.</i> ¹⁵² (2024)	Aprendizaje profundo Transformer (SegFormer)	Segmentación semántica automatizada de lesiones (LPO, leucoplasia y fibrosis submucosa oral)	Imágenes clínicas en luz blanca, formato RGB	60% del <i>dataset</i>

En cuanto al rendimiento diagnóstico de los modelos de IA evaluados, se observaron importantes variaciones entre los estudios, dependiendo del tipo de algoritmo, la fuente de datos y la tarea clínica asignada. Algunos autores compararon múltiples modelos dentro del mismo estudio, lo que permitió una visión más completa de sus capacidades diagnósticas, tal es el caso de Achararit *et al.*, quienes evaluaron tres arquitecturas de redes neuronales convolucionales (Xception, ResNet152V2 y EfficientNetB3). El modelo EfficientNetB3 mostró la mayor sensibilidad (96,36%) aunque con menor especificidad (67,27%), mientras que ResNet152V2 se destacó por su especificidad (92,73%). El modelo Xception ofreció un rendimiento más equilibrado, con sensibilidad de 92,73% y especificidad de 83,64%.

El estudio de Jeon *et al.*, quienes evaluaron cinco algoritmos distintos: SVM, Random Forest (RF), Linear Discriminant Analysis (LDA), Naive Bayes (NB) y una red neuronal artificial (NN). Entre ellos, el modelo RF obtuvo los mejores resultados, con sensibilidad de 90%, especificidad de 80%. Idrees *et al.* en 2021 evaluaron el rendimiento del modelo sobre dos grupos celulares diferentes, en el análisis total de células inflamatorias, se obtuvo una sensibilidad del 96% y especificidad del 91,25%, para las células mononucleares, el modelo logró una sensibilidad del 100% y mantuvo la misma especificidad, alcanzando una exactitud de 94,62%.

Idrees *et al.* en 2022 alcanzó un 100% tanto de sensibilidad como de especificidad al combinar biomarcadores inmunohistoquímicos (Ki-67 y BAX). Vinayahalingam *et al.* obtuvieron una sensibilidad del 77,6% y una especificidad del 97,6%, con un desempeño global sólido.

Tres estudios sólo reportaron la sensibilidad de sus modelos, sin especificar la especificidad. Su *et al.* informaron una sensibilidad general de 88,2%, y una específica de 94,1% para casos de LPO. Rashid *et al.* destacaron la importancia del preprocesamiento: con técnicas de aumento de datos, el modelo alcanzó 98% de sensibilidad, sin estas técnicas, la sensibilidad bajó drásticamente 30%. Xie *et al.* informaron una sensibilidad de 88,16%.

Varios estudios no reportaron sensibilidad ni especificidad, pero incluyeron otras métricas relevantes para evaluar el rendimiento. Zhang *et al.* informó una precisión del 88,6%, con métricas propias de segmentación como el mIoU (0,786), mPA (0,879) y Coefficient (0,710). Soltani y Jaouadi evaluaron un clasificador SVM y lo compararon con versiones optimizadas mediante algoritmos metaheurísticos; la exactitud mejoró progresivamente desde 91,9% (SVM) hasta 94,28% (SVM + ACO). Osipowicz *et al.* reportaron una precisión del 71% basada en datos clínicos e inmunofluorescencia directa, mientras que Keser *et al.* indicaron una precisión del 100%, aunque sin especificar más detalles.

Bian *et al.* evaluaron el desempeño diagnóstico individual de genes mediante AUC, con resultados heterogéneos: PI3 (0,755) fue el mejor, mientras que DEFB4A mostró un AUC bajo (0,367). Albagieh *et al.* utilizaron casos clínicos simulados para comparar IA conversacional con residentes, encontrando que los modelos respondieron correctamente el 66,7% de las preguntas sobre LPO, frente al 100% de aciertos por parte de los residentes. Uranbey *et al.* reportaron que ChatGPT fue capaz de realizar un diagnóstico correcto en el primer intento, aunque sin presentar métricas cuantitativas, utilizando como referencia el índice IKEM (mediana de 4). Finalmente, Yu *et al.* evaluó diferentes versiones de modelos de lenguaje, observando que el preentrenamiento mejoró significativamente la precisión: ChatGPT-4.0 aumentó de 59% a 77%, y GPT con plugin Diagrams de 68% a 80%.




Tabla 6. Resumen rendimiento de IA en el diagnóstico de LPO

Autor y año	Modelo de IA evaluado	Aplicación clínica	Tipo de entrada	Sensibilidad
Achararit, <i>et al.</i> ²⁹ (2023)	Xception	Diferenciar lesiones LPO y no-LPO	Imágenes clínicas	92,73%
	ResNet152V2	Diferenciar lesiones LPO y no-LPO	Imágenes clínicas	76,36%
	EfficientNetB3	Diferenciar lesiones LPO y no-LPO	Imágenes clínicas	96,36%
Albagieh, <i>et al.</i> ¹⁵⁰ (2024)	Modelos de aprendizaje profundo (GPT 3.5, <i>Stable Diffusion</i> , PopAI)	Evaluar la capacidad diagnóstica en comparación con residentes en Medicina Oral y Patología	Caso clínico simulado	No reportada
Bian, <i>et al.</i> ³² (2024)	Aprendizaje automático clásico (SVM)	Clasificación de datos transcriptómicos LPO y controles sanos	Perfiles de expresión génica	No reportada

Idrees, <i>et al.</i> ³⁰ (2021)	ANN (QuPath)	Clasificación de LPO vs no-LPO mediante recuento de células inflamatorias	Variables morfológicas celulares	Total de células: 96%
				Mononucleares: 100%
Idrees, <i>et al.</i> ³¹ (2022)	Aprendizaje automático clásico	Diferenciación entre LPO, OLL, OEDL	H- Score de biomarcadores IHQ (Ki-67, BAX, NF-Kb-p65 y AMACR)	Ki-67+ BAX: 100 %
Jeon, <i>et al.</i> ¹⁴² (2015)	SVM (Aprendizaje automático clásico)	Diferenciación entre LPO, mucositis y tejido sano	Expresión de genes obtenida por qRT-PCR (IL12RB2, TNFRSF8)	77%
	RF (Aprendizaje automático clásico)	Diferenciación entre LPO, mucositis y tejido sano	Expresión de genes obtenida por qRT-PCR (IL12RB2, TNFRSF8)	90%
	LDA (Aprendizaje automático clásico)	Diferenciación entre LPO, mucositis y tejido sano	Expresión de genes obtenida por qRT-PCR (IL12RB2, TNFRSF8)	87%
	NN (ANN)	Diferenciación entre LPO, mucositis y tejido sano	Expresión de genes obtenida por qRT-PCR (IL12RB2, TNFRSF8)	79%
	NB (Aprendizaje automático clásico)	Diferenciación entre LPO, mucositis y tejido sano	Expresión de genes obtenida por qRT-PCR (IL12RB2, TNFRSF8)	77%

Keser, <i>et al.</i> ¹⁴⁷ (2023)	CNN entrenada con imágenes clínicas	Detección de LPO vs mucosa sana	Fotografías clínicas	-
Osipowicz, <i>et al.</i> ¹⁴⁴ (2024)	ANN (Statistica 13)	Apoyo al diagnóstico diferencial de LPO basado en resultados de inmunofluorescencia directa	Datos clínicos + DIF	No reportada
Rashid, <i>et al.</i> ¹⁴³ (2021)	CNN con técnicas de aumento de datos	Clasificación automática de LPO y otras lesiones bucales	Fotografías clínicas con aumento de datos	98%
			Fotografías clínicas sin aumento de datos	30%
Soltani y Jaouadi ¹⁴⁵ (2022)	Aprendizaje automático clásico (SVM) optimizado con algoritmos metaheurísticos ABC y ACO	Clasificación diferencial de LPO, leucoplasia, carcinoma oral de células escamosas y mucosa bucal sana.	Conjuntos de 30 características numéricas extraídas de imágenes clínicas	No reportado
Su, <i>et al.</i> ¹⁴⁶ (2025)	CNN	Diagnóstico diferencial automatizado de lesiones mucosas bucales	Imágenes clínicas	94,1 %

Uranbey, <i>et al.</i> ¹⁴⁹ (2024)	Modelo de aprendizaje profundo (ChatGPT 3.5)	Evaluación de Dx clínico comparando con el Dx confirmado por especialista	Texto clínico completo con detalles del caso	No reportada
Vinayahalingam, <i>et al.</i> ¹⁴⁸ (2024)	Modelo de aprendizaje profundo (Mask R-CNN + Swin Transformer)	Detección y clasificación de LPO, leucoplasia, carcinoma oral de células escamosas y mucosa sana	Imágenes clínicas anotadas pixel por pixel	77.6%
Xie, <i>et al.</i> ¹⁵³ (2024)	CNN	Clasificación de LPO, leucoplasia y úlceras bucales	Imágenes clínicas	88.16 %
Yu, <i>et al.</i> ¹⁵¹ (2024)	Modelos de aprendizaje profundo (GPT 4o, GPT con <i>plugin</i> Diagrams y Claude Opus)	Diagnóstico asistido de LPO	Imágenes clínicas	No reportada

Zhang, <i>et al.</i> ¹⁵² (2024)	Aprendizaje profundo Transformer (SegFormer)	Segmentación semántica automatizada de lesiones (LPO, leucoplasia y fibrosis submucosa oral)	Imágenes clínicas en luz blanca, formato RGB	No reportada
---	--	---	---	--------------

www.bdigital.ula.ve

CAPÍTULO V

DISCUSIÓN

La presente revisión de alcance tuvo como objetivo describir la aplicación de la IA en el diagnóstico del LPO, a partir del análisis de 16 artículos científicos publicados entre los años 2015 y 2024. La investigación se centró en identificar los modelos de IA empleados, los tipos de datos clínicos utilizados como entrada, y la sensibilidad y especificidad reportadas por los modelos. En este capítulo se comparan, integran y discuten los hallazgos obtenidos con los resultados de otros estudios relevantes, analizando su posible aplicación clínica en el contexto odontológico y sus implicaciones para la práctica diagnóstica.

2.5 Datos clínicos

2.5.1 Diversidad en las fuentes de datos clínicos utilizados

Uno de los hallazgos más destacados de esta revisión fue la diversidad en los tipos y fuentes de datos clínicos empleados como entrada para los modelos de IA. Se identificaron en total 8.818 registros clínicos, con una marcada predominancia de las imágenes clínicas de lesiones bucales, utilizadas en nueve estudios^{29,143,145–148,151–153}. Esta elección responde a la facilidad de obtención, la naturaleza no invasiva y su aplicabilidad directa en la práctica odontológica. Las imágenes clínicas permiten capturar características visuales clave del LPO, como el patrón reticulado blanquecino, la distribución simétrica bilateral y la presencia de zonas atróficas o ulceradas, elementos diagnósticos que fueron destacados por varios autores^{29,145,146,152}. Además de las imágenes clínicas, se emplearon otros tipos de datos como expresión génica^{32,142}, imágenes histopatológicas³⁰, citologías con inmunohistoquímica³¹, datos clínicos tabulados con inmunofluorescencia directa¹⁴⁴, y casos clínicos en formato narrativo o

simulado^{149,150}, lo que evidencia el interés por explorar distintas fuentes de información diagnóstica, tanto cuantitativas como cualitativas.

Algunos estudios incluidos en esta revisión advirtieron sobre las limitaciones derivadas de la calidad de las imágenes clínicas, identificando factores como la iluminación, el enfoque y el ángulo de captura como posibles fuentes de error que pueden afectar el desempeño de los modelos de IA. En respuesta a estos desafíos, Zhang *et al.* y Xie *et al.* implementaron estrategias de control de calidad, como protocolos de anotación interobservador y revisión estructurada de las imágenes, con el objetivo de mejorar la consistencia en el etiquetado y aumentar la confiabilidad diagnóstica del modelo.

