ResearchGate

See discussions, stats, and author profiles for this publication at: https://www.researchgate.net/publication/390371171

Sistema de anotación de imágenes radiológicas 2D de periodontitis apical para su estudio mediante Deep Learning

Article · April 2025

DOI: 10.3306/AJHS.2025.40.04.62

CITATIONS
0

READS
4

1 author:

Angel Arturo López-González
Escuela Universitaria ADEMA
422 PUBLICATIONS **2,583** CITATIONS

SEE PROFILE

All content following this page was uploaded by Angel Arturo López-González on 01 April 2025.

The user has requested enhancement of the downloaded file.

eISSN 2255-0569

ORIGINAL

Sistema de anotación de imágenes radiológicas 2D de periodontitis apical para su estudio mediante Deep Learning

2D Radiological Image Annotation System for the Study of Apical Periodontitis Using Deep Learning

Catalina Bennasar Verger[1], Antonio Nadal Martínez[2], Sebastiana Arroyo Bote[3,4,5], José Ignacio Ramírez Manent[5,6], Ángel Arturo López-González[5], Pedro Juan Tárraga López[7]

1. ADEMA, Escuela Universitaria de Odontología, Universidad de las Islas Baleares, 07122 Palma de Mallorca, España
2. Grupo de Investigación en Soft Computing, Procesamiento de Imágenes y Agregación (SCOPIA), Universidad de las Islas Baleares (UIB), 07122 Palma de Mallorca, España 3. Coordinador de Odontología Conservadora, Escuela Universitaria de Odontología ADEMA. 4. Profesor agregado de la Universidad de Barcelona. Investigador del IDIBELL
5. Grupo ADEMA-Salud, Instituto Universitario de Ciencias de la Salud de las Islas Baleares (IUNICS), Palma de Mallorca, España
6. Facultad de Medicina, Universidad de las Islas Baleares, Palma de Mallorca, España
7. Facultad de Medicina, Universidad de Castilla-La Mancha, Albacete, España

Corresponding author
José Ignacio Ramírez Manent
E-mail: jignacioramirez@telefonica.net

Received: 00 - I - 2024
Accepted: 00 - I - 2024

doi: 10.3306/AJHS.2025.40.04.62

Resumen

Introducción: La inteligencia artificial (IA) es una herramienta que ayuda en el diagnóstico de patologías que requieren para su detección imágenes radiográficas. En odontología la periodontitis apical (PA) es una de estas patologías, pues es la presencia de radiolucidez periapical lo que nos indica el diagnóstico de periodontitis apical.
Objetivo: Exponer como la IA, concretamente el deep learning (DL) ayuda al odontólogo en el diagnóstico de la PA y de esta forma favorecer la integración de la IA en el campo odontológico.
Metodología: Se creo una base de datos, con imágenes radiográficas de distintos dientes con lesiones apicales, a los que se les realizó tratamiento endodóntico con la misma técnica de instrumentación y obturación. Para el análisis de las imágenes se ha utilizado el software de AnotIA que permite anotar y segmentar con precisión las radiografías y que ofrece además una serie de herramientas que permiten agregar notas, etiquetas y comentarios detallados. Se han utilizado dos etiquetas, una para indicar que la lesión se ha curado (0) y la otra que no ha curado (1), que se utilizan para contrastar la información proporcionada por el especialista con los resultados obtenidos por DL.
Discusión-Conclusiones: Muchos profesionales presentan unos conocimientos muy limitados para evaluar las aplicaciones de la IA a la odontología. Estos profesionales para conseguir una alta cualidad en cualquier aplicación de la IA en la odontología necesitan un básico conocimiento y unas habilidades para evaluar la IA dental. Es necesaria la formación tanto en pregrado como en el postgrado con el fin de establecer un conjunto mínimo de resultados que los estudiantes deben adquirir cuando se les enseña sobre inteligencia artificial en el terreno bucal y dental. En nuestra investigación, si bien hemos empleado una pequeña muestra de imágenes radiográficas, hemos podido exponer como es nuestra sistemática para poder acceder a realizar un estudio de DL.

Palabras clave: machine learning, deep learning, periodontitis apical.