Por otro lado, se evidenció el uso de imágenes histopatológicas digitalizadas³⁰, así como citología en base líquida³¹, lo que marca un enfoque más especializado centrado en patrones tisulares. Estos métodos ofrecen información detallada a nivel celular, permitiendo entrenar modelos con mayor especificidad para diferenciar entre LPO y otras lesiones potencialmente malignas o autoinmunes. Sin embargo, su implementación clínica puede verse limitada por el requerimiento de infraestructura de laboratorio, personal capacitado y costos asociados.

Además, se identificaron aproximaciones más recientes e innovadoras basadas en datos transcriptómicos³² y expresión génica¹⁴², lo cual representa una frontera emergente hacia el diagnóstico molecular en odontología, estas estrategias podrían permitir una caracterización más precisa del LPO y su diferenciación respecto a otras patologías de aspecto similar, pero aún se encuentran en etapas preliminares y requieren validación externa en poblaciones amplias.

Un enfoque interesante fue propuesto por Osipowicz, quien integró variables clínicas e inmunológicas, como historia clínica e inmunofluorescencia directa (DIF), para alimentar el modelo. De manera similar, Uranbey *et al.* diseñó un modelo con datos provenientes de casos reales retrospectivos, incluyendo características clínicas, imágenes panorámicas y tomografías CBCT, simulando con mayor fidelidad la complejidad del diagnóstico clínico cotidiano.

Finalmente, se destaca el caso de Albagieh *et al.*, cuyo modelo fue entrenado exclusivamente con preguntas de opción múltiple basadas en casos clínicos simulados, sin el uso de datos clínicos reales estructurados, aunque esta metodología podría tener valor pedagógico, su aplicabilidad diagnóstica es limitada, ya que no se sustenta en evidencia empírica ni refleja la complejidad del diagnóstico en pacientes reales.

En conjunto, estos hallazgos demuestran que, aunque las fotografías clínicas dominan como fuente de datos, existe una tendencia creciente a explorar fuentes más complejas como imágenes histopatológicas, inmunomarcadores o datos moleculares. Esta diversidad puede enriquecer los modelos diagnósticos basados en IA, pero también implica mayores exigencias metodológicas, para avanzar en su implementación clínica, se requiere estandarizar los métodos de recolección, mejorar el etiquetado de los datos, y realizar comparaciones sistemáticas sobre la eficacia diagnóstica según el tipo de entrada utilizado.

2.5.2 Número de casos y caracterización clínica de las muestras

Una de las principales observaciones metodológicas de esta revisión fue la marcada variabilidad en la cantidad de casos clínicos empleados para entrenar y evaluar los modelos de IA el número de registros utilizados osciló entre 12 y 4.161 por estudio, con una media aproximada de 553 muestras, esta dispersión evidencia tanto el potencial como las limitaciones actuales en el desarrollo de modelos de IA para el diagnóstico del LPO.

Los estudios con volúmenes amplios de datos, como el de Vinayahalingam *et al.* (4.161 imágenes clínicas), ofrecen mayor robustez estadística para el entrenamiento, lo cual favorece la capacidad de generalización del modelo y reduce el riesgo de sobreajuste. En contraste, investigaciones con bases de datos reducidas, como el estudio de Uranbey *et al.*, que sólo incluyó 12 casos reales, reflejan las dificultades que enfrentan muchos entornos clínicos en cuanto al acceso a repositorios estructurados, estandarizados y digitalizados.

En varios estudios incluidos en esta revisión, las muestras fueron divididas en grupos con diagnóstico confirmado de LPO y otros con lesiones compatibles dentro de su diagnóstico diferencial, tales como displasia epitelial, leucoplasia, pénfigo vulgar,

mucositis crónica no específica, candidiasis, carcinoma oral de células escamosas y lupus eritematoso^{29,30,142,143,145,146,148–150,152,153}.

Este enfoque de clasificación multicategoría aumenta la complejidad computacional del modelo, pero representa un mayor valor clínico, ya que simula de forma más realista los escenarios diagnósticos cotidianos, donde el profesional debe discriminar entre múltiples condiciones con presentaciones clínicas similares. Por ello, esta estrategia es esencial para validar la utilidad práctica de los sistemas de IA, que no sólo deben ser capaces de reconocer una patología específica, sino de distinguirla frente a otras alternativas relevantes en el contexto clínico real.

Por otro lado, se identificaron limitaciones importantes en la caracterización clínica y demográfica de las muestras. Sólo cuatro estudios reportaron información detallada sobre edad, sexo o localización anatómica de las lesiones^{30,31,142,151}. En todos ellos se evidenció una ligera predominancia femenina, lo cual concuerda con la epidemiología general del LPO, una enfermedad que afecta con mayor frecuencia a mujeres en edad media o avanzada. Las edades promedio reportadas oscilaron entre los 46 y 66 años, con porcentajes de mujeres que variaron del 52% al 64%.

En cuanto a la localización anatómica, la mucosa bucal fue consistentemente el sitio más afectado, seguido por la lengua, la encía y el paladar, lo que concuerda con las formas clínicas más frecuentes de presentación del LPO^{30,142,151}. Sin embargo, la mayoría de los estudios incluidos no especificaron estas variables, lo cual representa una laguna metodológica importante. La ausencia de estos datos impide evaluar si los modelos presentan sesgos en el reconocimiento de lesiones según su ubicación o características clínicas específicas. La caracterización clínica y demográfica de los casos resulta crucial no solo para comprender mejor el rendimiento de los modelos, sino también para garantizar su equidad diagnóstica ya que los sistemas de IA entrenados con bases de datos poco diversas pueden reproducir sesgos implícitos, afectando su desempeño en poblaciones distintas a las de entrenamiento, por tanto, es importante que futuros estudios incluyan de forma sistemática información sobre sexo, edad, tipo clínico y localización anatómica, lo cual contribuiría a validar la aplicabilidad del modelo en diferentes contextos odontológicos.

2.5.3 Métodos de confirmación diagnóstica

Una dimensión crucial en la construcción de modelos de IA para el diagnóstico del LPO es la forma en que se confirma el diagnóstico de los casos clínicos utilizados como entrada. En esta revisión se observó que cinco estudios utilizaron la biopsia con diagnóstico histopatológico como estándar de referencia, lo que representa el *gold standard* en la identificación del LPO debido a su capacidad para revelar características morfológicas claves como la degeneración de la capa basal, el infiltrado inflamatorio en banda y la hiperqueratosis^{29,30,32,144,147}. Adicionalmente, dos estudios combinaron la biopsia con otras herramientas complementarias de diagnóstico, Osipowicz *et al.* integraron la biopsia con inmunofluorescencia directa (DIF), con el fin de detectar depósitos de fibrina o inmunoglobulinas en la membrana basal, lo cual contribuye a la diferenciación precisa del LPO frente a otras enfermedades vesiculoampollares, como el pénfigo vulgar o el lupus eritematoso. Por su parte Idrees *et al.* en 2022, complementaron la biopsia con inmunohistoquímica, utilizando biomarcadores como Ki-67 y BAX para reforzar el diagnóstico y evaluar la expresión celular en lesiones liquenoides.

Por otro lado, algunos trabajos basaron la clasificación diagnóstica en criterios clínicos estandarizados, como el sistema propuesto por Van der Meij, aplicado por Jeon *et al.*, el cual permite identificar casos de LPO en función de signos clínicos consensuados, sin necesidad de confirmación histológica, este enfoque es válido en presentaciones clínicas clásicas, aunque puede introducir cierto grado de incertidumbre diagnóstica en ausencia de verificación histopatológica.

Ocho estudios se apoyaron exclusivamente en el juicio clínico de especialistas, sin mención a biopsia ni criterios diagnósticos validados^{143,146,148–153} aunque la experiencia profesional tiene un peso importante en la práctica clínica, la falta de una referencia diagnóstica objetiva puede comprometer la precisión de las etiquetas utilizadas para el entrenamiento de los modelos. Ante esta limitación, autores como Zhang *et al.* y Xie *et al.*, implementaron protocolos estructurados de revisión interobservador y anotación por pares, una práctica que mejora la confiabilidad del proceso de etiquetado, aunque no sustituye completamente la necesidad de una fuente diagnóstica sólida y verificable,

la calidad del etiquetado inicial es uno de los factores determinantes del rendimiento de un modelo de IA supervisada, cuando el diagnóstico de referencia es incierto o varía entre observadores, el modelo puede aprender patrones erróneos, afectando su aplicabilidad en la práctica clínica. En este sentido, se destaca la necesidad de establecer estándares mínimos de validación diagnóstica en futuros estudios, especialmente cuando se pretende entrenar modelos para diferenciar el LPO de otras condiciones de apariencia similar.

Finalmente, en el caso de Soltani y Jaouadi, no se reportó de manera explícita el criterio de diagnóstico utilizado para clasificar los casos, lo que limita la evaluación de la validez de las etiquetas empleadas para el entrenamiento del modelo.

2.5.4 Preparación de los datos clínicos

En los estudios revisados se evidenció una importante heterogeneidad en las estrategias aplicadas para la preparación de los datos clínicos antes de ser introducidos en los modelos de IA esta etapa resulta fundamental, ya que la calidad del preprocesamiento incide directamente en la capacidad del sistema para aprender patrones relevantes, minimizar sesgos y mejorar su desempeño en entornos clínicos reales.

En el caso de los estudios que utilizaron imágenes clínicas, el preprocesamiento incluyó con frecuencia el recorte de las fotografías para centrar la zona lesional, la redimensión de las imágenes a tamaños estandarizados (como 256×256 px en Achararit *et al.*, 224×224 en Rashid *et al.*, 600×600 en Xie *et al.* o 512×512 en Zhang *et al.*, y la aplicación de técnicas de aumento de datos, como rotación, escalado, traslación o modificación del brillo, con el objetivo de mejorar la robustez del modelo ante variaciones clínicas^{29,143,144,146,152,153}. Algunos autores también aplicaron métodos de estandarización más avanzados, como la corrección de balance de blancos, eliminación de fondos irrelevantes y difuminado de rasgos faciales¹⁵¹, o la segmentación por píxeles anotada manualmente por clínicos calibrados¹⁴⁸. En el caso del estudio de Soltani, se optó por extraer características visuales mediante el algoritmo SURF, generando vectores numéricos por imagen. En cuanto a los estudios basados en histopatología y citología, se emplearon procedimientos específicos como la estandarización digital del

color en láminas histológicas³⁰, el uso del sistema ThinPrep® para citología en base líquida, la cuantificación automática con H-score y la selección de regiones de interés con más de 500 células en imágenes citológicas e inmunohistoquímicas³¹. Los datos transcriptómicos fueron preparados mediante filtrado de genes con baja expresión y selección estadística de características relevantes³², o por extracción de ARN a partir de tejidos en parafina para su análisis por qRT-PCR¹⁴². En estudios que integraron datos clínicos tabulados, se aplicaron codificaciones binarias y categóricas para convertir información inmunopatológica en matrices compatibles con modelos computacionales, como ocurrió en el trabajo de Osipowicz. Por otro lado, en estudios que utilizaron únicamente descripciones clínicas escritas, como Uranbey *et al.* o Albagieh *et al.*, no se realizó preparación computacional previa, ya que los datos fueron introducidos como textos o cuestionarios clínicos simulados elaborados por expertos.

2.6 Inteligencia Artificial

2.6.1 Tipo de modelo de IA usada

Los estudios incluidos en esta revisión aplicaron una variedad de enfoques de IA, los cuales se agrupan en cuatro categorías principales: aprendizaje automático clásico (machine learning), redes neuronales artificiales (ANN), redes neuronales convolucionales (CNN) y modelos de aprendizaje profundo avanzados como los Transformers o los sistemas de lenguaje natural. Esta diversidad metodológica responde a las diferencias en el tipo de datos clínicos empleados y al objetivo diagnóstico planteado en cada investigación.

Dentro del grupo de aprendizaje automático clásico, se destacó el uso de máquinas de vectores de soporte (SVM) y modelos de regresión, particularmente en estudios basados en datos numéricos como perfiles de expresión génica o características extraídas de imágenes clínicas. Por ejemplo, Bian *et al.* aplicó SVM para clasificar casos de LPO a partir de datos transcriptómicos, mientras que Idrees *et al.* en 2022 utilizó modelos estadísticos para analizar biomarcadores inmunohistoquímicos. Soltani combinó SVM con algoritmos de optimización para mejorar la clasificación entre LPO y otras lesiones bucales.

Las redes neuronales artificiales multicapa (ANN) fueron empleadas en modelos que integraron datos clínicos estructurados, histopatológicos o inmunopatológicos. Osipowicz *et al.* entrenó una red neuronal con variables clínicas e inmunológicas para predecir la presencia de LPO, mientras que Idrees *et al.* en 2021 utilizó una (ANN) para identificar células inflamatorias en imágenes histológicas. Jeon *et al.* también combinó este tipo de enfoque con datos de expresión génica y características clínicas del paciente.

Las redes neuronales convolucionales (CNN) fueron el tipo de arquitectura más común, especialmente en estudios que utilizaron imágenes clínicas como datos de entrada. Achararit *et al.*, Su *et al.*, Keser *et al.*, Xie *et al.* y Rashid *et al.* desarrollaron modelos CNN para diferenciar lesiones de LPO respecto a otras condiciones de aspecto similar. Estas redes tienen la capacidad de aprender directamente de las imágenes, reconociendo patrones visuales relevantes para el diagnóstico, lo cual ha demostrado ser altamente eficaz.

Algunos trabajos exploraron arquitecturas más avanzadas basadas en modelos tipo Transformer, diseñadas originalmente para otras aplicaciones, pero que han sido adaptadas al análisis de imágenes clínicas. Zhang *et al.* empleó un modelo Transformer para segmentar lesiones de LPO a nivel de píxel, obteniendo resultados prometedores en la delimitación automatizada de lesiones. Por su parte, Vinhaligam combinó este enfoque con una red de detección para clasificar múltiples patologías bucales, entre ellas el LPO.

Finalmente, dos estudios integraron sistemas de IA conversacional o modelos de lenguaje natural. Uranbey *et al.* y Albagieh *et al.* emplearon versiones de ChatGPT para interpretar casos clínicos redactados como descripciones narrativas o simuladas. Este tipo de modelos puede contribuir como herramientas de apoyo diagnóstico al interpretar información escrita, siendo útil en contextos educativos o en regiones con acceso limitado a recursos tecnológicos. Yu *et al.* también utilizó un modelo de lenguaje previamente entrenado, el cual interactuaba con el clínico y procesaba la descripción antes de presentar la imagen, generando una propuesta diagnóstica.

En conjunto, los resultados sugieren que las CNN siguen siendo la estrategia más consolidada y efectiva en tareas de clasificación visual de lesiones bucales, mientras que los modelos basados en lenguaje natural representan una vía emergente con potencial para complementar la toma de decisiones clínicas, especialmente en entornos sin infraestructura avanzada, los modelos híbridos basados en Transformers ofrecen nuevas posibilidades para la segmentación y análisis preciso de lesiones, aunque aún se requieren más estudios validados en entornos clínicos reales. En conjunto, los hallazgos de esta revisión reflejan la amplia gama de modelos de IA aplicables al diagnóstico del LPO, desde algoritmos clásicos estructurados hasta arquitecturas profundas capaces de análisis multimodal. Sin embargo, la elección del modelo debe responder al tipo de datos disponibles, los recursos computacionales, la necesidad de interpretabilidad y el entorno clínico en el que se pretende aplicar, se sugiere que futuras investigaciones exploren comparaciones directas entre modelos, con base en métricas estandarizadas, para determinar cuáles ofrecen el mejor equilibrio entre precisión, velocidad, explicabilidad y costo de implementación.

2.6.2 Estrategias de entrenamiento de los modelos

Uno de los aspectos clave observados en esta revisión fue la forma en que los modelos de IA fueron entrenados. Esta etapa influye directamente en el aprendizaje del sistema, su capacidad de generalización y su posible aplicación clínica. De los estudios incluidos, algunos desarrollaron modelos entrenados completamente desde cero, otros aprovecharon arquitecturas previamente entrenadas en grandes bases de datos, y un tercer grupo utilizó sistemas sin aplicar entrenamiento adicional, esta diversidad refleja tanto las diferencias en los recursos disponibles como la evolución de las estrategias metodológicas.

Varios estudios optaron por construir y entrenar sus modelos desde el inicio, utilizando únicamente los datos clínicos recopilados para tal fin. Este fue el caso de modelos basados en imágenes clínicas^{29,143,146–148,152,153}, transcriptomas³², características numéricas derivadas de imágenes¹⁴⁵, imágenes histológicas³⁰, datos inmunopatológicos tabulados¹⁴⁴, e incluso modelos que integraron expresión génica con datos clínicos¹⁴². En general, estos trabajos destinaron entre el 60 % y el 90 % del

total de datos disponibles al proceso de entrenamiento, empleando particiones o validación cruzada para reducir el riesgo de sobreajuste. Aunque este enfoque permite adaptar el modelo específicamente al tipo de datos clínicos, también puede limitar su capacidad de generalización cuando el tamaño del conjunto de entrenamiento es reducido. Esta situación es común en el ámbito odontológico, donde aún existen pocos repositorios públicos de imágenes bucales bien etiquetadas.

Otros estudios aprovecharon arquitecturas preentrenadas, especialmente en el caso de las redes neuronales convolucionales aplicadas al análisis de imágenes. Rashid *et al.* utilizó InceptionResNetV2, Xie *et al.* y Zhang *et al.* usaron una CNN basada en ImageNet, y Vinhaligam integró Mask R-CNN preentrenado en COCO. Este tipo de modelos han sido previamente entrenados con millones de imágenes generales, por lo que ya han aprendido patrones visuales complejos y sólo requieren un ajuste fino para adaptarse al contexto específico de la mucosa bucal. Esta técnica, conocida como transferencia de aprendizaje, resulta especialmente útil cuando se dispone de un número limitado de imágenes clínicas, ya que acorta el tiempo de entrenamiento, reduce el riesgo de sobreajuste y permite obtener resultados competitivos.

Finalmente, algunos trabajos utilizaron modelos de lenguaje previamente entrenados por sus desarrolladores, sin aplicar procesos de entrenamiento adicional como los realizados con datos clínicos tradicionales. Este fue el caso de Uranbey *et al.* y Albagieh *et al.*, quienes emplearon herramientas como ChatGPT en sus versiones 3.5, junto con otros sistemas conversacionales como Claude Opus, los cuales fueron utilizados directamente para interpretar descripciones clínicas redactadas en lenguaje natural o para responder preguntas tipo test. Estos modelos no fueron entrenados específicamente en datos odontológicos ni ajustados con bases de casos reales, lo que puede limitar su precisión diagnóstica en contextos especializados.

El estudio de Yu *et al.*, aunque también utilizó un modelo preentrenado, introdujo una dinámica distinta: antes de mostrar las imágenes clínicas, se presentó al modelo una descripción detallada de las características del LPO, lo que puede considerarse una forma de contextualización guiada. Aunque esta estrategia no constituye un entrenamiento formal, sí representa un intento por orientar la interpretación del modelo

hacia criterios clínicos relevantes. No obstante, en todos estos casos, los resultados diagnósticos fueron inferiores a los obtenidos por modelos específicamente entrenados con imágenes clínicas, lo que refuerza la importancia de contar con datos clínicos especializados para el desarrollo de sistemas de apoyo diagnóstico más precisos y confiables.

La forma en que se entrena un modelo influye profundamente en su aplicabilidad clínica, los modelos entrenados desde cero permiten una adaptación completa a los datos disponibles, pero exigen bases robustas y un control riguroso. Por su parte, los modelos preentrenados ofrecen ventajas claras en términos de rendimiento y eficiencia, pero deben ajustarse adecuadamente al contexto clínico. Los modelos no entrenados, como los conversacionales, abren nuevas posibilidades en educación y asistencia diagnóstica, pero todavía requieren validación específica en el área odontológica.

2.7 Rendimiento diagnóstico de los modelos de IA

2.7.1 Variabilidad en el reporte de sensibilidad y especificidad.

En esta revisión se observó una considerable heterogeneidad en las métricas utilizadas para evaluar el rendimiento diagnóstico de los modelos de IA. Mientras algunos estudios informaron claramente valores de sensibilidad y especificidad, otros reportaron sólo una de estas métricas, o bien utilizaron otras formas alternativas para medir el desempeño. Por ejemplo, estudios como los de Achararit *et al.*, Jeon *et al.* e Idrees *et al.* en 2021 proporcionaron análisis detallados sobre la sensibilidad y especificidad, permitiendo una evaluación robusta del desempeño diagnóstico. Específicamente, Achararit *et al.* comparó tres modelos CNN, observando una alta sensibilidad en EfficientNetB3 (96,36%), pero a costa de menor especificidad (67,27%), mientras que el modelo ResNet152V2 logró la mejor especificidad (92,73%) pero menor sensibilidad (76,36%), sugiriendo la importancia del equilibrio entre estas métricas según el objetivo clínico. Idrees *et al.* en 2022 destacó particularmente por su excepcional desempeño, alcanzando una sensibilidad y especificidad del 100% al combinar biomarcadores inmunohistoquímicos específicos (Ki-67 y BAX).

En contraste, autores como Su *et al.*, Rashid *et al.* y Xie *et al.* reportaron únicamente la sensibilidad de sus modelos, lo que limita parcialmente la interpretación clínica de sus resultados. Rashid *et al.* destacó especialmente el efecto crítico del preprocesamiento: con técnicas de aumento de datos alcanzó una sensibilidad del 98%, pero sin estas técnicas la sensibilidad cayó hasta un 30%. Esto subraya la importancia de optimizar las estrategias de preparación de datos antes del entrenamiento.

2.7.2 Uso de otras métricas relevantes

Dado que no todos los estudios reportaron sensibilidad y especificidad, varias investigaciones recurrieron a métricas diagnósticas alternativas que también aportan información clínica valiosa. Soltani y Jaouadi utilizaron la exactitud como principal métrica, mostrando una mejora gradual del rendimiento desde un modelo básico de SVM (91,9%) hasta versiones optimizadas con algoritmos metaheurísticos (94,28%). Por su parte, Zhang *et al.* empleó métricas propias de segmentación semántica como el mIoU (0,786), mPA (0,879) y un coeficiente de Dice (0,710), lo cual refleja una capacidad de delimitar con precisión las lesiones bucales. Esto indica la importancia de adaptar las métricas a la tarea específica que realiza el modelo (clasificación vs. segmentación), ya que proporciona una comprensión más adecuada del rendimiento clínico real.

Asimismo, algunos estudios como los de Albagieh *et al.* y Uranbey *et al.* reportaron el desempeño cualitativamente mediante aciertos en la respuesta clínica. Albagieh *et al.* comparó la precisión diagnóstica de modelos conversacionales (66,7%) frente al juicio experto de residentes (100%), lo que evidencia que, aunque prometedores, los modelos basados en lenguaje natural aún requieren mejoras sustanciales para aplicaciones clínicas fiables. Cabe destacar que el rendimiento inferior de estos modelos podría estar relacionado con la ausencia de entrenamiento específico en datos clínicos odontológicos, lo cual limita su capacidad de adaptación al contexto especializado de la práctica clínica bucal.