Abstract

Introduction: Artificial intelligence (AI) is a powerful tool that assists in the diagnosis of pathologies that require radiographic imaging for detection. In dentistry, apical periodontitis (AP) is one such condition, as the presence of periapical radiolucency serves as a key diagnostic indicator.
Objective: To demonstrate how AI, particularly deep learning (DL), supports dental professionals in diagnosing AP, thereby promoting the integration of AI in the dental field.
Methodology: A database was created using radiographic images of various teeth with apical lesions, all of which underwent endodontic treatment using the same instrumentation and obturation technique. For image analysis, the AnotIA software was employed, which enables precise annotation and segmentation of radiographs and offers a range of tools for adding notes, labels, and detailed comments. Two labels were used: one indicating that the lesion had healed (0), and the other indicating that it had not healed (1). These labels were used to compare the specialist's assessment with the results obtained through DL.
Discussion-Conclusions: Many professionals have limited knowledge regarding the application of AI in dentistry. To ensure high-quality implementation of AI in dental practice, these professionals require foundational knowledge and skills to evaluate dental AI systems. Training at both undergraduate and postgraduate levels is essential in order to establish a minimum set of learning outcomes that students must achieve when being taught about AI in the oral and dental domains. In our study, although we worked with a small sample of radiographic images, we were able to present our systematic approach to conducting a DL-based investigation.

Key words: Machine learning, deep learning, apical periodontitis.

Cite as: Bennasar Verger C, Nadal Martínez A, Arroyo Bote S, Ramírez Manent JI, López-González ÁA, Tárraga López PJ. Sistema de anotación de imágenes radiológicas 2D de periodontitis apical para su estudio mediante Deep Learning. *Academic Journal of Health Sciences 2025*;40 (4): 62-68 doi: 10.3306/AJHS.2025.40.04.62

Introducción

La periodontitis apical (PA) es una respuesta inflamatoria causada por la presencia de microorganismos en el canal radicular de un diente infectado afectando a los tejidos periapicales produciendo una pérdida ósea apical[1].

Su oportuno tratamiento es el tratamiento de conductos teniendo como alternativa la indeseada pérdida del diente.

El dentista toma la decisión de realizar uno u otro tratamiento teniendo en cuenta una serie de factores, unos centrados en el paciente, tales como factores preoperatorios, dolor preoperatorio, enfermedades sistémicas (p. ej., diabetes mellitus o enfermedades cardiovasculares), tipo de diente (p. ej., incisivo, canino, premolar o molar) y tamaño de la lesión y otros centrados en las técnicas y materiales endodónticos empleados durante el tratamiento y el tipo de reconstrucción posterior[2-4].

Para analizar la imagen de la periodontitis apical utilizamos, tanto en el diagnóstico como en la evaluación del tratamiento, como primera opción, las radiografías periapicales de dos dimensiones (RP2D) cuya interpretación exhibe una gran susceptibilidad y una gran diferencia entre examinadores[5,6], aunque se disponga de una cuantificación de los cambios producidos en la mineralización y en la estructura del hueso adyacente al sitio de la inflamación mediante el ÍNDICE PAI siendo un método de registro apical desarrollado por Orstavik en 1986[7]. Actualmente la IA es especialmente adecuada para superar la variabilidad en el examen individual subjetivo de las imágenes radiográficas y aumentar la eficacia de la atención al tiempo que reduce costos al eliminar tareas rutinarias[8].

La inteligencia artificial (IA) se refiere a la idea de construir máquinas que sean capaces de realizar tareas que normalmente realizan los humanos[9].

Un subcampo de la IA es el aprendizaje automático, machine learning (ML), en el que se aplican algoritmos para aprender patrones intrínsecos de un conjunto de datos determinado (datos de entrenamiento) con el objetivo de reconocer patrones similares en datos nuevos (datos de prueba). Este objetivo de reconocer patrones puede ser de utilidad en tareas de clasificación, regresión y agrupamiento. Los algoritmos de ML se pueden entrenar de dos formas: supervisada y no supervisada. En el aprendizaje supervisado cada dato del conjunto de entrenamiento tiene una etiqueta con lo cual en este modelo tenemos varias entradas cuyas varias salidas se conocen. El único objetivo con estos datos de entrenamiento es conocer la relación entre los datos de entrada y la salida para posteriormente poder predecir cual será la salida para una entrada de datos de prueba. En cuanto al aprendizaje no supervisado en el conjunto de entrenamiento los datos no están etiquetados y el objetivo es identificar patrones mediante la extracción de las características más relevantes de este conjunto de datos.

Las redes neuronales artificiales (ANNs) superan a los algoritmos más clásicos de ML, particularmente en estructuras de datos complejos, como son imágenes o lenguaje.

La unidad básica de las ANNs es la neurona artificial, que no es más que un modelo matemático inspirado en la neurona humana. Mediante la concatenación de estas neuronas artificiales y la conexión de estas capas mediante operaciones matemáticas se diseña una red que es capaz de resolver tareas tan específicas como clasificación de imágenes (ejemplo, una radiografía con una imagen de periodontitis apical: si o no)[10].

Las redes neuronales profundas, deep learning (DL), se refieren a ANNs con múltiples capas, de tal manera que los datos de entrenamiento pasan repetidamente por las múltiples capas da las redes neuronales. Este proceso se conoce como entrenamiento de la red, donde en cada iteración o época se ajustan los pesos de la red mediante la retropropagación del error y el uso de optimizadores, como el descenso de gradiente estocástico (SGD). Con esta operación se consigue que las conexiones de las neuronas o pesos de los modelos se optimicen de forma iterativa con respecto a minimizar el error de predicción, es decir, la diferencia entre el resultado verdadero y el predicho. Para determinar la calidad del modelo, se emplean métricas de evaluación tanto en la fase de entrenamiento como en la de validación. Entre las métricas más utilizadas en tareas de clasificación se encuentran la precisión (accuracy), que mide el porcentaje de aciertos del modelo; la sensibilidad (recall), que indica la capacidad del modelo para detectar correctamente los casos positivos; la especificidad, que evalúa la capacidad de identificar correctamente los casos negativos; y la métrica F1-score, que representa un equilibrio entre precisión y sensibilidad. El monitoreo de estas métricas es esencial para evitar problemas como el sobreajuste (overfitting), donde el modelo memoriza los datos de entrenamiento y pierde capacidad de generalización, o el subajuste (underfitting), donde el modelo no logra aprender patrones relevantes. Esta red entrenada puede predecir el resultado de datos ocultos al pasar nuevos datos a través de la red[10,11].

El DL tiene la habilidad de aprender complejas representaciones de datos, siendo más robusto contra la variabilidad humana que el ML. En este sentido, el DL sobrepasa al ML. Por otra parte, requiere una gran cantidad de datos y un mayor poder computacional. Ahora bien, en la actualidad, los avances en el poder computacional, la mejora en el almacenaje de datos y los nuevos algoritmos de DL

han permitido a los computadores realizar tareas que antes eran imposibles. Actualmente, hay un aumento en el uso de los instrumentos de la IA en el área de la salud, donde las Redes Neuronales Convolucionales (CNN), una familia de redes neuronales profundas que hacen uso de convoluciones, desempeña un papel muy importante en el procesamiento de imágenes médicas[10].

Estas redes neuronales profundas son particularmente útiles para estructuras de datos complejos, como las imágenes, ya que son capaces de representar una imagen y sus características jerárquicas, como los bordes, las esquinas, las formas y los patrones macroscópicos[12]. Sin embargo, su implementación en odontología enfrenta el desafío de la disponibilidad de grandes volúmenes de datos etiquetados. Para abordar esta limitación, se emplean estrategias como el aumento de datos y el aprendizaje por transferencia.

El aumento de datos es una técnica que permite expandir artificialmente el conjunto de datos sin necesidad de recopilar nuevas muestras. En odontología, donde la obtención de imágenes clínicas y radiográficas etiquetadas es un proceso costoso y regulado, este método se vuelve especialmente útil. Se pueden aplicar transformaciones como rotaciones, inversiones, cambios de escala, modificaciones en el contraste, adición de ruido y desenfoque para crear versiones modificadas de las imágenes originales. Estas variaciones ayudan a mejorar la capacidad del modelo para reconocer estructuras dentales bajo diferentes condiciones y perspectivas, reduciendo así el riesgo de sobreajuste y mejorando su generalización a nuevos casos clínicos.