2.7.3 Factores que influyeron en el rendimiento diagnóstico

El rendimiento diagnóstico de los modelos analizados estuvo influenciado no solo por el algoritmo o arquitectura seleccionada, sino también por aspectos relacionados

con el tipo y calidad de los datos utilizados, el preprocesamiento aplicado y el grado de especialización del entrenamiento. Las redes neuronales convolucionales (CNN), por ejemplo, demostraron un rendimiento consistentemente alto en sensibilidad y especificidad, frecuentemente superior al 90%, especialmente cuando los modelos fueron entrenados con imágenes clínicas cuidadosamente preparadas y aumentadas mediante técnicas específicas. Por el contrario, estudios basados en datos moleculares o transcriptómicos, como el de Jeon *et al.*, exhibieron resultados más variables según el tipo de algoritmo aplicado, destacando modelos como Random Forest, que alcanzó una sensibilidad del 90% y una especificidad del 80%.

El preprocesamiento fue otro factor crítico, como se evidenció claramente en el estudio de Rashid *et al.*, donde técnicas de aumento de datos resultaron decisivas para mantener una sensibilidad alta (98%), comparado con una reducción drástica en su ausencia (30%). De igual forma, el uso de arquitecturas preentrenadas, como en los trabajos de Rashid *et al.*, Vinhaligam *et al.*, Xie *et al.* y Zhang *et al.*, confirmó que la transferencia de aprendizaje ofrece importantes beneficios en términos de eficiencia y rendimiento diagnóstico, especialmente en entornos con limitaciones en la cantidad y calidad de datos disponibles.

Por otra parte, los modelos basados en IA conversacional o lenguaje natural ^{149–151}, aunque prometedores y capaces de mejorar su precisión al ser contextualizados previamente, aún no logran alcanzar el rendimiento diagnóstico obtenido por los modelos entrenados directamente con datos clínicos o imágenes específicas, esta brecha podría explicarse en gran medida por la ausencia de entrenamiento especializado con datos odontológicos reales, sugiriendo que futuras investigaciones deberían considerar ajustes específicos para mejorar su precisión clínica.

Adicionalmente, los estudios con resultados diagnósticos inferiores o con un reporte incompleto de métricas como los de Albagieh *et al.*, Uranbey *et al.*, Jeon *et al.* y Bian *et al.* compartieron ciertas limitaciones metodológicas importantes, incluyendo la falta de anotaciones clínicas detalladas, ausencia o insuficiencia en la segmentación, omisiones en técnicas de validación robustas y la utilización de modelos sin entrenamiento específico en datos odontológicos.

En síntesis, tras este análisis se desprende que los modelos de IA que alcanzaron mejores resultados diagnósticos en LPO presentaron al menos tres características fundamentales en común:

1. Datos clínicos cuidadosamente preparados y anotados, incluyendo procesos sistemáticos de segmentación y preprocesamiento.
2. Uso de modelos robustos, ya sea por arquitecturas avanzadas como CNN combinadas con Transformers, o mediante estrategias de entrenamiento especializado y ajustado.
3. Conjuntos de datos clínicos estructurados y validados, que incorporaron criterios diagnósticos claros y verificables.

Para avanzar hacia una implementación clínica efectiva, futuras investigaciones deberían priorizar estos aspectos como mínimos metodológicos, promoviendo adicionalmente validaciones externas multicéntricas, transparencia en la documentación y estandarización metodológica, para lograr modelos reproducibles y aplicables de manera confiable en el contexto odontológico.

2.8 Análisis complementario: sesgos, limitaciones y decisiones metodológicas

2.8.1 Consideraciones éticas y de sesgo en el uso de IA.

Aunque la IA ofrece beneficios evidentes, también plantea desafíos éticos importantes. Uno de los riesgos más relevantes es la posibilidad de reproducir sesgos presentes en los datos de entrenamiento, como ocurre cuando los modelos se desarrollan con imágenes de pacientes de una etnia, edad o sexo específicos. En esta revisión, se evidenció que pocos estudios reportaron características demográficas detalladas, lo cual impide evaluar la equidad diagnóstica de los modelos analizados.

Además, la creciente automatización del diagnóstico podría generar una dependencia excesiva de la tecnología, desplazando el juicio clínico del profesional. Es esencial que el uso de IA en odontología se base en un modelo de complementariedad, no sustitución, donde el odontólogo siga siendo el principal responsable de la toma de decisiones, interpretando críticamente los resultados emitidos por el sistema. También

será necesario desarrollar marcos regulatorios que definan claramente la responsabilidad legal en casos de error diagnóstico asistido por IA.

2.8.2 Limitaciones de la presente revisión

Esta revisión de alcance presenta ciertas limitaciones que deben ser consideradas al interpretar sus resultados. En primer lugar, la heterogeneidad metodológica entre los estudios incluidos dificultó la comparación directa de métricas diagnósticas, algoritmos utilizados y tipo de datos clínicos empleados. Algunos estudios no reportaron sensibilidad ni especificidad, lo que restringió el análisis cuantitativo comparativo.

Asimismo, el campo de la IA aplicada a la patología bucal es todavía incipiente, por lo que gran parte de los estudios analizados corresponden a diseños exploratorios o preliminares.

2.8.3 Consideraciones sobre estudios excluidos

Durante el proceso de búsqueda y selección de estudios, se identificó una revisión sistemática reciente realizada por Tiwari *et al.*³³ titulada *Artificial Intelligence's Use in the Diagnosis of Mouth Ulcers*, la cual abordaba la aplicación de IA en diversas lesiones ulcerativas bucales, incluyendo el LPO dentro de un conjunto más amplio de patologías como el pénfigo vulgar, úlceras aftosas recurrentes, lupus, OSCC y herpes simple. Aunque el estudio cumple con criterios metodológicos aceptables y recoge hallazgos interesantes sobre el potencial de la IA en este ámbito, fue excluido de esta revisión debido a su enfoque amplio y poco específico sobre el diagnóstico del LPO.

Además, dicho artículo incluye tres estudios^{29,30,147} que ya fueron analizados de forma individual y en mayor profundidad en esta tesis, sin aportar datos nuevos o interpretaciones clínicas adicionales. La información contenida en Tiwari *et al.* Resultó, en algunos casos, redundante o menos detallada, especialmente respecto a las características de entrenamiento, fuentes de datos clínicos o validación de los modelos. Por estas razones, se optó por su exclusión, priorizando estudios que abordaran de forma más directa, específica y profunda la aplicación de IA en el diagnóstico del LPO.

Conclusiones

- Se evidenció que la IA puede alcanzar un desempeño diagnóstico elevado en el reconocimiento de LPO, con valores de sensibilidad y especificidad superiores al 85 % en la mayoría de los estudios revisados, lo que refuerza su utilidad como herramienta complementaria en el diagnóstico clínico.
- Los modelos de IA más utilizados fueron las redes neuronales convolucionales (CNN), especialmente aplicadas sobre imágenes clínicas.
- Los tipos de datos clínicos utilizados como entrada fueron variados, destacando las imágenes clínicas de lesiones bucales como la fuente más frecuente, también se emplearon imágenes histopatológicas, citologías líquidas, matrices transcriptómicas, datos inmunológicos, casos clínicos simulados y descripciones estructuradas.
- Los estudios con mejor rendimiento diagnóstico combinaron múltiples prácticas metodológicas, como la preparación adecuada de los datos (segmentación, normalización y aumento de datos), el uso de criterios diagnósticos validados (biopsia, inmunofluorescencia directa) y el entrenamiento riguroso del modelo (validación cruzada, ajuste fino de modelos preentrenados o entrenamiento desde cero).
- Se constató una falta de estandarización en el diseño y validación de los modelos, así como una escasa caracterización demográfica de las muestras en algunos estudios, lo cual podría generar sesgos en el reconocimiento de lesiones según edad, sexo o localización anatómica.
- La aplicación de la IA en el diagnóstico del LPO representa una oportunidad para mejorar la precisión diagnóstica en odontología, pero su implementación clínica requiere validar los modelos en contextos reales, garantizar la calidad de los datos de entrada y formar al personal en el uso ético y responsable de estas herramientas.
- En la práctica odontológica, la IA podría integrarse como herramienta de apoyo en la detección temprana de lesiones mucosas sospechosas, favoreciendo la referencia oportuna y reduciendo errores diagnósticos.

- En el ámbito académico, estos modelos pueden utilizarse como recursos innovadores en simulaciones clínicas, brindando retroalimentación objetiva y fortaleciendo el razonamiento diagnóstico de los estudiantes, además de familiarizarlos con tecnologías emergentes que formarán parte de su futuro profesional.

Recomendaciones

- Validar los modelos de IA en contextos odontológicos reales, incluyendo diferentes tipos de pacientes, características anatómicas y condiciones clínicas, a fin de garantizar su aplicabilidad y reproducibilidad.
- Promover el uso de sistemas de IA como herramientas complementarias y no sustitutivas del juicio clínico, especialmente en la evaluación de lesiones mucosas con sospecha de LPO, para mejorar la precisión diagnóstica y la referencia oportuna.
- Asegurar que los datos clínicos utilizados para entrenar e implementar modelos de IA provengan de fuentes verificadas y estén acompañados de una confirmación diagnóstica confiable, para reducir el riesgo de sesgos.
- Integrar progresivamente contenidos relacionados con IA en los programas de pregrado y postgrado en odontología, enfocados en su aplicación clínica, principios éticos y análisis crítico de sus resultados.
- Fomentar la estandarización de los procesos de recolección, anotación y preparación de datos clínicos en investigaciones con IA, a fin de facilitar la comparación entre estudios, mejorar la reproducibilidad y elevar la calidad científica en este campo.
- Explorar el uso combinado de diferentes tipos de datos clínicos (imágenes, histología, expresión génica, descripciones clínicas) en modelos multimodales de IA, lo cual podría aumentar la precisión y profundidad del análisis diagnóstico en lesiones bucales complejas como el LPO.

REFERENCIAS

1. González-Moles MÁ, Ramos-García P. Oral lichen planus and related lesions. What should we accept based on the available evidence? Oral Diseases [Internet]. 2023 [citado 19 de marzo de 2024];29(7):2624-37. Disponible en: <https://onlinelibrary.wiley.com/doi/abs/10.1111/odi.14438>
2. Li C, Tang X, Zheng X, Ge S, Wen H, Lin X, et al. Global Prevalence and Incidence Estimates of Oral Lichen Planus: A Systematic Review and Meta-analysis. JAMA Dermatol. 1 de febrero de 2020;156(2):172-81.
3. Gonzalez-Moles MA, Gil-Montoya JA, Ruiz-Avila I, Bravo M. Is oral cancer incidence among patients with oral lichen planus/oral lichenoid lesions underestimated? J Oral Pathol Med. febrero de 2017;46(2):148-53.
4. Arduino PG, Carbone M, Conrotto D, Gambino A, Cabras M, Karimi D, et al. Changing epidemiology of HCV infection in patients with oral lichen planus in north-west Italy. Oral Diseases [Internet]. 2019 [citado 19 de marzo de 2024];25(5):1414-5. Disponible en: <https://onlinelibrary.wiley.com/doi/abs/10.1111/odi.13099>