Por otro lado, el aprendizaje por transferencia ofrece una solución eficiente cuando la cantidad de datos disponibles es limitada. En lugar de entrenar un modelo desde cero, se utilizan redes neuronales profundas previamente entrenadas en conjuntos de datos extensos, generalmente de imágenes médicas o incluso de otros dominios visuales, y se ajustan a la tarea específica odontológica. Esto es posible porque las primeras capas de estas redes aprenden características generales, como bordes y texturas, que son útiles para múltiples aplicaciones. Luego, las capas superiores del modelo se refinan mediante reentrenamiento con imágenes odontológicas específicas, permitiendo que la red adquiera conocimientos especializados sin necesidad de un conjunto de datos masivo. Esta técnica no solo reduce el tiempo de entrenamiento y los requerimientos computacionales, sino que también mejora la precisión del modelo al aprovechar conocimientos previos adquiridos en otros dominios, que pueden ser, o no, médicos.

La IA ha comenzado a impactar en la odontología, incluyendo la mejora de las imágenes en radiología, el diagnóstico de quistes y tumores[13], el diagnóstico de lesiones periapicales[14], la identificación de la anatomía radicular para endodoncia[15], el diagnóstico de periodontitis[16], la localización automatizada de puntos de referencia cefalométricos en ortodoncia[17], la detección del foramen apical[18], la determinación de la longitud de trabajo[19] y la identificación de fracturas verticales[20].

Objetivo

Dar a conocer el camino a seguir para que el odontólogo pueda introducir el empleo de la IA, concretamente el DL, en la clínica odontológica y de esta forma favorecer la integración de la IA en el campo odontológico.

Metodología

Esta investigación está aprobada por el Comité de Ética de la Investigación de las Illes Balears (IB4015/19IP).

Para poder realizar nuestro estudio hemos analizado las imágenes radiológicas diagnósticas de pacientes con piezas dentales afectadas de periodontitis apical, en cuyo diagnóstico hemos tenido en cuenta los datos clínicos y pruebas complementarias, a las que se les ha realizado un tratamiento de conductos primarios no quirúrgico y su posterior evolución a partir de los 6 meses hasta los 10 años en algunos casos.

Todas las RX periapicales se realizaron con un X MIMD UNITY ACTEON SATELEC, las imágenes fueron adquiridas con un CARESTREAM 6100 y se utilizó un posicionador Rinn XCD (DENSPLY).

En todos los tratamientos se siguió la misma técnica de instrumentación y de obturación y en la RX final de tratamiento no se visualizaron poros ni sobreobturación.

Para empezar nuestro trabajo exportamos las RP2D de diagnóstico desde la radiovisiografía a una base de datos, asignándole un identificador a cada una de las imágenes e indicando a que tipo de pieza corresponden y estableciendo un valor lógico para determinar su curación (0) o no curación (1) así como la posición que la pieza afectada ocupa en la imagen radiológica otorgando a la pieza de la izquierda el nº1 y a partir de ésta tendremos las siguientes enumeraciones que se precisen dependiendo del número de piezas dentarias que aparecen en la radiografía periapical. Una vez finalizado este proceso, la BBDD (Bases de datos) ya está preparada para importarla al software encargado de hacer el estudio correspondiente.

Tratamiento de endodoncia que presenta curación al año

Base de datos

Id	Tooth	Healed	Position	Id	Tooth	Healed	Position	Id	Tooth	Healed	Position
00001	Molar	1	1	00041	Incisor	0	2	00404	Molar	0	1
00002	Canine	1	1	00042	Incisor	1	2	00406	Canine	0	2
00003	Incisor	1	2	00043	Incisor	1	2	00407	Incisor	0	3
00004	Incisor	1	1	00044	Molar	1	1	00408	Incisor	0	1
00005	Incisor	0	2	00045	Incisor	1	4	00409	Incisor	1	4
00006	Molar	1	2	00046	Premolar	1	1	00410	Premolar	1	1
00007	Molar	1	1	00047	Premolar	1	1	00411	Premolar	0	1
00008	Incisor	1	2	00048	Incisor	0	2	00412	Incisor	1	1
00009	Incisor	0	2	00049	Molar	1	1	00413	Incisor	1	3
00010	Incisor	1	3	00050	Molar	1	1	M1	Incisor	1	2
00011	Incisor	0	2	00051	Incisor	1	1	M3	Premolar	1	2
00012	Molar	1	2	00052	Molar	1	1	M5	Premolar	1	2
00013	Molar	1	1	00053	Molar	1	1	M6	Incisor	0	2
00014	Incisor	1	1	00054	Incisor	1	2	M6	Incisor	0	3
00015	Incisor	1	2	00327	Incisor	0	1	M6	Incisor	0	4
00016	Premolar	1	2	00333	Incisor	0	1	M8	Incisor	0	1
00017	Incisor	1	3	00334	Premolar	0	1	M9	Molar	0	1
00018	Molar	1	1	00335	Premolar	0	1	M11	Molar	1	1
00019	Premolar	1	1	00338	Molar	0	2	M12	Incisor	0	2
00020	Incisor	1	2	00339	Premolar	0	1	M13	Molar	0	1
00021	Molar	1	1	00342	Premolar	0	2	M15	Incisor	0	2
00022	Incisor	1	3	00346	Incisor	1	2	M15	Incisor	0	3
00023	Premolar	1	2	00348	Premolar	0	1	M17	Molar	0	1
00024	Incisor	1	3	00349	Molar	0	1	M18	Bicúspide	0	1
00025	Molar	1	1	00350	Incisor	1	2	M19	Canine	1	2
00026	Premolar	1	2	00351	Premolar	0	1	M20	Premolar	1	2
00027	Molar	1	2	00377	Canine	1	2	M21	Molar	0	1
00028	Canine	1	3	00379	Molar	1	1	M23	Canine	0	2
00029	Molar	1	2	00382	Premolar	0	2	M24	Canine	0	2
00030	Molar	1	1	00387	Molar	0	2	RX1	Molar	1	1
00031	Incisor	1	1	00393	Incisor	0	2	RX2	Molar	1	2
00032	Incisor	1	2	00397	Molar	0	1	RX3	Molar	0	1
00033	Incisor	1	2	00358	Canine	0	2	RX4	Molar	1	2
00034	Premolar	1	1	00363	Molar	1	1	RX5	Premolar	1	4
00035	Incisor	1	2	00370	Incisor	0	1	RX7	Molar	0	1
00036	Premolar	1	1	00373	Molar	0	1	RX8	Molar	0	1
00037	Molar	0	1	00375	Incisor	1	1	RX10	Incisor	1	2
00038	Molar	0	2	00376	Molar	0	1	RX11	Incisor	1	2
00039	Molar	0	1	00402	Incisor	0	1				
00040	Molar	1	1	00403	Incisor	1	2				

En nuestro estudio, para el análisis de las imágenes se ha utilizado el software de AnotIA que permite anotar y segmentar con precisión las radiografías y que ofrece además una serie de herramientas que permiten agregar notas, etiquetas y comentarios detallados (**Imagen 1**). El proceso se divide en varias fases. En primer lugar, se crea el proyecto (**Imagen 2**) y a continuación, se procede a cargar las imágenes a analizar y se definen las anotaciones o marcas que se van a realizar asignándoles un identificador y un color a cada una de ellas (**Imagen 3**).

Una vez completado este proceso, se pasa a realizar las anotaciones correspondientes a cada una de las radiografías. Para ello, utilizando las herramientas de delimitación se marca el área afectada por la lesión (**Imagen 4**) y se le añade un comentario que hace referencia al tipo de pieza y su numeración y, finalmente, se asigna la etiqueta correspondiente para la realización del análisis estadístico posterior (**Imagen 5**). En nuestro caso se han utilizado dos etiquetas, una para indicar que la lesión se ha curado (0) y la otra que no ha curado (1).

Dichas etiquetas son las que se utilizan para contrastar la información proporcionada por el especialista con los resultados obtenidos por DL.