5. Varghese SS, George GB, Sarojini SB, Vinod S, Mathew P, Mathew DG, et al. Epidemiology of Oral Lichen Planus in a Cohort of South Indian Population: A Retrospective Study. *J Cancer Prev* [Internet]. marzo de 2016 [citado 19 de marzo de 2024];21(1):55-9. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4819667/>
6. Andabak-Rogulj A, Vindiš E, Aleksijević LH, Škrinjar I, Juras DV, Aščić A, et al. Different Treatment Modalities of Oral Lichen Planus—A Narrative Review. *Dent J (Basel)* [Internet]. 12 de enero de 2023 [citado 19 de marzo de 2024];11(1):26. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9857452/>
7. Deng X, Wang Y, Jiang L, Li J, Chen Q. Updates on immunological mechanistic insights and targeting of the oral lichen planus microenvironment. *Front Immunol* [Internet]. 9 de enero de 2023 [citado 19 de marzo de 2024];13:1023213. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9870618/>
8. Li Q, Wang F, Shi Y, Zhong L, Duan S, Kuang W, et al. Single-cell immune profiling reveals immune responses in oral lichen planus. *Front Immunol* [Internet]. 6 de abril de 2023 [citado 19 de marzo de 2024];14:1182732. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10116058/>
9. González-Moles MÁ, de Porras-Carrique T, Ramos-García P. Association of oral lichen planus with hepatic disorders and hepatocellular carcinoma: systematic review and meta-analysis. *Med Oral Patol Oral Cir Bucal* [Internet]. mayo de 2023 [citado 19 de marzo de 2024];28(3):e229-37. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10181030/>
10. Gupta S, Jawanda MK. Oral Lichen Planus: An Update on Etiology, Pathogenesis, Clinical Presentation, Diagnosis and Management. *Indian J Dermatol* [Internet]. 2015 [citado 19 de marzo de 2024];60(3):222-9. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4458931/>
11. Gholizadeh N, Rezayi A, Mirzaii-Dizgah I, Sheykhbahaei N. Saliva Levels of Adrenergic Receptors in Relation to Psychological Factors in Patients with Oral Lichen Planus. *Chin J Dent Res*. 21 de septiembre de 2023;26(3):163-9.
12. González-Moles MÁ, Ramos-García P, Warnakulasuriya S. An appraisal of highest quality studies reporting malignant transformation of oral lichen planus based on a systematic review. *Oral Dis*. noviembre de 2021;27(8):1908-18.
13. Giuliani M, Troiano G, Cordaro M, Corsalini M, Gioco G, Lo Muzio L, et al. Rate of malignant transformation of oral lichen planus: A systematic review. *Oral Dis*. abril de 2019;25(3):693-709.
14. Fitzpatrick SG, Hirsch SA, Gordon SC. The malignant transformation of oral lichen planus and oral lichenoid lesions: a systematic review. *J Am Dent Assoc*. enero de 2014;145(1):45-56.
15. Aghbari SMH, Abushouk AI, Attia A, Elmaraezy A, Menshawy A, Ahmed MS, et al. Malignant transformation of oral lichen planus and oral lichenoid lesions: A meta-analysis of 20095 patient data. *Oral Oncol*. mayo de 2017;68:92-102.
16. González-Moles MÁ, Ramos-García P. An Evidence-Based Update on the Potential for Malignancy of Oral Lichen Planus and Related Conditions: A

- Systematic Review and Meta-Analysis. *Cancers* (Basel) [Internet]. 31 de enero de 2024 [citado 19 de marzo de 2024];16(3):608. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10854587/>
17. Aguirre Urizar JM. Letter to the editor: oral lichenoid disease. A new classification proposal. *Med Oral Patol Oral Cir Bucal*. 1 de abril de 2008;13(4):E224.
 18. Gruda Y, Albrecht M, Buckova M, Haim D, Lauer G, Koch E, et al. Characteristics of Clinically Classified Oral Lichen Planus in Optical Coherence Tomography: A Descriptive Case-Series Study. *Diagnostics* (Basel) [Internet]. 10 de agosto de 2023 [citado 15 de mayo de 2024];13(16):2642. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10453426/>
 19. Gorouhi F, Davari P, Fazel N. Cutaneous and Mucosal Lichen Planus: A Comprehensive Review of Clinical Subtypes, Risk Factors, Diagnosis, and Prognosis. *The Scientific World Journal* [Internet]. 30 de enero de 2014 [citado 18 de mayo de 2024];2014:e742826. Disponible en: <https://www.hindawi.com/journals/tswj/2014/742826/>
 20. Bermejo-Fenoll A, López-Jornet P. Liqueen plano oral: Naturaleza, aspectos clínicos y tratamiento. *RCOE* [Internet]. agosto de 2004 [citado 18 de mayo de 2024];9(4):395-408. Disponible en: https://scielo.isciii.es/scielo.php?script=sci_abstract&pid=S1138-123X20040004000003&lng=es&nrm=iso&tlng=es
 21. Bradić-Vasić M, Pejčić A, Kostić M, Minić I, Obradović R, Stanković I. Lichen planus: Oral manifestations, differential diagnosis and treatment. *Acta stomatologica Naissi* [Internet]. 2020 [citado 19 de marzo de 2024];36(81):1980-94. Disponible en: <https://scindeks.ceon.rs/Article.aspx?artid=0352-52522081980B>
 22. Córdova P, Rubio A, Echeverría P. Oral lichen planus: A look from diagnosis to treatment. *Joralres* [Internet]. 27 de noviembre de 2013 [citado 19 de marzo de 2024];3(1):62-7. Disponible en: <http://www.joralres.com/index.php/JOR/article/view/74/76>
 23. Ferreira GA, Pinto BMG, Paula CCD. Diagnóstico de líquen plano oral. *RSD* [Internet]. 2 de agosto de 2023 [citado 19 de marzo de 2024];12(7):e18312742698. Disponible en: <https://rsdjournal.org/index.php/rsd/article/view/42698>
 24. Shan T, Tay FR, Gu L. Application of Artificial Intelligence in Dentistry. *J Dent Res*. marzo de 2021;100(3):232-44.
 25. Schwendicke F, Samek W, Krois J. Artificial Intelligence in Dentistry: Chances and Challenges. *J Dent Res*. julio de 2020;99(7):769-74.
 26. Núñez Martí JM, Krois J, Schwendicke F, Sauro S. La inteligencia artificial: Qué es, su uso en odontología y qué debemos saber para aplicarla. *Gaceta dental: Industria y profesiones* [Internet]. 2022 [citado 20 de enero de 2024];(342):96-105. Disponible en: <https://dialnet.unirioja.es/servlet/articulo?codigo=8225240>
 27. artificial-intelligence noun - Definition, pictures, pronunciation and usage notes | Oxford Advanced Learner's Dictionary at OxfordLearnersDictionaries.com [Internet]. [citado 20 de enero de 2024]. Disponible en:

<https://www.oxfordlearnersdictionaries.com/definition/english/artificial-intelligence>

28. Cacñahuaray-Martínez G, Gómez-Meza D, Lamas-Lara V, Guerrero ME. Aplicación de la inteligencia artificial en Odontología: Revisión de la literatura. *Odontología Sanmarquina* [Internet]. 1 de julio de 2021 [citado 20 de enero de 2024];24(3):243-53. Disponible en: <https://revistasinvestigacion.unmsm.edu.pe/index.php/odont/article/view/20512>
29. Achararit P, Manaspon C, Jongwannasiri C, Phattaratatip E, Osathanon T, Sappayatosok K. Artificial Intelligence-Based Diagnosis of Oral Lichen Planus Using Deep Convolutional Neural Networks. *Eur J Dent* [Internet]. 20 de enero de 2023 [citado 20 de marzo de 2024];17(4):1275-82. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10756816/>
30. Idrees M, Farah C, Shearston K, Kujan O. A machine-learning algorithm for the reliable identification of oral lichen planus. *Journal of Oral Pathology & Medicine*. 1 de agosto de 2021;50.
31. Idrees M, Shearston K, Farah CS, Kujan O. Immunoexpression of oral brush biopsy enhances the accuracy of diagnosis for oral lichen planus and lichenoid lesions. *Journal of Oral Pathology & Medicine* [Internet]. 2022 [citado 18 de mayo de 2024];51(6):563-72. Disponible en: <https://onlinelibrary.wiley.com/doi/abs/10.1111/jop.13301>
32. Bian J, Yan J, Chen C, Yin L, Liu P, Zhou Q, et al. Development of an immune-related diagnostic predictive model for oral lichen planus. *Medicine (Baltimore)*. 15 de marzo de 2024;103(11):e37469.
33. Tiwari A, Gupta N, Singla D, Ranjan Swain J, Gupta R, Mehta D, et al. Artificial Intelligence's Use in the Diagnosis of Mouth Ulcers: A Systematic Review. *Cureus* [Internet]. [citado 18 de mayo de 2024];15(9):e45187. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10576017/>
34. Rouhiainen L. *Inteligencia Artificial*. Primera Edición. España: Editorial Planeta, S.A; 2018.
35. *Inteligencia Artificial - Margaret A. Boden* - Google Libros [Internet]. [citado 20 de enero de 2024]. Disponible en: <https://books.google.co.ve/books?hl=es&lr=&id=LCnYDwAAQBAJ&oi=fnd&pg=PT3&dq=tesis+sobre+inteligencia+artificial&ots=dsPqBThQj7&sig=090qr1ggGax5dmddn2ZpvuEK6Qg#v=onepage&q&f=false>
36. *Artificial Intelligence in Dentistry: Chances and Challenges* - PubMed [Internet]. [citado 20 de enero de 2024]. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/32315260/>
37. Katwaroo AR, Adesh VS, Lowtan A, Umakanthan S. The diagnostic, therapeutic, and ethical impact of artificial intelligence in modern medicine. *Postgraduate Medical Journal* [Internet]. 1 de mayo de 2024 [citado 15 de mayo de 2024];100(1183):289-96. Disponible en: <https://doi.org/10.1093/postmj/qgad135>
38. Naik N, Hameed BMZ, Shetty DK, Swain D, Shah M, Paul R, et al. Legal and Ethical Consideration in Artificial Intelligence in Healthcare: Who Takes Responsibility? *Front Surg* [Internet]. 14 de marzo de 2022 [citado 15 de mayo de 2024];9(2022):1000000. Disponible en: <https://doi.org/10.3389/fsurg.2022.1000000>

- de 2024];9. Disponible en: <https://www.frontiersin.org/articles/10.3389/fsurg.2022.862322>
39. Zhang J, Zhang Z ming. Ethics and governance of trustworthy medical artificial intelligence. BMC Medical Informatics and Decision Making [Internet]. 13 de enero de 2023 [citado 15 de mayo de 2024];23(1):7. Disponible en: <https://doi.org/10.1186/s12911-023-02103-9>
 40. Machine Learning textbook [Internet]. [citado 20 de enero de 2024]. Disponible en: <http://www.cs.cmu.edu/~tom/mlbook.html>
 41. Krittanawong C, Zhang H, Wang Z, Aydar M, Kitai T. Artificial Intelligence in Precision Cardiovascular Medicine. J Am Coll Cardiol. 30 de mayo de 2017;69(21):2657-64.
 42. Humanity should fear advances in artificial intelligence – Debating Matters [Internet]. [citado 21 de enero de 2024]. Disponible en: <https://debatingmatters.com/topic/humanity-should-fear-advances-in-artificial-intelligence/>
 43. Handelman GS, Kok HK, Chandra RV, Razavi AH, Lee MJ, Asadi H. eDoctor: machine learning and the future of medicine. J Intern Med. diciembre de 2018;284(6):603-19.
 44. Lee JG, Jun S, Cho YW, Lee H, Kim GB, Seo JB, et al. Deep Learning in Medical Imaging: General Overview. Korean J Radiol. 2017;18(4):570-84.
 45. A Big Wave of Deep Learning in Medical Imaging - Analysis of Theory and Applications | IEEE Conference Publication | IEEE Xplore [Internet]. [citado 21 de enero de 2024]. Disponible en: <https://ieeexplore.ieee.org/document/9788412>
 46. A Review of Artificial Intelligence's Neural Networks (Deep Learning) Applications in Medical Diagnosis and Prediction | IEEE Journals & Magazine | IEEE Xplore [Internet]. [citado 21 de enero de 2024]. Disponible en: <https://ieeexplore.ieee.org/abstract/document/9464112>
 47. Tacchino F, Macchiavello C, Gerace D, Bajoni D. An artificial neuron implemented on an actual quantum processor. npj Quantum Information [Internet]. 2018 [citado 18 de mayo de 2024];5. Disponible en: <https://consensus.app/papers/neuron-implemented-quantum-processor-tacchino/4509ee177a80596682598e28c1a7f640/>
 48. Tan M, Le QV. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks [Internet]. arXiv; 2020 [citado 21 de enero de 2024]. Disponible en: <http://arxiv.org/abs/1905.11946>
 49. Mandal M. Introduction to Convolutional Neural Networks (CNN) [Internet]. Analytics Vidhya. 2021 [citado 21 de enero de 2024]. Disponible en: <https://www.analyticsvidhya.com/blog/2021/05/convolutional-neural-networks-cnn/>
 50. Hiraiwa T, Arijji Y, Fukuda M, Kise Y, Nakata K, Katsumata A, et al. A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. Dentomaxillofac Radiol. marzo de 2019;48(3):20180218.
 51. Jung W, Jang S. Oral Microbiome Research on Oral Lichen Planus: Current Findings and Perspectives. Biology (Basel) [Internet]. 9 de mayo de 2022 [citado