Imagen 1

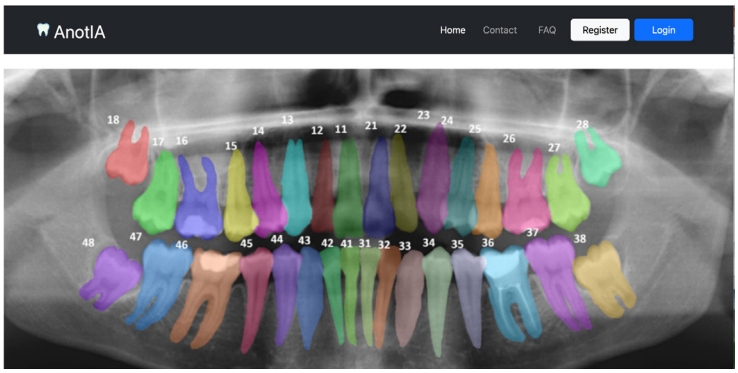

Imagen 2

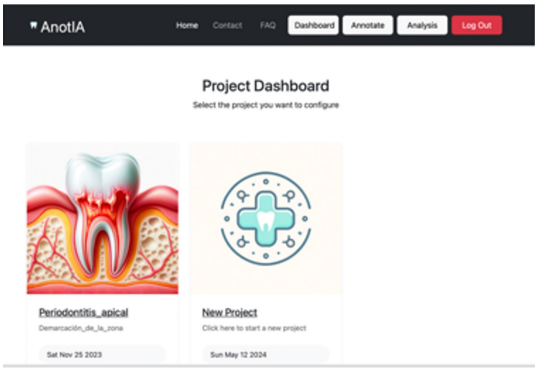

Imagen 3

Imagen 4

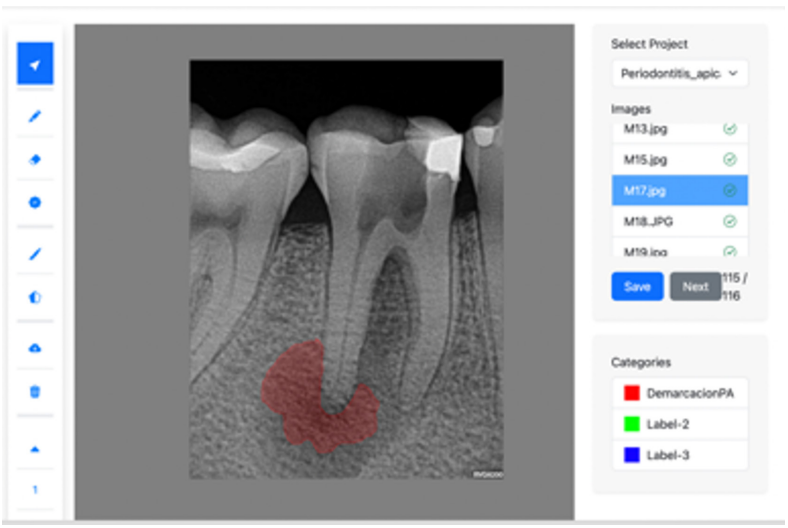

Imagen 5

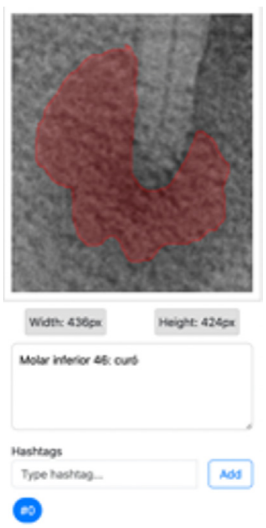

Discusión

Sólo a partir del año 2015 las ANNs empezaron a utilizarse en investigación, aplicándose a radiografías digitales y estas aplicaciones más recientemente se están incorporando en el territorio clínico[12]. Según Schwendicke et al.[8] este hecho contrasta con tres situaciones que se dan en la odontología haciéndola ideal para que se integre con la IA:

1. En la odontología las imágenes radiológicas son pruebas complementarias muy importantes. Las radiografías periapicales pueden ser usadas para el diagnóstico, planificación, realización y comparación de los resultados de tratamientos de endodoncia al proyectar con más exactitud las estructuras coronales y radiculares de las piezas que nos interesan que las radiografías panorámicas[13].