- 12 de mayo de 2024];11(5):723. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9138428/>
52. El-Howati A, Thornhill MH, Colley HE, Murdoch C. Immune mechanisms in oral lichen planus. *Oral Dis.* mayo de 2023;29(4):1400-15.
 53. Alrashdan MS, Cirillo N, McCullough M. Oral lichen planus: a literature review and update. *Arch Dermatol Res.* octubre de 2016;308(8):539-51.
 54. Li C, Tang X, Zheng X, Ge S, Wen H, Lin X, et al. Global Prevalence and Incidence Estimates of Oral Lichen Planus: A Systematic Review and Meta-analysis. *JAMA Dermatology* [Internet]. 1 de febrero de 2020 [citado 12 de mayo de 2024];156(2):172-81. Disponible en: <https://doi.org/10.1001/jamadermatol.2019.3797>
 55. González-Moles MÁ, Warnakulasuriya S, González-Ruiz I, González-Ruiz L, Ayén Á, Lenouvel D, et al. Worldwide prevalence of oral lichen planus: A systematic review and meta-analysis. *Oral Diseases* [Internet]. 2021 [citado 12 de mayo de 2024];27(4):813-28. Disponible en: <https://onlinelibrary.wiley.com/doi/abs/10.1111/odi.13323>
 56. Torrente-Castells E, Figueiredo R, Berini-Aytés L, Gay-Escoda C. Clinical features of oral lichen planus. A retrospective study of 65 cases. *Med Oral Patol Oral Cir Bucal.* 1 de septiembre de 2010;15(5):e685-690.
 57. Vičić M, Hlača N, Kaštelan M, Brajac I, Sotošek V, Prpić Massari L. Comprehensive Insight into Lichen Planus Immunopathogenesis. *Int J Mol Sci* [Internet]. 3 de febrero de 2023 [citado 15 de mayo de 2024];24(3):3038. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9918135/>
 58. Maldonado ÁYA, Astudillo ACB. ACTUALIZACIÓN DEL ROL DE LAS CITOQUINAS EN LA ETIOPATOGENIA DE LAS AFTAS ORALES. REVISIÓN SISTEMÁTICA EXPLORATORIA.
 59. Albu C, Bencze MA, Dragomirescu A, Vlădan C, Albu Ș., Russu EA, et al. Oral Lichen Planus Genetics Update. *European Journal of Dental and Oral Health* [Internet]. 2022 [citado 12 de mayo de 2024]; Disponible en: <https://www.semanticscholar.org/paper/Oral-Lichen-Planus-Genetics-Update-Albu-Bencze/9ffeb7877f9bceee730930afec2467fcf0facf71>
 60. Araya MS, Alcayaga GR, Esguep A. Asociación entre alteraciones psicológicas y la presencia de Liquen plano oral, Síndrome boca urente y Estomatitis aftosa recidivante. *Med Oral.*
 61. Gaitán-Cepeda LA, Rivera-Reza DI, Villanueva-Vilchis M del C. Neuroticism and Psychological Stress in Patients Suffering Oral Lichen Planus: Research Evidence of Psycho-Stomatology? *Healthcare (Basel)* [Internet]. 13 de junio de 2023 [citado 12 de mayo de 2024];11(12):1738. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10297908/>
 62. Shah J, Patel AJ. Evaluation Of Serum Cortisol And Psychological Factors In Patients With Oral Lichen Planus. En 2019 [citado 12 de mayo de 2024]. Disponible en: <https://www.semanticscholar.org/paper/Evaluation-Of-Serum-Cortisol-And-Psychological-In-Shah-Patel/b67db8ec9a157ccc02b8fec6a921b9ecd1eaab0>

63. Carrozzo M. Oral diseases associated with hepatitis C virus infection. Part 2: lichen planus and other diseases. Oral diseases [Internet]. 2008 [citado 14 de mayo de 2024];14 3:217-28. Disponible en: <https://consensus.app/papers/diseases-associated-hepatitis-virus-infection-part-carrozzo/8a9f622f05195b93826d53b39df2a802/>
64. Grossmann S de MC, Aguiar MFD de, Teixeira R, Carmo MAD do. Oral lichen planus and chronic hepatitis C: a controversial association. American journal of clinical pathology [Internet]. 2007 [citado 14 de mayo de 2024];127 5:800-4. Disponible en: <https://consensus.app/papers/lichen-planus-hepatitis-association-grossmann/d299c927424a541b8b80cfc450d21475/>
65. Lodi G, Pellicano R, Carrozzo M. Hepatitis C virus infection and lichen planus: a systematic review with meta-analysis. Oral Dis. octubre de 2010;16(7):601-12.
66. Alaizari NA, Al-Maweri S, Al-Shamiri H, Tarakji B, Shugaa-Addin B. Hepatitis C virus infections in oral lichen planus: a systematic review and meta-analysis. Australian dental journal [Internet]. 2016 [citado 14 de mayo de 2024];61 3:282-7. Disponible en: <https://consensus.app/papers/hepatitis-virus-infections-planus-review-metaanalysis-alaizari/f40f58d895b25cc6b610e0d49c964cbe/>
67. Femiano F, Scully C. Functions of the cytokines in relation oral lichen planus-hepatitis C. Med Oral Patol Oral Cir Bucal. 1 de abril de 2005;10 Suppl 1:E40-44.
68. Porras-Carrique T de, Ramos-García P, Gonzalez-Moles M. Hypertension in oral lichen planus: A systematic review and meta-analysis. Oral diseases [Internet]. 2023 [citado 14 de mayo de 2024]; Disponible en: <https://consensus.app/papers/hypertension-lichen-planus-review-metaanalysis-porrascarrique/e42c5d53ef70532dad9e4c61b6eefbc8/>
69. Cassol-Spanemberg J, Blanco-Carrión A, Rivera-Campillo MER de, Estrugo-Devesa A, Jané-Salas E, López-López J. Cutaneous, genital and oral lichen planus: A descriptive study of 274 patients. Medicina Oral, Patología Oral y Cirugía Bucal [Internet]. 2018 [citado 14 de mayo de 2024];24:1-7. Disponible en: <https://consensus.app/papers/lichen-planus-study-patients-cassolspanemberg/3de10cc42e685869861d18e35a3fc2ce/>
70. Lauritano D, Arrica M, Lucchese A, Valente M, Pannone G, Lajolo C, et al. Oral lichen planus clinical characteristics in Italian patients: a retrospective analysis. Head Face Med. 26 de abril de 2016;12:18.
71. Kaomongkolgit R, Daroonpan P, Tantanapornkul W, Palasuk J. Clinical profile of 102 patients with oral lichen planus in Thailand. J Clin Exp Dent. julio de 2019;11(7):e625-9.
72. Christensen E, Holmstrup P, Wiberg-Jørgensen F, Neumann-Jensen B, Pindborg J. Arterial blood pressure in patients with oral lichen planus. Journal of oral pathology [Internet]. 1977 [citado 14 de mayo de 2024];6 3:139-42. Disponible en: <https://consensus.app/papers/blood-pressure-patients-planus-christensen/flb9494b5f1e54c48a4d6fcb50c70893/>
73. Bagewadi A, Bhoweer A kumar, Kailasam S. Oral lichen planus and its association with diabetes mellitus and hypertension. Journal of Indian Academy

- of Oral Medicine and Radiology [Internet]. 2011 [citado 14 de mayo de 2024];23. Disponible en: <https://consensus.app/papers/lichen-planus-association-diabetes-mellitus-bagewadi/62246d20ed465bd4ad4a204ddf8414c9/>
74. Sun Y, Chen D, Deng X, Xu Y, Wang Y, Qiu X, et al. Prevalence of oral lichen planus in patients with diabetes mellitus: A cross-sectional study. *Oral diseases* [Internet]. 2022 [citado 14 de mayo de 2024]; Disponible en: <https://consensus.app/papers/prevalence-lichen-planus-patients-diabetes-sun/f277fc497fe7515493bc305fcd40182c/>
 75. Albrecht M, Bánóczy J, Dinya E, Tamás G. Occurrence of oral leukoplakia and lichen planus in diabetes mellitus. *Journal of oral pathology & medicine : official publication of the International Association of Oral Pathologists and the American Academy of Oral Pathology* [Internet]. 1992 [citado 14 de mayo de 2024];21 8:364-6. Disponible en: <https://consensus.app/papers/occurrence-leukoplakia-lichen-planus-diabetes-mellitus-albrecht/04d6f1ed7e1957d4957cd29c4519ca92/>
 76. Kaomongkolgit R. Oral lichenoid drug reaction associated with antihypertensive and hypoglycemic drugs. *Journal of drugs in dermatology: JDD* [Internet]. 2010 [citado 14 de mayo de 2024];9(1):73-5. Disponible en: <https://europepmc.org/article/med/20120430>
 77. Ramos-Garcia P, Roca-Rodriguez M del M, Aguilar-Diosdado M, Gonzalez-Moles MA. Diabetes mellitus and oral cancer/oral potentially malignant disorders: A systematic review and meta-analysis. *Oral Diseases* [Internet]. 2021 [citado 14 de mayo de 2024];27(3):404-21. Disponible en: <https://onlinelibrary.wiley.com/doi/abs/10.1111/odi.13289>
 78. Mallah N, Varela-Centelles P, Seoane-Romero J, Takkouche B. Diabetes Mellitus and Oral Lichen Planus: A systematic review and meta-analysis. *Oral diseases* [Internet]. 2021 [citado 14 de mayo de 2024]; Disponible en: <https://consensus.app/papers/diabetes-mellitus-oral-lichen-planus-review-metaanalysis-mallah/2f511d2441b15cb99d02649af32f0f25/>
 79. Li D, Li J, Li C lei, Chen Q, Hua H. The Association of Thyroid Disease and Oral Lichen Planus: A Literature Review and Meta-analysis. *Frontiers in Endocrinology* [Internet]. 2017 [citado 14 de mayo de 2024];8. Disponible en: <https://consensus.app/papers/association-thyroid-disease-oral-lichen-planus-li/4811124872a55f7285f337149869419f/>
 80. Keteveva A, Boykova Y, Koynova I, Balcheva M. Correlation between oral lichen planus and thyroid disease. 2018 [citado 14 de mayo de 2024];2. Disponible en: <https://consensus.app/papers/correlation-lichen-planus-thyroid-disease-keteveva/ea582aa024de57e39a56c02407518e47/>
 81. Tang Y, Shi L, Jiang B, Zhou Z, Shen X. A Cross-Sectional Study of Oral Lichen Planus Associated With Thyroid Diseases in East China. *Frontiers in Endocrinology* [Internet]. 2020 [citado 14 de mayo de 2024];10. Disponible en: <https://consensus.app/papers/crosssectional-study-oral-lichen-planus-associated-with-tang/751bdc764a955d89a2cda484638237ef/>