2. En odontología empleamos diferentes imágenes de una misma región y estas imágenes las acompañamos de datos clínicos y dentales. Pues bien, la IA puede vincular todos estos datos mejorando el diagnóstico, la predicción y la toma de decisiones.

3. En odontología se dan una serie de alteraciones prevalentes, como son las caries y las alteraciones pulpares. Gracias a ello la creación de un conjunto de datos que presenten estas alteraciones prevalentes no requiere un esfuerzo ilimitado.

Si bien en Odontología se dispone de un material muy apropiado para emplear la IA, en muchas ocasiones los datos son escogidos sin seguir ninguna guía lo cual genera un "sesgo de espionaje de datos"[14]. En nuestro caso los datos han sido recogidos siguiendo una plantilla de recopilación de datos que ha sido confeccionada para la estandarización de las investigaciones en endodoncia[15-17].

Cuando utilizamos el PAI para evaluar un tratamiento de endodoncia se nos pueden presentar dudas al tener que diagnosticar si existe éxito o fracaso ya que en caso de duda se asigna al diente el valor más alto[7]. Nosotros para evitar estas dudas, los resultados de nuestros tratamientos los hemos dicotomizado, lo cual también es realizado por otros autores[18-20].

Según Schwendicke et al.[21] la IA esta entrando rápidamente en nuestro campo de la odontología, sin embargo, muchos profesionales presentan unos conocimientos muy limitados para evaluar las aplicaciones de la IA a la odontología. Estos profesionales de la odontología para conseguir una alta cualidad en la aplicación de la IA necesitan un conocimiento básico y la adquisición de unas habilidades en el terreno de la IA. Para solventar este problema define un currículo tanto para la educación pregrado como en el postgrado con la finalidad de establecer un conjunto mínimo de conocimientos que los estudiantes deben adquirir sobre IA en sus estudios odontológicos. Considera que si este currículum es adoptado por los educadores y los estudiantes en la planificación, desarrollo y evaluación de la educación odontológica de la IA podría aumentar la formación de los profesionales odontológicos en el terreno de la IA.

Conclusión

Si bien hemos empleado una pequeña muestra de imágenes radiográficas, hemos podido exponer como es nuestra sistemática, que a nivel clínico no es difícil teniendo en cuenta que debemos tener conocimiento de la IA (aprendizaje profundo y redes neuronales profundas), para poder hacer posible realizar un estudio de DL y de esta forma poder saber si los resultados conseguidos mediante el estudio de lesiones periapicales mediante redes de aprendizaje profundo coinciden con los de nuestra casuística.

Confilctos de intereses

Las autoras declaran no tener conflictos de intereses.

References

1. Abbott P V. Classification, diagnosis and clinical manifestations of apical periodontitis. Endod Topics. 2004 Jul;8(1):36–54.

2. Van Nieuwenhuysen JP, D'Hoore W, Leprince JG. What ultimately matters in root canal treatment success and tooth preservation: A 25-year cohort study. Int Endod J. 2023 May 8;56(5):544–57.

3. Segura-Egea JJ, Cabanillas-Balsera D, Martín-González J, Cintra LTA. Impact of systemic health on treatment outcomes in endodontics. Int Endod J. 2022 Jul 8;

4. Jakovljevic A, Nikolic N, Jacimovic J, Pavlovic O, Milicic B, Beljic-Ivanovic K, et al. Prevalence of Apical Periodontitis and Conventional Nonsurgical Root Canal Treatment in General Adult Population: An Updated Systematic Review and Meta-analysis of Cross-sectional Studies Published between 2012 and 2020. J Endod. 2020 Oct;46(10):1371-1386.e8.

5. Goldman M, Pearson AH, Darzenta N. Endodontic success--who's reading the radiograph? Oral Surg Oral Med Oral Pathol. 1972 Mar;33(3):432-7. doi: 10.1016/0030-4220(72)90473-2. PMID: 4501172

6. Goldman M, Pearson AH, Darzenta N. Reliability of radiographic interpretations. Oral Surg Oral Med Oral Pathol. 1974 Aug;38(2):287-93. doi: 10.1016/0030-4220(74)90070-x. PMID: 4528712.

7. Jiménez Pinzón A, Segura Egea JJ. Valoración clínica y radiológica del estado periapical: registros e índices periapicales. Endodoncia (Mex). 2003;21(4):220-8.

8. Schwendicke F, Samek W, Krois J. Artificial Intelligence in Dentistry: Chances and Challenges. J Dent Res. 2020 Jul 1;99(7):769-74.

9. Shan T, Tay FR, Gu L. Application of Artificial Intelligence in Dentistry. Vol. 100, Journal of Dental Research. SAGE Publications Inc.; 2021. p. 232-44.

10. Leite AF, Vasconcelos K de F, Willems H, Jacobs R. Radiomics and Machine Learning in Oral Healthcare. Proteomics Clin Appl. 2020 May 29;14(3):1900040.

11. Vodanović M, Subašić M, Milošević D, Pavičin IS. Artificial Intelligence in Medicine and Dentistry. Vol. 57, Acta Stomatologica Croatica. University of Zagreb; 2023. p. 70-84.

12. Schwendicke F, Golla T, Dreher M, Krois J. Convolutional neural networks for dental image diagnostics: A scoping review. J Dent [Internet]. 2019 Dec 1;91:103226. Available from: https://linkinghub.elsevier.com/retrieve/pii/S0300571219302283

13. Setzer FC, Lee SM. Radiology in Endodontics. Dent Clin North Am. 2021 Jul;65(3):475-86.

14. Gianfrancesco MA, Tamang S, Yazdany J, Schmajuk G. Potential Biases in Machine Learning Algorithms Using Electronic Health Record Data. JAMA Intern Med. 2018 Nov 1;178(11):1544.

15. Azarpazhooh A, Khazaei S, Jafarzadeh H, Malkhassian G, Sgro A, Elbarbary M, et al. A Scoping Review of Four Decades of Outcomes in Nonsurgical Root Canal Treatment, Nonsurgical Retreatment, and Apexification Studies: Part 3—A Proposed Framework for Standardized Data Collection and Reporting of Endodontic Outcome Studies. J Endod. 2022 Jan;48(1):40-54.

16. Azarpazhooh A, Sgro A, Cardoso E, Elbarbary M, Laghapour Lighvan N, Badewy R, et al. A Scoping Review of 4 Decades of Outcomes in Nonsurgical Root Canal Treatment, Nonsurgical Retreatment, and Apexification Studies—Part 2: Outcome Measures. Vol. 48, Journal of Endodontics. Elsevier Inc.; 2022. p. 29-39.

17. Azarpazhooh A, Cardoso E, Sgro A, Elbarbary M, Laghapour Lighvan N, Badewy R, et al. A Scoping Review of 4 Decades of Outcomes in Nonsurgical Root Canal Treatment, Nonsurgical Retreatment, and Apexification Studies—Part 1: Process and General Results. Vol. 48, Journal of Endodontics. Elsevier Inc.; 2022. p. 15-28.

18. Herbst CS, Schwendicke F, Krois J, Herbst SR. Association between patient-, tooth- and treatment-level factors and root canal treatment failure: A retrospective longitudinal and machine learning study. J Dent [Internet]. 2022 Feb;117:103937. Available from: https://linkinghub.elsevier.com/retrieve/pii/S0300571221003596

19. Suebnukarn S, Rungcharoenporn N, Sangsuratham S. A Bayesian decision support model for assessment of endodontic treatment outcome. Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology and Endodontology. 2008 Sep;106(3).

20. Moidu NP, Sharma S, Chawla A, Kumar V, Logani A. Deep learning for categorization of endodontic lesion based on radiographic periapical index scoring system. Clin Oral Investig. 2021;

21. Schwendicke F, Chaurasia A, Wiegand T, Uribe SE, Fontana M, Akota I, et al. Artificial intelligence for oral and dental healthcare: Core education curriculum. J Dent [Internet]. 2022 Nov 18;104363. Available from: http://www.ncbi.nlm.nih.gov/pubmed/36410581

View publication stats