82. Farhi D, Dupin N. Pathophysiology, etiologic factors, and clinical management of oral lichen planus, part I: facts and controversies. *Clinics in Dermatology* [Internet]. 1 de enero de 2010 [citado 15 de mayo de 2024];28(1):100-8. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0738081X09000509>
83. Kumari P, Debta P, Dixit A. Oral Potentially Malignant Disorders: Etiology, Pathogenesis, and Transformation Into Oral Cancer. *Front Pharmacol* [Internet]. 20 de abril de 2022 [citado 18 de mayo de 2024];13:825266. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9065478/>
84. Lavanya N, Jayanthi P, Rao UK, Ranganathan K. Oral lichen planus: An update on pathogenesis and treatment. *J Oral Maxillofac Pathol.* mayo de 2011;15(2):127-32.
85. Husein-ElAhmed H, Steinhoff M. Potential role of INTERLEUKIN-17 in the pathogenesis of oral lichen planus: a systematic review with META-analysis. *J Eur Acad Dermatol Venereol.* octubre de 2022;36(10):1735-44.
86. Georgescu SR, Mitran CI, Mitran MI, Nicolae I, Matei C, Ene CD, et al. Oxidative Stress in Cutaneous Lichen Planus-A Narrative Review. *J Clin Med.* 18 de junio de 2021;10(12):2692.
87. Ismail SB, Kumar SKS, Zain RB. Oral lichen planus and lichenoid reactions: etiopathogenesis, diagnosis, management and malignant transformation. *J Oral Sci.* junio de 2007;49(2):89-106.
88. Rosa-Nieves PM, Antonson M, Georgesen C, Wysong A, Whitley MJ, Arthur M. Characteristics and malignancy transformation rate of 17 patients with oral erosive lichen planus: A case series. *Int J Womens Dermatol* [Internet]. 25 de enero de 2024 [citado 19 de mayo de 2024];10(1):e133. Disponible en: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10810583/>
89. Manifestative Papular Dermatoses: Lichen Ruber Planus of the Mucous Membrane of Oral Cavity. En: *Journal of Clinical and Investigative Dermatology* [Internet]. 2016 [citado 19 de mayo de 2024]. Disponible en: <http://www.avensonline.org/fulltextarticles/JCID-2373-1044-04-0026.html>
90. Huang C, Chen S, Liu Z, Tao J, Wang C, Zhou Y. Familial bullous lichen planus (FBLP): Pedigree analysis and clinical characteristics. *J Cutan Med Surg.* octubre de 2005;9(5):217-22.
91. van der Meij EH, van der Waal I. Lack of clinicopathologic correlation in the diagnosis of oral lichen planus based on the presently available diagnostic criteria and suggestions for modifications. *J Oral Pathol Med.* octubre de 2003;32(9):507-12.
92. Al-Hashimi I, Schifter M, Lockhart PB, Wray D, Brennan M, Migliorati CA, et al. Oral lichen planus and oral lichenoid lesions: diagnostic and therapeutic considerations. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod.* marzo de 2007;103 Suppl:S25.e1-12.
93. Scully C, Carrozzo M. Oral mucosal disease: Lichen planus. *Br J Oral Maxillofac Surg.* enero de 2008;46(1):15-21.

94. Potts AJ, Hamburger J, Scully C. The medication of patients with oral lichen planus and the association of nonsteroidal anti-inflammatory drugs with erosive lesions. *Oral Surg Oral Med Oral Pathol.* noviembre de 1987;64(5):541-3.
95. Rotaru D, Chisnoiu R, Picos AM, Picos A, Chisnoiu A. Treatment trends in oral lichen planus and oral lichenoid lesions (Review). *Exp Ther Med.* diciembre de 2020;20(6):198.
96. Lodi G, Scully C, Carrozzo M, Griffiths M, Sugerman PB, Thongprasom K. Current controversies in oral lichen planus: report of an international consensus meeting. Part 2. Clinical management and malignant transformation. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod.* agosto de 2005;100(2):164-78.
97. Tyldesley WR, Harding SM. Betamethasone valerate aerosol in the treatment of oral lichen planus. *Br J Dermatol.* junio de 1977;96(6):659-62.
98. Snyder RA, Schwartz RA, Schneider JS, Elias PM. Intermittent megadose corticosteroid therapy for generalized lichen planus. *Journal of the American Academy of Dermatology* [Internet]. 1982 [citado 19 de mayo de 2024];6(6):1089-90. Disponible en: <https://www.researchwithrutgers.com/en/publications/intermittent-megadose-corticosteroid-therapy-for-generalized-lich>
99. Silverman S, Lozada-Nur F, Migliorati C. Clinical efficacy of prednisone in the treatment of patients with oral inflammatory ulcerative diseases: a study of fifty-five patients. *Oral Surg Oral Med Oral Pathol.* abril de 1985;59(4):360-3.
100. Vincent SD. Diagnosing and managing oral lichen planus. *J Am Dent Assoc.* mayo de 1991;122(5):93-4, 96.
101. Rc K, Hp L, A S, Yp W. Prompt healing of erosive oral lichen planus lesion after combined corticosteroid treatment with locally injected triamcinolone acetonide plus oral prednisolone. *Journal of the Formosan Medical Association = Taiwan yi zhi* [Internet]. abril de 2013 [citado 19 de mayo de 2024];112(4). Disponible en: <https://pubmed.ncbi.nlm.nih.gov/23537868/>
102. Z R, Z B, Aa R, M A, Vv B, Dv V. ORAL LICHEN PLANUS AND ORAL LICHENOID REACTION--AN UPDATE. *Acta clinica Croatica* [Internet]. diciembre de 2015 [citado 19 de mayo de 2024];54(4). Disponible en: <https://pubmed.ncbi.nlm.nih.gov/27017728/>
103. Carbone M, Goss E, Carrozzo M, Castellano S, Conrotto D, Broccoletti R, et al. Systemic and topical corticosteroid treatment of oral lichen planus: a comparative study with long-term follow-up. *J Oral Pathol Med.* julio de 2003;32(6):323-9.
104. Buchman AL. Side effects of corticosteroid therapy. *J Clin Gastroenterol.* octubre de 2001;33(4):289-94.
105. Eisen D, Carrozzo M, Bagan Sebastian JV, Thongprasom K. Number V Oral lichen planus: clinical features and management. *Oral Dis.* noviembre de 2005;11(6):338-49.
106. Boorghani M, Gholizadeh N, Taghavi Zenouz A, Vatankhah M, Mehdipour M. Oral lichen planus: clinical features, etiology, treatment and management; a review of literature. *J Dent Res Dent Clin Dent Prospects.* 2010;4(1):3-9.

107. Casale M, Moffa A, Vella P, Rinaldi V, Lopez MA, Grimaldi V, et al. Systematic review: the efficacy of topical hyaluronic acid on oral ulcers. *J Biol Regul Homeost Agents*. 27 de diciembre de 2017;31(4 Suppl 2):63-9.
108. Medina MC. Generalidades de las pruebas diagnósticas, y su utilidad en la toma de decisiones médicas. *Revista Colombiana de Psiquiatría* [Internet]. diciembre de 2011 [citado 19 de mayo de 2024];40(4):787-97. Disponible en: http://www.scielo.org.co/scielo.php?script=sci_abstract&pid=S0034-74502011000400015&lng=en&nrm=iso&tlng=es
109. Niyati Gupta NG. Accuracy, Sensitivity and Specificity Measurement of Various Classification Techniques on Healthcare Data. *IOSR-JCE* [Internet]. 2013 [citado 15 de mayo de 2024];11(5):70-3. Disponible en: <http://www.iosrjournals.org/iosr-jce/papers/Vol11-issue5/L01157073.pdf>
110. Guía: Pruebas diagnósticas: Sensibilidad y especificidad - Fistera [Internet]. [citado 22 de enero de 2024]. Disponible en: <https://www.fistera.com/formacion/metodologia-investigacion/pruebas-diagnosticas-sensibilidad-especificidad/>
111. Bak MJ, Albrechtsen NW, Pedersen J, Hartmann B, Christensen M, Vilsbøll T, et al. Specificity and sensitivity of commercially available assays for glucagon and oxyntomodulin measurement in humans. *Eur J Endocrinol*. abril de 2014;170(4):529-38.
112. Vizcaíno-Salazar GJ. Importancia del cálculo de la sensibilidad, la especificidad y otros parámetros estadísticos en el uso de las pruebas de diagnóstico clínico y de laboratorio. *Med Lab* [Internet]. 1 de julio de 2017 [citado 22 de enero de 2024];23(7-8):365-86. Disponible en: <https://medicinaylaboratorio.com/index.php/myl/article/view/34>
113. INTRODUCCIÓN A LA ESTADÍSTICA EN CIENCIAS DE LA SALUD (2ª ED.) | RICARDO LUIS MACCHI | Segunda mano | Casa del Libro [Internet]. [citado 22 de enero de 2024]. Disponible en: <https://www.casadellibro.com/libro-introduccion-a-la-estadistica-en-ciencias-de-la-salud-2-ed/9789500606042/2243091>
114. Arias Odón F. Investigación documental, investigación bibliométrica y revisiones sistemáticas. *REDHECS: Revista electrónica de Humanidades, Educación y Comunicación Social* [Internet]. 2023 [citado 10 de agosto de 2025];31(22):9-28. Disponible en: <https://dialnet.unirioja.es/servlet/articulo?codigo=9489470>
115. Tricco AC, Lillie E, Zarin W, O'Brien KK, Colquhoun H, Levac D, et al. PRISMA Extension for Scoping Reviews (PRISMA-ScR): Checklist and Explanation. *Ann Intern Med* [Internet]. 2 de octubre de 2018 [citado 7 de agosto de 2025];169(7):467-73. Disponible en: <https://www.acpjournals.org/doi/10.7326/M18-0850>
116. Thirumal Raj A. Formulating a clinicopathological algorithm for oral lichenoid dysplasia and related lesions. *Oral Oncol*. agosto de 2017;71:186-7.
117. Ali ShA, Saudi HI. An expert system for the diagnosis and management of oral ulcers. *Tanta Dental Journal* [Internet]. 1 de abril de 2014 [citado 8 de mayo de 2025];20(1):1-10. Disponible en: <https://www.tandfonline.com/doi/10.1080/17447759.2014.903111>

- 2024];11(1):42-6. Disponible en: <https://www.sciencedirect.com/science/article/pii/S1687857414000171>
118. Naji Z, El abbadi N. Skin Diseases Detection Based On Convolutional Neural Network Technique. 2022.
 119. Li Pomi F, Papa V, Borgia F, Vaccaro M, Pioggia G, Gangemi S. Artificial Intelligence: A Snapshot of Its Application in Chronic Inflammatory and Autoimmune Skin Diseases. *Life* [Internet]. abril de 2024 [citado 8 de mayo de 2024];14(4):516. Disponible en: <https://www.mdpi.com/2075-1729/14/4/516>
 120. Özçift A, Gülten A. Genetic algorithm wrapped Bayesian network feature selection applied to differential diagnosis of erythematous-squamous diseases. *Digital Signal Processing* [Internet]. 1 de enero de 2013 [citado 8 de mayo de 2024];23(1):230-7. Disponible en: <https://www.sciencedirect.com/science/article/pii/S1051200412001625>
 121. Rahman T, Mahanta L. Evaluating the Deep Learning Models Performance for Segmentation of Oral Epithelial Dysplasia: A Histological Data-Driven Approach. Vol. 3, *Prabha Materials Science Letters*. 2024.
 122. Pinho RF de C. Inteligência artificial no processo de diagnóstico: utilização de software para comparação de imagens e perspectivas futuras [Internet] [text]. Universidade de São Paulo; 2022 [citado 8 de mayo de 2024]. Disponible en: <https://www.teses.usp.br/teses/disponiveis/23/23154/tde-29062022-092036/>
 123. Ridao Marín D. Desarrollo de un sistema de ayuda a la decisión para tratamientos odontológicos con imágenes digitales. Development of a decision support system for dental treatments with digital images [Internet]. 30 de enero de 2017 [citado 8 de mayo de 2024]; Disponible en: <https://riuma.uma.es/xmlui/handle/10630/12836>
 124. Torra AEM. Sistemas de Ayuda a la Decisión Clínica en Enfermedades de Diagnóstico Complejo. 2017;
 125. Qing M, Yang D, Shang Q, Li W, Zhou Y, Xu H, et al. Humoral immune disorders affect clinical outcomes of oral lichen planus. *Oral Dis*. 1 de julio de 2023;
 126. McRae MP, Rajsri KS, Kerr AR, Vigneswaran N, Redding SW, Janal M, et al. A cytomics-on-a-chip platform and diagnostic model stratifies risk for oral lichenoid conditions. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology* [Internet]. 14 de abril de 2024 [citado 8 de mayo de 2024];0(0). Disponible en: [https://www.oooojournal.net/article/S2212-4403\(24\)00155-X/abstract](https://www.oooojournal.net/article/S2212-4403(24)00155-X/abstract)
 127. Chegani JD, Asadoorian M, Sedghizadeh PP. Artificial Intelligence for Rapid Clinical Diagnosis in Oral Medicine. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology* [Internet]. 1 de febrero de 2023 [citado 8 de mayo de 2024];135(2):e40-1. Disponible en: [https://www.oooojournal.net/article/S2212-4403\(22\)01150-6/abstract](https://www.oooojournal.net/article/S2212-4403(22)01150-6/abstract)
 128. Rokhshad R, Mohammad-Rahimi H, Price JB, Shoorgashti R, Abbasiparashkouh Z, Esmaeili M, et al. Artificial intelligence for classification and detection of oral mucosa lesions on photographs: a systematic review and meta-analysis. *Clin Oral Invest* [Internet]. 13 de enero de 2024 [citado 19 de

- mayo de 2025];28(1):88. Disponible en: <https://doi.org/10.1007/s00784-023-05475-4>
129. Adeoye J, Koohi-Moghadam M, Lo AWI, Tsang RKY, Chow VLY, Zheng LW, et al. Deep Learning Predicts the Malignant-Transformation-Free Survival of Oral Potentially Malignant Disorders. *Cancers* [Internet]. enero de 2021 [citado 19 de mayo de 2025];13(23):6054. Disponible en: <https://www.mdpi.com/2072-6694/13/23/6054>
 130. Rai V, Chakrabarty A, Bose S, Pal D, Bhattacharjee D, Ahmed F, et al. AI-Driven Smartphone Screening for Early Detection of Oral Potentially Malignant Disorders. En: 2024 Ninth International Conference on Science Technology Engineering and Mathematics (ICONSTEM) [Internet]. 2024 [citado 19 de mayo de 2025]. p. 1-5. Disponible en: <https://ieeexplore.ieee.org/document/10568597>
 131. Ye YJ, Han Y, Liu Y, Guo ZL, Huang MW. Utilizing deep learning for automated detection of oral lesions: A multicenter study. *Oral Oncology* [Internet]. 1 de agosto de 2024 [citado 20 de mayo de 2025];155:106873. Disponible en: <https://www.sciencedirect.com/science/article/pii/S136883752400191X>
 132. Lu M, Zhang J, Cao Y, Zhang R, Zhang G. Diagnosing Oral Mucosal Diseases Using Deep Learning. En: 2024 China Automation Congress (CAC) [Internet]. 2024 [citado 20 de mayo de 2025]. p. 1300-5. Disponible en: <https://ieeexplore.ieee.org/document/10864634>
 133. Cuevas-Nunez M, Silberberg VIA, Arregui M, Jham BC, Ballester-Victoria R, Koptseva I, et al. Diagnostic performance of ChatGPT-4.0 in histopathological description analysis of oral and maxillofacial lesions: a comparative study with pathologists. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology* [Internet]. 1 de abril de 2025 [citado 20 de mayo de 2025];139(4):453-61. Disponible en: [https://www.oooojournal.net/article/S2212-4403\(24\)00901-5/abstract](https://www.oooojournal.net/article/S2212-4403(24)00901-5/abstract)
 134. Xu Z, Han Q, Yang D, Li Y, Shang Q, Liu J, et al. Automatic Detection of Image-Based Features for Immunosuppressive Therapy Response Prediction in Oral Lichen Planus. *Front Immunol* [Internet]. 23 de junio de 2022 [citado 20 de mayo de 2025];13. Disponible en: <https://www.frontiersin.org/journals/immunology/articles/10.3389/fimmu.2022.942945/full>
 135. Ju J, Zhang Q, Guan Z, Shen X, Shen Z, Xu P. NTSM: a non-salient target segmentation model for oral mucosal diseases. *BMC Oral Health* [Internet]. 3 de mayo de 2024 [citado 20 de mayo de 2025];24(1):521. Disponible en: <https://doi.org/10.1186/s12903-024-04193-x>
 136. Guneri P, Epstein J, İlhan B, Kaya A, Boyacioglu H. Clinical application of a digital method to improve the accuracy of color perception in toluidine blue stained oral mucosal lesions. *Quintessence international* (Berlin, Germany : 1985). 27 de marzo de 2013;44.
 137. Rajendran S, Lim JH, Yogalingam K, Kallarakkal TG, Zain RB, Jayasinghe RD, et al. The establishment of a multi-source dataset of images on common oral

- lesions [Internet]. 2021 [citado 20 de mayo de 2024]. Disponible en: <https://www.researchsquare.com/article/rs-496890/v1>
138. Dubuc A. Utilisation de nouvelles approches en intelligence artificielle pour le diagnostic de lésions de la muqueuse orale [Internet] [phdthesis]. Université de Toulouse; 2024 [citado 20 de mayo de 2025]. Disponible en: <https://theses.hal.science/tel-04685280>
 139. Mira ES, Sapri AMS, Aljehani RF, Jambi BS, Bashir T, El-Kenawy ESM, et al. Early Diagnosis of Oral Cancer Using Image Processing and Artificial Intelligence. *Fusion: Practice and Applications* [Internet]. 1 de enero de 2024 [citado 20 de mayo de 2025];(Issue 1):293-308. Disponible en: <https://www.americaspj.com/articleinfo/3/show/2348>
 140. La Mantia G, Kiswarday F, Pizzo G, Giuliana G, Oteri G, Cimino MGCA, et al. Detection of Elementary White Mucosal Lesions by an AI System: A Pilot Study. *Oral* [Internet]. diciembre de 2024 [citado 20 de mayo de 2025];4(4):557-66. Disponible en: <https://www.mdpi.com/2673-6373/4/4/43>
 141. Ramani RS, Tan I, Bussau L, O'Reilly LA, Silke J, Angel C, et al. Convolutional neural networks for accurate real-time diagnosis of oral epithelial dysplasia and oral squamous cell carcinoma using high-resolution in vivo confocal microscopy. *Sci Rep* [Internet]. 20 de enero de 2025 [citado 20 de mayo de 2025];15(1):2555. Disponible en: <https://www.nature.com/articles/s41598-025-86400-5>
 142. Jeon SH, Jeon EH, Lee JY, Kim YS, Yoon HJ, Hong SP, et al. The potential of interleukin 12 receptor beta 2 (IL12RB2) and tumor necrosis factor receptor superfamily member 8 (TNFRSF8) gene as diagnostic biomarkers of oral lichen planus (OLP). *Acta Odontologica Scandinavica* [Internet]. 17 de noviembre de 2015 [citado 20 de mayo de 2024];73(8):588-94. Disponible en: <https://doi.org/10.3109/00016357.2014.967719>
 143. Rashid J, Qaisar BS, Faheem M, Akram A, Amin R ul, Hamid M. Mouth and oral disease classification using InceptionResNetV2 method. *Multimed Tools Appl* [Internet]. 1 de marzo de 2024 [citado 20 de mayo de 2024];83(11):33903-21. Disponible en: <https://doi.org/10.1007/s11042-023-16776-x>
 144. Osipowicz K, Turkowski P, Zdolińska-Malinowska I. Classification-Predictive Model Based on Artificial Neural Network Validated by Histopathology and Direct Immunofluorescence for the Diagnosis of Oral Lichen Planus. *Diagnostics* [Internet]. enero de 2024 [citado 20 de mayo de 2025];14(14):1525. Disponible en: <https://www.mdpi.com/2075-4418/14/14/1525>
 145. Soltani R, Jaouadi A. Optimization of Support Vector Machines by Meta-Heuristic Approach for Differential Diagnosis and Classification of Oral Diseases. 2022.
 146. Su AY, Wu ML, Wu YH. Deep learning system for the differential diagnosis of oral mucosal lesions through clinical photographic imaging. *Journal of Dental Sciences* [Internet]. 1 de enero de 2025 [citado 20 de mayo de 2025];20(1):54-60. Disponible en: <https://www.sciencedirect.com/science/article/pii/S1991790224003623>

147. Keser G, Bayrakdar İŞ, Pekiner FN, Çelik Ö, Orhan K. A deep learning algorithm for classification of oral lichen planus lesions from photographic images: A retrospective study. *Journal of Stomatology, Oral and Maxillofacial Surgery* [Internet]. 1 de febrero de 2023 [citado 20 de mayo de 2024];124(1):101264. Disponible en: <https://www.sciencedirect.com/science/article/pii/S2468785522002312>
148. Vinayahalingam S, van Nistelrooij N, Rothweiler R, Tel A, Verhoeven T, Tröltzsch D, et al. Advancements in diagnosing oral potentially malignant disorders: leveraging Vision transformers for multi-class detection. *Clin Oral Invest* [Internet]. 8 de junio de 2024 [citado 20 de mayo de 2025];28(7):364. Disponible en: <https://doi.org/10.1007/s00784-024-05762-8>
149. Uranbey Ö, Özbey F, Kaygısız Ö, Ayrancı F. Assessing ChatGPT's Diagnostic Accuracy and Therapeutic Strategies in Oral Pathologies: A Cross-Sectional Study. *Cureus*. abril de 2024;16(4):e58607.
150. Albagieh H, Alzeer ZO, Alasmari ON, Alkadhi AA, Naitah AN, Almasaad KF, et al. Comparing Artificial Intelligence and Senior Residents in Oral Lesion Diagnosis: A Comparative Study. *Cureus*. enero de 2024;16(1):e51584.
151. Yu S, Sun W, Mi D, Jin S, Wu X, Xin B, et al. Artificial Intelligence Diagnosing of Oral Lichen Planus: A Comparative Study. *Bioengineering* [Internet]. noviembre de 2024 [citado 20 de mayo de 2025];11(11):1159. Disponible en: <https://www.mdpi.com/2306-5354/11/11/1159>
152. Zhang R, Lu M, Zhang J, Chen X, Zhu F, Tian X, et al. Research and Application of Deep Learning Models with Multi-Scale Feature Fusion for Lesion Segmentation in Oral Mucosal Diseases. *Bioengineering* [Internet]. noviembre de 2024 [citado 20 de mayo de 2025];11(11):1107. Disponible en: <https://www.mdpi.com/2306-5354/11/11/1107>
153. Xie F, Xu P, Xi X, Gu X, Zhang P, Wang H, et al. Oral mucosal disease recognition based on dynamic self-attention and feature discriminant loss. *Oral Diseases* [Internet]. 2024 [citado 20 de mayo de 2025];30(5):3094-107. Disponible en: <https://onlinelibrary.wiley.com/doi/abs/10.1111/odi.14732>